

Göğüs Kanseri Histopatolojik Görüntü Sınıflandırması

Araştırma Makalesi/Research Article

 Ebru ERDEM*,  Tolga AYDIN

Bilgisayar Mühendisliği Bölümü, Atatürk Üniversitesi, Erzurum, Türkiye
ebuerdem@atauni.edu.tr, atolga@atauni.edu.tr
 (Geliş/Received:02.06.2020; Kabul/Accepted:15.01.2021)
 DOI: 10.17671/gazibtd.746673

Özet— Meme kanseri, dünya genelinde kadınlarda, akciğer kanserinden sonra en çok rastlanan kanser türlerinden biridir. Kanserin erken teşhisi ve sınıflandırılması hastaların iyileşme sürecine olumlu etki edebilmektedir. Bu çalışmada, göğüs histopatolojik görüntülerinde kanser tespiti için derin öğrenme yaklaşımları sunulmuştur. Derin öğrenme mimarilerinin başarısı probleme özgü değişebilmektedir. Bu çalışmada, önceden eğitilmiş CNN mimarilerinden, VGG16, Inception-V3 ve iki derin sinir ağı birleşimi olan ağ (VGG16+Inception-V3) kullanılarak sınıflandırma yapılmıştır. Çalışma içerisinde birleştirme ağ yapısı VIHist olarak adlandırılmıştır. Önerilen yaklaşımların performansı, BreakHist veri seti üzerinde incelenmiştir. Tespit için kullanılan görüntüler 40X büyütülmüş görüntü slaytlarıdır. Elde edilen bulgularda, %99.03 başarı ile birleştirme ağ yapısı (VIHist) en yüksek doğruluk oranını vermiştir. Inception-V3 ağı, VGG16 derin sinir ağına göre ~%6 daha üstün performans göstermiştir. Hastalık üzerinde patoloji bilgisine sahip olunmamasına rağmen, önerilen derin öğrenme mimarileri ile hastalık tespitinde %98.3 ± %1 başarı elde edilmiştir. Sonuçlar incelendiğinde, literatürdeki başarılı çalışmalara göre performansın daha yüksek bulunduğu görülmüştür.

Anahtar Kelimeler— Göğüs kanseri, Inception-V3, VGG16

Breast Cancer Histopathological Image Classification

Abstract—Breast cancer is one of the most common types of cancer in women worldwide, after lung cancer. Early diagnosis and classification of cancer can positively affect the healing process of patients. In this study, deep learning approaches for cancer detection in chest histopathological images are presented. The success of deep learning architectures may vary depending on the problem. In this study, classification is made using pre-trained CNN architectures, VGG16, Inception-V3, and the network (VGG16 + Inception-V3), which is a combination of two deep neural networks. The concatenate network structure in the study was named as VIHist. The performance of the proposed approaches has been examined on the BreakHist dataset. The images used for detection are 40X magnified image slides. In results, the concatenate network structure (VIHist) gave the highest accuracy rate with 99.03% accuracy. Inception-V3 network showed ~6% superior performance than VGG16 deep neural network. Although there is no pathology knowledge on the disease, 98.3% ± 1% accuracy was achieved in the detection of diseases with the proposed deep learning architectures. When the results are examined, it is seen that the performance is higher than the successful studies in the literature.

Keywords— breast cancer, Inception-V3, VGG16

1. GİRİŞ (INTRODUCTION)

Medikal ve biyomedikal alanlarda, farklı biyolojik eylemlerin anlaşılmasında mikroskopik görüntülerin analizi önem teşkil etmektedir. Doku resimleri sınıflandırırken, iyi huylu ya da kötü huylu hücre tespiti zordur. Meme kanserinin sınıflandırılması, patoloji

uzmanlarının sistematik tanı koyabilmelerine imkân tanımaktadır. Bilgisayar destekli geliştirilen sistemler bu duruma yardımcı olmaktadır. Bu amaçla, makine öğrenmesi ya da derin öğrenme yöntemleri ile kanser doku tespiti yapılabilmektedir. Sarıtaş ve Yaşar (2019) tarafından kan testi sonucu elde edilen, glukoz, insülin, HOMA, Leptin, Adiponektin, Resistin, MCP-1, yaş ve

BMI verileri elde edilerek meme kanseri olma durumu tahmin edilmiştir. Veri sınıflandırması için naive bayes ve yapay sinir ağları (YSA) kullanılarak performans analizi incelenmiştir. YSA ile %86.95 ve naive bayes ile %83.54 başarı elde edilmiştir [1]. Bardou ve diğerleri tarafından konvolüsyonel sinir ağları kullanılarak önerilen yaklaşımda histoloji görüntülerine göre meme kanserinin sınıflandırılması yapılmıştır. Yaklaşık %96.15 başarı alınmış ve klasik elle çıkartılan özelliklere göre üstün başarı alındığı gösterilmiştir [2]. Meme kanseri (BC), memenin cilt dokusuna, acı şiddetine, gende oluşan mutasyon gibi durumlara göre, adenosis, fibroadenom gibi farklı karakteristiklere ayrılabilir. Amrane, vd. tarafından k en yakın komşu (KNN) ve naive bayes (NB) ile sınıflandırma yapılmıştır. %97.51 başarı oranı ile KNN başarı oranı NB'yi (%96.19) geçmiştir [3].

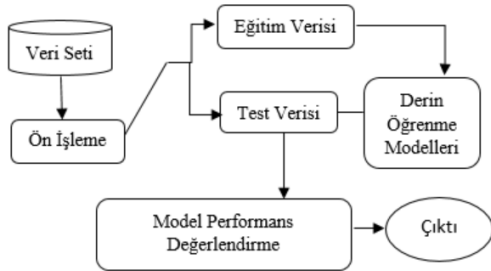
Literatürde genel olarak meme kanseri ikili sınıflandırılmıştır. Ama, bu durum meme kanserinin kantitatif değerlendirilmesine katkı sağlamamaktadır. Han tarafından önerilen derin öğrenme modeli ile çoklu sınıflandırma yapılmıştır. Meme kanserinin, duktal karsinom, fibroadenom, adinos, lobüler karsinom gibi türlerden hangisine ait olduğu saptanmıştır. Ortalama %93.2 doğruluk elde edilmiştir [4]. Derin öğrenme ile otomatik meme kanseri teşhisi, Benhammou, vd. tarafından yapılmıştır. Probleme çoklu-kategori (MIM) yaklaşımı uygulanmıştır [5]. Derin öğrenme ile BreakHist veri seti üzerinde, Nahid, vd. tarafından yapılan çalışmada, 40X görüntüler üzerinde %88.7, 100X görüntüler üzerinde %85.3, 200X görüntüler üzerinde %88.6 ve 400X görüntüler üzerinde %88.4 başarı elde edilmiştir [6].

Derin öğrenmede görüntüler üzerindeki sınıflandırma ya da nesne tespitinde en çok kullanılan ağlardan biri konvolüsyonel sinir ağlarıdır. Derin konvolüsyonel sinir ağları ile histopatoloji resimleri üzerindeki sınıflandırma başarısı Adeshina, vd. tarafından yapılan çalışmada görülmüştür. BreakHis veri seti üzerinde %91.5 başarı yakalanmıştır [7]. Bayramoğlu ve diğerleri tarafından evrişimsel sinir ağları (CNN) kullanılarak sınıflandırma işlemi yapılmıştır. Elde edilen sonuçlarda, 40X görüntülerde %80 civarında başarı elde edilmiştir. Ayrıca 40x, 100X, 200X, 400X görüntülerde genel olarak ortalama %83.25 oran başarı ile yararlı/zararlı doku sınıflandırması yapılmıştır [8]. Ting ve arkadaşları, meme kanseri sınıflandırması için, evrişimsel sinir ağı geliştirmişlerdir (CNNI-BCC). Göğüs kanseri üzeri ile ilgili tıbbi resimler, iyi huylu, kötü huylu ya da sağlıklı olarak sınıflandırılmıştır. Elde edilen sonuçlarda, %90.50 başarılı sınıflandırma ile uzmanlara yardım etmek amaçlanmıştır [9]. Sudharshan, vd. tarafından önerilen çoklu örnek öğrenme (MIL) ile BreakHis veri setinde klasik öğrenme ile elde edilen sonuçlara göre daha üstün başarı elde edildiği görülmüştür. 40X görüntüler üzerinde, MIL ile %92.1 başarı ile CNN (%90) sonucuna göre üstünlük elde edilmiştir [10]. Alom, vd. tarafından önerilen Inception Recurrent Residual konvolüsyon sinir ağının (IRRCNN), Deep konvolüsyon sinir ağına göre sınıflandırmada daha yüksek başarı elde ettiği gözlemlenmiştir [11]. Konvolüsyonel sinir ağları, biyolojik

görüntü işleme sistemlerinden esinlenerek oluşturulmuştur. Konvolüsyonel bir sinir ağı eğitimi çok uzun sürebilir. Bu duruma çözüm olarak, önceden eğitilmiş ağ yapıları öne sürülmektedir. Bu duruma örnek olarak, Khan, vd. tarafından yapılan çalışmada, göğüs sitoloji resimleri kullanarak transfer öğrenme ile derin öğrenme mimarisi önerilmiştir. GoogleNet, ResNet ve VGGNet ile özellikler çıkartılıp, tam bağlı katmana sınıflandırma için verilmiştir [12]. Saini, vd. tarafından yapılan çalışmada BREAKHIS veri seti üzerinde Inception-V3 ve Resnet-50 ön eğitilmiş ağlar ile sınıflandırma yapılmıştır. En yüksek başarı Inception-V3 modelinden alınmıştır [13]. Chang, vd. tarafından yapılan çalışmada, 7909 mikroskopik biyopsi görüntüden oluşan BreakHis veri seti üzerinde Inception-V3 modeli ile sınıflandırma yapılmıştır. Elde edilen sonuçlarda, %93 AUC alınmıştır [14]. Gour, vd. tarafından yapılan çalışmada, büyütme faktörü 40X olan 1995 görüntüden oluşan BreakHis veri seti üzerinde, Inception-V3 ile %76.77±%1.73 başarı alınmıştır [15]. Göğüs kanserini tespit etmek için BreakHis veri seti üzerinde yapılan başka bir çalışmada ise büyütme faktörü 40X görüntülerde, VGG16 ile ~%93 başarı alınmıştır [16]. Man, vd. tarafından yapılan çalışmada, VGG16 ile 40X görüntüler üzerinde, %82.64±%1.9 başarı alınmıştır [17]. Bu çalışmada ise tümör doku sınıflandırma işlemi için iki farklı ön eğitilmiş derin öğrenme yaklaşımı kullanılmıştır: Inception-V3 ve VGG16.

Inception-V3 [18], Google tarafından geliştirilmiş ve eğitilmiş modeldir. 2014 yılında, ImageNet yarışmasında yaklaşık 1.2 milyon resmi öğrenerek üstün performans göstermiştir. Bu sinir ağı, 22 katmandan oluşmaktadır. Bu mimaride, ardışık yapıda konvolüsyon ve havuzlama katmanları üst üste gelmektedir. Bu sebeple, hafıza açısından oldukça güçlüdür. Vgg16'nın [19] diğer modellerden en önemli farkı evrişim katmanlarınının 2'li ya da 3'lü kullanılmasıdır. Bu modelde de ağı giriş kısmından çıkışına doğru ilerledikçe, derinlik artar iken, matris boyutu azalmaktadır. Ağa girecek görüntü boyutu, 224x224 boyutunda olmalıdır.

Evrişimsel sinir ağların, nesne tespiti yaparken, kenar bulma, imge türevleri elde etme üzerindeki üstün başarısı, tıbbi görüntüler üzerindeki analiz işlemlerini kolaylaştırmıştır. Bu çalışmada bu ağlar ile ikili sınıflandırma yapılmıştır (iyi huylu, kötü huylu). BreakHis [20] isimli açık erişim olarak dağıtımı yapılan veri seti üzerinde işlemler gerçekleştirilmiştir. 40X büyütme seviyesi altında yer alan görüntüler dikkate alınarak sınıflandırma yapılmıştır. Sınıflandırma işlemi için gerçekleştirilen çalışmanın akış diagramı Şekil 1'de verilmiştir. Bu şema incelendiğinde, hafızada tutulan veri üzerinde ön işleme gerçekleştirilmiştir. Elde edilen yeni görüntüler üzerinde çeşitliliği sağlamak için veri artırma işlemi yapılarak eğitim başarısının artırılması hedeflenmiştir. Doku slayt görüntüleri üzerinde meme tümör hücrelerini tespit eden derin sinir ağlar uygulanmıştır. Görüntüler, Inception-V3, VGG16 ve VIHist eğitilmiş sinir ağlarından geçirilmiştir. Özellik çıkarma ve sınıflandırma işlemi gerçekleştirilmiştir.



Şekil 1. Çalışmanın akış diagramı
(The workflow of the study)

Bu çalışmanın 2. Bölümü'nde kullanılan veriye ve ön işleme ait bilgiye, 3. Bölümde kullanılan yöntemle, 4. Ve 5. Bölümlerde sırasıyla yapılan deneylere ve performans sonuçlarına yer verilmiştir.


2. VERİ SETİ VE ÖN İŞLEME (DATA SET AND PRE-PROCESSING)

2.1. Veri Seti (Data Set)

BreakHis (göğüs kanseri histopatolojik görüntüleri) veri tabanı, Patolojik Anatomi (P&D Laboratuvarı) ve Sitopatoloji [20] (Parana, Brezilya) işbirliği ile oluşturulmuştur. Bu veri tabanı, 82 hastadan toplanan 9.109 mikroskopik göğüs tümör dokularının farklı büyütme faktörlerinden (40X, 100X, 200X, 400X) oluşmaktadır. Toplam, 2.480 iyi huylu, 5.429 kötü huylu örnek mevcuttur. Her bir örnek 700x460 piksel boyutunda, 3 kanallı RGB olarak ve her bir kanal 8 bit derinlikten oluşmaktadır. BreakHis veri seti iki ana gruba ayrılır: İyi huylu tümörler ve kötü huylu tümörler. İyi huylu tümör, geliştikleri yerde sınırlı kalır iken kötü huylu tümör organlar ve çevre dokulara yayılır. Kötü huylu tümör kanser ile eş anlamlıdır. Veri setindeki veriler, eksizyonel biyopsi ve mastektomi yöntemi ile toplanmıştır. Tümörler, mikroskop altında hücrelerin görünüşüne bağlı olarak farklı tiplere ayrılabilir. Veri setinde bulunan iyi ve kötü huylu tümör kendi içinde 4 farklı tipe sahiptir. İyi huylu tümör tipleri: Adenoz (A), fibroadenom (F), filloid tümör, tübüler adenoma (TA). Kötü huylu tümör tipleri: Karsinom (DC), lobüler karsinom (LC), müsinöz karsinom (MC), papiller karsinom (PC).

2.2. Ön İşleme (Pre Processing)

Bu çalışma kapsamında, 40X büyütülmüş göğüs tümör dokuları üzerinde işlemler gerçekleştirilmiştir. Görüntü boyutu 244x224 olacak şekilde yeniden boyutlandırılmıştır. Görüntüler, numpy matrisi içerisine alınmıştır, 0 veya 1 olarak etiketlenmiştir. Sınıflandırma için kullanılacak evrişimsel sinir ağ mimarileri, matrisde yer alan pixel değerleri üzerinde işlemlerini yürütmektedir. Toplam 1.975 görüntünün, 1.383 tanesi eğitim ve 592 tanesi test için kullanılmıştır. Bu çalışma için gerçekleştirilen veri yapılandırılması Tablo 1'de verilmiştir.



Şekil 2. Histopatolojik 40X görüntü örnekleri
(Histopathological 40X image samples)

Tablo 1. Veri yapılandırılması
(Data configuration)

Tip	Eğitim	Test
İyi Huylu	438	187
Kötü Huylu	945	405
Toplam	1.383	592

Performansın artmasına yardımcı olmak için, eğitim esnasında veri kümesindeki her bir sınıf için veri artırma işlemi yapılmıştır. Elde edilen verinin model üzerindeki etkisi ölçülmüştür. Aşırı uyumu önlemek için gerçekleştirilen bu işlemler, "keras.preprocessing.image.ImageDataGenerator" sınıfı ile yapılmıştır. Bu çalışmada, artırma işlemi için kullanılan teknikler: Yakınlaştırma, yatay döndürme ve dikey döndürmedir. Yakınlaştırma, görüntüyü enterpolasyonlu hale getirilebilir ya da görüntüyü rastgele yakınlaştırır. Yakınlaştırma yüzdesi tek bir kayan nokta ya da aralık olarak verilebilir. Çalışma içerisinde, "ImageDataGenerator" yapıcısının, "zoom_range" parametresi ile yakınlaştırma işlemi yapılmıştır. Yakınlaştırma aralığı 2 olarak alınmıştır. Verilen kayan nokta durumuna göre, yakınlaştırma aralığı %100 (yakınlaştırma) ile %300 (uzaklaştırma) arasında olmuştur. "ImageDataGenerator" yapıcısının, "rotation_range" parametresi ile rastgele yatay ve dikey döndürme açısı 90° olarak alınmıştır.

3. METODOLOJİ (METHODOLOGY)

Python ortamında tüm deneylerin implemantasyonu gerçekleştirilmiştir. Keras kütüphanesi kullanılmıştır [21]. Eğitilmiş ağ olan Inception-V3 ve VGG16'nın sınıflandırma üzerinde yüksek performans ve minimum hata vermesi sebebi ile bu çalışma için kullanımı tercih edilmiştir. Inception-V3 ve VGG16 ile evrişimsel sinir ağ özellikleri çıkartılmış ve kanser doku hücresinin sınıflandırması yapılmıştır. Birleştirme ağ yapısında ise iki ağ yapısında çıkartılan birden çok özellik kullanılmış ve sınıflandırma yapılmıştır.

3.1. Inception-V3, VGG16 (Inception-V3, VGG16)

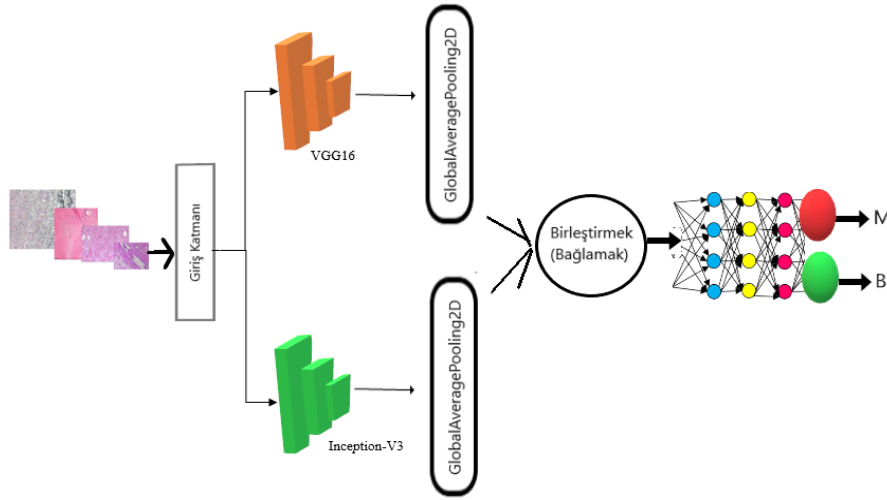
GoogleNet'in gelişmiş bir sürümü olan evrimsel sinir ağ mimarisidir. Inception modül çerçevesi kullanılarak, büyük evrim ağlarını daha küçük evrim ağlarına ayırarak, yüksek hesaplamalı evrimsel katmanların azaltılması amaçlanmıştır. Bu mimaride yer alan modüller, daha büyük evrimle (kırımla) aynı etkiyi oluşturmak için, büyük evrimleri daha küçük evrimlere hesaplamalı olarak ayırır. Bu ağda daha küçük evrimler ve daha az parametrelerden oluşur. Mimaride, 1x1 ve 3x3 lük evrimler ve havuzlama işlemi, 3x3 ve 5x5 lik evrimsel ve havuzlama işleminden önce yapılır ve maliyet azalması hedeflenir. Bu modüllerin kullanımı ile parametre sayısı azaltılmaktadır. AlexNet'de [22] 60 milyon parametre kullanılır iken, bu rakam Inception modülleri sayesinde GoogleNet'de [23] 5 milyona düşürülmüştür.

Simonyan ve arkadaşları tarafından mevcut evrimsel sinir ağ modellerinin derinliği artırılarak VGGNet adında

yeni model önerilmiştir. Bu model, 16 ya da 19 katmandan oluşmaktadır. Bu çalışmada, 16 katmanlı ve 3x3'lük filtrelerden oluşan mimarisi kullanılmıştır [19].

3.2. VIHist (VIHist)

VIHist olarak adlandırılan, birleştirilmiş ağda gömülü modül olarak iki farklı derin öğrenme ağı seçilmiştir: VGG16 ve Inception-V3. VIHist sistem mimarisi Şekil 3'de verilmiştir. Bu mimaride, VGG16 ve Inception-V3 modelleri ayrı ayrı eğitilmiştir. "Global Average Pooling2D" katmanından sonra ise sonuçlar birleştirilmiştir. Birleştirme katmanı, girdi olarak tensörlerin bir listesini alır ve birleştirme eksenini etrafında tüm girdileri birleştirir. Birleştirme sonucu elde edilen özelliklere göre, sınıflandırma işlemi gerçekleştirilmiştir. Bu amaçla, son aşamada 512 nörondan oluşan, 2 tam bağlı katman kullanılmıştır. Çıktı katmanında ise softmax katmanı ile sınıflandırma yapılmıştır. VIHist mimarisinin parametre detayları Tablo 2'de verilmiştir.



Şekil 3. VIHist mimarisi özellik çıkartma, sınıflandırma diagramı (VIHist architecture feature extraction, classification diagram)

Tablo 2. VIHist mimarisinin parametre detayları (Parameter details of the VIHist architecture)

Model	Katman	Çıktı Büyüklüğü	Parametre #	Toplam Parametre
VIHist	input_1	(None,224,244,3)	0	38,092,386
	vgg16	(None,7,7,512)	14714688	
	inception_v3	(None,5,5,2048)	21802784	
	global_average_pooling_2d_1	(None,512)	0	
	global_average_pooling_2d_2	(None,2048)	0	
	concatenate_1	(None,2560)	0	
	dense_1	(None,512)	1311232	
	dense_2	(None,512)	262656	
	dense_3	(None,2)	1026	

3.3. Test Ortamı (Test Environment)


Çalışmada kullanılan derin sinir ağlar, Tablo3'de yer alan konfigürasyonlara sahip bilgisayarda çalıştırılmıştır.

Tablo 3. Test işleminin yapıldığı bilgisayar konfigürasyonları
(Computer configurations where the test procedure)


Bellek	245676MB, 24GB
İşlemci	Intel(R) Core(TM) i7-7700 CPU @3.60GHz (8 CPUs), ~3.6GHz
Ekran Kartı	Intel(r) Hd Graphics 630 NVIDIA GeForce GT 730
İşletim Sistemi	Windows 10 Pro 64 Bit (10.0, build 18362)

4. BULGULAR (RESULTS)


40X büyütülmüş görüntüler üzerinde performans değerlendirilmesi yapılmıştır. Bu çalışmada, InceptionV3, VGG16 ve VHIst mimarileri kullanılarak deneyler yapılmıştır. Yapılan deneylerde, her koşulda sınıf sayısı 2'dir. Kayıp fonksiyonu olarak, "binary_crossentropy" kullanılmıştır. Öğrenme oranı "0.001", batch size "16" olarak alınıp, iyileştirme yöntemi olarak "adam" kullanılmıştır. Farklı mimarilerin sınıflandırma üzerindeki başarısını görmek için, 3 farklı derin öğrenme mimarisine ait sonuçlar karşılaştırılmıştır. Optimizasyon ve performans öğrenme eğrileri incelendiğinde, VGG16, Inception-V3 ve VHIst derin sinir ağlarının, eğitim ve doğrulama dağılımları birbirine yakın olduğu için uygun birer model oldukları düşünülebilir (Şekil-4, Şekil-5, Şekil-6, Şekil-7, Şekil-8, Şekil-9). Grafiksel sonuçlarda, Inception-V3 modelinin VGG16'ya göre ve VHIst modelinin VGG16'ya göre veri seti ile arasında daha fazla uyum olduğu ve öğrenmenin olumlu seyrinde devam ettiği görülmektedir. Her üç mimaride de ezberleme ya da öğrenememe durumu gerçekleşmemiştir.




Şekil 4. VGG16 performans başarı durum grafiği gösterimi
(VGG16 performance accuracy graph representation)




Şekil 5. VGG16 performans kayıp durum grafiği gösterimi
(VGG16 performance loss graph representation)




Şekil 6. Inception-V3 performans başarı durum grafiği gösterimi
(Inception-V3 performance accuracy graph representation)



Şekil 7. Inception-V3 performans kayıp durum grafiği gösterimi
(Inception-V3 performance loss graph representation)



Şekil 8. VHIst performans başarı durum grafiği gösterimi
(VHIst performance accuracy graph representation)




Şekil 9. VIHist performans kayıp durum grafiği gösterimi
(VIHist performance loss graph representation)

Bu çalışmada, performans değerlendirmesi için, doğruluk, ROC eğrisi ve AUC metrikleri kullanılmıştır. Kullanılan algoritmaların sınıflandırma sonucundaki başarı yüzdeleri Tablo 4’de verilmiştir. Çalışmanın temel değerlendirme prensibi olan doğruluk oranına bakıldığında, VIHist derin sinir ağı ile daha yüksek başarı elde edilmiştir (%99.03). Algoritmaların AUC’lerine bakıldığında, sınıflandırma başarısı en yüksek olan yöntemin yine %74.2 oranı ile VIHist olduğu görülmüştür.

Tablo 4. Derin öğrenme mimarilerinin test verisi üzerindeki başarı durumları
(Success situations of deep learning architectures on test data)

Mimari	AUC(%)	Accuracy(%)
VGG16	69.6	92.2
Inception-V3	71.3	98.3
VIHist	74.2	99.03


Şekil 10, Şekil 11 ve Şekil 12’de görülen ROC eğrilerine göre, üç algoritmanın doğruluk sonucunun birbirine yakın olduğu görülmektedir.




Şekil 10. VGG16 performansının ROC eğrisinde gösterimi
(Representation of VGG16 performance on the ROC curve)

Şekil 13, Şekil 14 ve Şekil 15’de yer alan karışıklık matrislerinde görülen performans değerlendirmesi incelendiğinde, VGG16 mimarisinde, 127 iyi huylu tümör doğru, 60 tanesi ise yanlış tespit edilmiştir. 289 kötü huylu tümör doğru, 116 tanesi ise yanlış tespit edilmiştir. Inception-V3’de, 147 iyi huylu tümör doğru, 40 tanesi ise yanlış tespit edilmiştir. 259 kötü huylu tümör doğru, 146 tanesi ise yanlış tespit edilmiştir. VIHist mimarisinde ise, 141 iyi huylu tümör doğru, 46 tanesi ise yanlış tespit edilmiştir. 296 kötü huylu tümör doğru, 109 tanesi ise yanlış tespit edilmiştir. Bu duruma göre, iyi huylu tümör

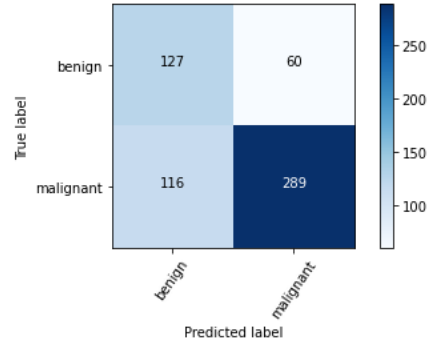
tespitinde, Inception-V3 mimarisi daha üstün performans sergilemiştir. Kötü huylu tümör tespitinde ise VIHist daha üstün performans göstermiştir.



Şekil 11. Inception-V3 performansının ROC eğrisinde gösterimi
(Representation of Inception-V3 performance on the ROC curve)




Şekil 12. VIHist performansının ROC eğrisinde gösterimi
(Representation of VIHist performance on the ROC curve)



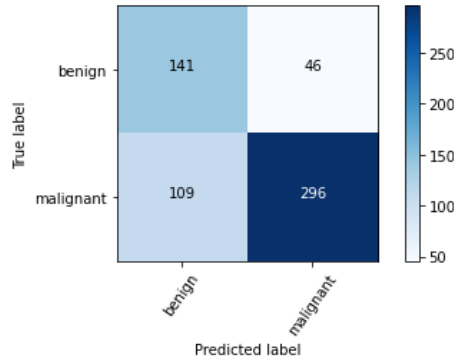
Şekil 13. VGG16 karışıklık matrisi
(VGG16 confusion matrix)

Tablo 5’de aynı veri seti [20] üzerinde, meme kanseri tespitini yapan diğer yaklaşımlar ile önerilen mimarilerin karşılaştırılması yapılmıştır. 2016 yılında, Neslihan ve diğ. [9], meme kanseri tespiti için önerdikleri CNN yöntemi ile %80 civarında başarı yakalamışlar. 2018 yılında, Abdullah-Al, vd. [11] tarafından RBM ile yapılan sınıflandırmada %88.7 başarı yakalanmış. Sudharshan, vd. tarafından [5] çoklu örnek öğrenme (MIL) ile 40X görüntüler üzerinde %92.1 oranında bulunan performans, bu çalışmada VGG16 ile %0.1 artırılıp %92.2, Inception-V3 ile %6.2 artırılıp %98.3 ve VIHist ile %6.93 artırılıp %99.03 doğruluk oranına ulaşılmıştır. 2020 yılında, Sharma vd. [16] tarafından, 40X görüntüler üzerinde

VGG16 ile elde edilen başarı, bu çalışmada Inception-V3 ve VGG16 ile ~%6 artırılmıştır. Tablo 5’de görüldüğü gibi, bu çalışmada uygulanan üç derin öğrenme mimari performansı, mevcut çalışmalarda kullanılan modellere nispeten daha başarılı olmuştur.



Şekil 14. Inception-V3 karışıklık matrisi
(Inception-V3 confusion matrix)



Şekil 15. VIHist karışıklık matrisi
(VIHist confusion matrix)

2020 yılında, Sharma vd. [16] tarafından, 40X görüntüler üzerinde VGG16 ile elde edilen başarı, bu çalışmada Inception-V3 ve VIHist ile ~%6 artırılmıştır. Tablo 5’de görüldüğü gibi, bu çalışmada uygulanan üç derin öğrenme mimari performansı, mevcut çalışmalarda kullanılan modellere nispeten daha başarılı olmuştur.

Tablo 5. Yapılan çalışmalarla karşılaştırmalar
(Comparisons with studies)

Makale	Yıl	Yöntem	Doğruluk(%)
Sudharshan vd. [6]	2019	MIL	92.1
Abdullah-Al and etc. [11]	2018	RBM	88.7
Neslihan vd. [9]	2016	CNN	~80
Sharma vd. [16]	2020	VGG16	~%93
Önerilen-1	2020	VGG16	92.2
Önerilen-2	2020	Inception-V3	98.3
Önerilen-3	2020	VIHist	99.03

5. SONUÇLAR (CONCLUSIONS)

Kadınlar arasında görülen meme kanseri teşhisinde, meme dokusunun mikroskopik görüntülerinin yorumlanması

gerekir. Doktorlar tarafından, meme kanserinin tespiti için dijital bir tıbbi fotoğrafçılık tekniği kullanılmaktadır. Ama, doğru tespit için alanında yeterli olması ve daha fazla zaman harcaması gerekmektedir. Uzmanlara yardımcı olmak için önerilen bilgisayar destekli sistemler son derece önem taşımaktadır. Bu sistemlerinin kanseri tanıma işlemi ve monitörde kanser hücreleri doğru gösterebilmesi için çeşitli teknikler geliştirilmiştir. Dijital görüntü tekniklerindeki ilerlemeler, patoloji çalışma akışında önerilen teşhis yöntemlerinin otomatikleştirilmiş halini vermektedir. Bu durum hastalık teşhisine hız kazandırmaktadır. Derin öğrenmenin sınıflandırma ve özellik çıkartma üzerindeki üstün başarısı bu alanda da kendini göstermiştir. Bu çalışmada, patoloji görüntülerinin derin öğrenme mimarileri ile değerlendirilmesi sunulmuştur. Eğitilmiş ağ olan Inception-V3 ve VGG16 sınıflandırmada minimum hata verebilmeleri sebebi ile kullanılmıştır. Veri seti transfer öğrenim kullanılarak eğitilmiştir. Bu mimariler ile manuel olarak herhangi bir özellik çıkarımı yapılmaksızın kanser hücresi tespitinde %98.3 ± %1 oranında başarı tespit edilmiştir. Her bir derin öğrenme modelinin kendine göre farklı başarı sonucu verdiği gözlemlenmiştir. En yüksek başarı %99.03 ile VIHist mimarisinden alınmıştır. Ayrıca, Inception-V3 ile alınan başarının, VGG16’ya göre daha yüksek olduğu gözlemlenmiştir. Elde edilen sonuçlar, birleştirilmiş derin öğrenme modelinin (VIHist) sınıflandırma performansını iyileştirebildiğini göstermiştir. Bu etkinin ana sebebi, birleştirme modelindeki gömülü modüllerden kaynaklıdır (VGG16+Inception-V3).

Meme kanser teşhisinin başarısını histopatoloji uzmanının yeterliliğine dayandırmadan, teşhis geliştirmeye yönelik derin öğrenme tabanlı bir sistem önerilmiştir. Bu tür çalışmaların devam ettirilmesi, medikal alanda büyük önem taşımakta ve elzem görülmektedir. Gelecekte yapılacak çalışmada, önerilen sistemin birleşik model mantığı ile geliştirilerek, daha büyük veri seti üzerinde, 100X, 200X ve 400X büyütülmüş görüntü slaytları üzerinde test edilmesi planlanmaktadır.

KAYNAKLAR (REFERENCES)

- [1] M. M. Saritas, A. Yasar, “Performance Analysis of ANN and Naive Bayes Classification Algorithm for Data Classification”, *International Journal of Intelligent Systems and Applications in Engineering*, 7(2), 88-91, 2019.
- [2] D. Bardou, K. Zhang, S.M. Ahmad, “Classification of breast cancer based on histology images using convolutional neural networks”, *IEEE Access*, 6, 24680-24693, 2018.
- [3] M. Amrane, et al., “Breast cancer classification using machine learning”, *Electric Electronics, Computer Science, Biomedical Engineerings' Meeting (EBBT)*, Istanbul, Turkey, 17885967, 2018.
- [4] Z. Han, et al., “Breast cancer multi-classification from histopathological images with structured deep learning model”, *Scientific reports*, 7(1), 1-10, 2017.

- [5] Y. Benhammou, et al., “BreakHis based breast cancer automatic diagnosis using deep learning: Taxonomy, survey and insights”, *Neurocomputing*, 375, 9-24, 2020.
- [6] A.-A. Nahid, A. Mikaelian, Y. Kong, “Histopathological breast-image classification with restricted Boltzmann machine along with backpropagation”, *Biomedical Research*, 29(10), 2018.
- [7] S.A. Adeshina, et al., “Breast cancer histopathology image classification with deep convolutional neural networks”, **14th International Conference on Electronics Computer and Computation (ICECCO)**, Kaskelen, Kazakhstan, 18434739, 29 November-1 December, 2018.
- [8] N. Bayramoglu, J. Kannala, and J. Heikkilä. “Deep learning for magnification independent breast cancer histopathology image classification”, **23rd International conference on pattern recognition (ICPR)**, Cancun, Mexico, 16824576, 4-8 December, 2016.
- [9] F. F. Ting, Y.J. Tan, K.S. Sim, “Convolutional neural network improvement for breast cancer classification”, *Expert Systems with Applications*, 120, 103-115, 2019.
- [10] P. Sudharshan, et al., “Multiple instance learning for histopathological breast cancer image classification”, *Expert Systems with Applications*, 117, 103-111, 2019.
- [11] M. Z. Alom, et al., “Breast cancer classification from histopathological images with inception recurrent residual convolutional neural network”, *Journal of digital imaging*, 32(4), 605-617, 2019.
- [12] S. Khan, et al., “A novel deep learning based framework for the detection and classification of breast cancer using transfer learning”, *Pattern Recognition Letters*, 125, 1-6, 2019.
- [13] M. Saini, et al. “Data Augmentation of Minority Class with Transfer Learning for Classification of Imbalanced Breast Cancer Dataset Using Inception-V3”, **Iberian Conference on Pattern Recognition and Image Analysis**, 409-420, 2019.
- [14] J. Chang, et al. “A method for classifying medical images using transfer learning: A pilot study on histopathology of breast cancer”, **2017 IEEE 19th International Conference on e-Health Networking, Applications and Services (Healthcom)**, 1-4, 2017.
- [15] M. Gour, et al., “Residual learning based CNN for breast cancer histopathological image classification”, *International Journal of Imaging Systems and Technology*, 30(3), 621-635, 2020.
- [16] S. Sharma, et al., “Conventional Machine Learning and Deep Learning Approach for Multi-Classification of Breast Cancer Histopathology Images—a Comparative Insight”, *Journal of Digital Imaging*, 33, 632-654, 2020.
- [17] R. Man, et al., “Classification of Breast Cancer Histopathological Images Using Discriminative Patches Screened by Generative Adversarial Networks”, *IEEE Access*, 8, 2020.
- [18] C. Szegedy, et al. “Rethinking the inception architecture for computer vision”, **Proceedings of the IEEE conference on computer vision and pattern recognition**, 2818-2826, 2016.
- [19] K. Simonyan, and A. Zisserman, “Very deep convolutional networks for large-scale image recognition”, *arXiv preprint arXiv:1409.1556*, 2014.
- [20] Internet: Sitapatology, P.A.a. Excelência no Diagnóstico. Apoio ao cliente, <http://www.prevencaoediagnose.com.br/>, 12.03.2020.
- [21] F. Chollet, “Keras”, 2015.
- [22] A. Krizhevsky, I. Sutskever, and G.E. Hinton. “Imagenet classification with deep convolutional neural networks”, *Advances in neural information processing systems*, 2012.
- [23] C. Szegedy, et al., “Going deeper with convolutions”, **Proceedings of the IEEE conference on computer vision and pattern recognition**, 1-9, 2015.