



# Meme Kanserinin Evrişimsel Sinir Ağı Modelleriyle Tespitinde Farklı Görüntü Büyütme Oranlarının Etkisi

*The Effect of Different Image Magnification Rates in the Detection of Breast Cancer with Convolutional Neural Network Models*

Ali Narin<sup>1,\*</sup> , Safa Kaan Kefeli<sup>2</sup> 

<sup>1</sup>Zonguldak Bülent Ecevit Üniversitesi, Mühendislik Fakültesi, Elektrik-Elektronik Mühendisliği, Zonguldak, Türkiye

<sup>2</sup>Zonguldak Bülent Ecevit Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği, Zonguldak, Türkiye

## Öz

Meme kanseri, tüm dünyada oldukça yaygın olan bir kanser türüdür. Çoğunlukla kadınlarda görülen bu kanser türünün erken tespiti oldukça önemlidir. Bu nedenle zorlu ve yorucu olan meme kanseri tespit sürecinde bilgisayar destekli karar mekanizmalarının geliştirilmesi önem arz etmektedir. Bu çalışmada, meme kanseri tespitinde kesin tanının konulmasına yardımcı olmak için bilgisayar tabanlı otomatik bir karar destek sistemi tasarlanmıştır. Sistem için, farklı büyütme miktarlarına sahip gerçek ham histopatolojik görüntüler kullanılmıştır. Bu görüntülerden hangisinin iyi huylu tümör hangisinin kötü huylu tümör olduğuna ön eğitilmiş ResNet50 evrişimsel sinir ağı (Convolutional Neural Network (CNN)) ve ön eğitimsiz VGG16 CNN kullanılarak karar verilmiştir. Bununla beraber veri setindeki 4 farklı büyütme oranlarından (40X, 100X, 200X, 400X) hangi büyütme miktarında daha iyi tespit yapıldığı araştırılmıştır. Sonuç olarak 200X büyütme miktarına sahip veriler için %93,03 doğruluk, %93,03 hassaslık ve %93,03 seçicilik performans değerleri ön eğitilmiş ResNet50 CNN ile tespit edilmiştir. Benzer şekilde ön eğitimsiz VGG16 modelinde ise %93,03 doğruluk, %99,28 hassaslık ve %79,03 seçicilik değerlerine ulaşılmıştır. Elde edilen bu sonuçlara göre, önerilen bu sistemin patoloğlara yardımcı bir bilgisayar tabanlı tümör tespit uygulaması olacağı düşünülmektedir.

**Anahtar Kelimeler:** Derin öğrenme, Meme kanseri, Ön eğitilmiş ResNet50, VGG16

## Abstract

Breast cancer is a very common form of cancer all over the world. Early diagnosis and detection of this type of cancer, which is mostly seen in women, is very important. Therefore, it is significant to develop computer-aided decision mechanisms in the difficult and laborious breast cancer detection process. In this study, an automated computer based decision support system has been designed to help for the diagnosis of breast cancer. For the system, real raw histopathological images with different magnifications have been used. Whichever of these images are benign or malignant tumors has been decided using the pre-trained ResNet50 Convolutional Neural Network (CNN) and VGG16 CNN. However, it has been investigated which magnification amount has been determined better from 4 different magnification rates (40X, 100X, 200X, 400X) in the data set. As a result, 93.03% accuracy, 93.03% sensitivity and 93.03% specificity performance values for 200X magnification data have been determined with the pre-trained Resnet50 CNN. Similarly, 93.03% accuracy, 99.28% sensitivity and 79.03% specificity values have been achieved in the VGG16 model without pre-trained. According to these obtained results, it is thought that this proposed system will be a computer-based tumor detection application to assist pathologists.


**Keywords:** Deep learning, Breast cancer, Pre-trained ResNet50, VGG16

## 1. Giriş

Meme kanseri, kadın ve erkeklerde göğüs hücrelerinde oluşan bir kanser türüdür (Siegel vd. 2017). Çoğunlukla

kadınlarda görülür. Memede oluşan sertlik ve yumru, meme kanserinin ilk belirtilerindedir (Haliloğlu vd. 2019). Bu yapıların, kanser olup olmadığı görüntüleme yöntemlerinden mamografi ve ultrasonografi testleri ile gerçekleştirilir. Yapılan bu testler kesin tanı koymak için yeterli değildir. Kesin tanı koyabilmek için kanserli olduğu düşünülen yapının biyopsisi ile histopatolojik incelemesi

\*Sorumlu yazarın e-posta adresi: [alinarin45@gmail.com](mailto:alinarin45@gmail.com)

Ali Narin  [orcid.org/0000-0003-0356-2888](https://orcid.org/0000-0003-0356-2888)

Safa Kaan Kefeli  [orcid.org/0000-0002-1351-2860](https://orcid.org/0000-0002-1351-2860)

yapılır (Lipponen vd. 1994). Patoloji uzmanları tarafından incelenen dokunun iyi huylu (benign) mu veya kötü huylu (malign) mu olduğu mikroskop altında çeşitli büyütme eşliğinde test edilir (Wan vd. 2017, Rahlal 2018). Bu işlemler sonucunda köyü huylu tümöre sahip olduğu tespit edilen kişinin, hemen tedavi altına alınması gerekmektedir. Aksi halde vücudun diğer taraflarına yayılması ile birlikte önlenemez bir hal almasına neden olabilir. Tedavi için iki yöntem söz konusudur. Bunlardan biri tümörün yayılmasını engelleyen kimyasal tedavidir. Diğeri kanserli olan yerin cerrahi yöntemlerle alınmasıdır ki bu yöntem daha kesin bir yöntemdir.

Tüm dünyada alınan çok çeşitli önlemler ve farkındalıklar sayesinde ölüm oranlarının düşmesine rağmen, hala meme kanserine yakalananların sayısı çok fazladır. Tahminen 2019 yılında sadece ABD'de yaklaşık 268,600 kadının meme kanserine yakalandığı ve 41,760 kişinin bu kanserden öldüğü rapor edilmiştir (DeSantis vd. 2019).

Meme kanserinin tespiti genellikle manuel yöntemlerle yapılmaktadır. Bu iş zaman alıcı olduğu kadar yorucu bir iştir. En ufak bir dikkatsizlikte hastalığın yanlış teşhis edilmesine neden olabilir. Bu sebeple araştırmacılar, bilgisayar destekli otomatik teşhis sistemleri geliştirmişlerdir. Özellikle son yıllarda derin öğrenme tabanlı modellerin Elektrokardiyogram (EKG), Elektroensefalogram (EEG) gibi biyolojik işaretlere ve Manyetik Rezonans Görüntüleme (MR), röntgen gibi görüntülere uygulandığı çalışmalar literatürde yerini almaktadır (Hammad vd. 2020, Talo vd. 2019, Michielli vd. 2019, Narin vd. 2020). Aynı şekilde meme kanseri tespiti için öznelik çıkarımı ile yapılan geleneksel olarak bilinen çalışmaların yanında, derin öğrenme tabanlı yöntemlerle de yapılmış çalışmalar vardır (Spanhol vd. 2016, Bayramoğlu vd. 2016, Spanhol vd. 2017, Gour vd. 2020). Veri sayısının az olduğu ilk zamanlarda geleneksel yöntemlerle çalışmalar gerçekleştirilmiştir. Geleneksel yöntemler içerisinde sınıflandırıcı olarak çoğunlukla k-en yakın komşu, Naive Bayes, karar ağaçları, geri yayımlı çok katlı algılayıcı ağlar, olasılıksal sinir ağları ve destek vektör makina algoritmalarının kullanıldığını görülmektedir (George vd. 2014, Hang ve Lai 2010, Rashmi vd. 2020).

Meme kanseri türü üzerine derin öğrenme modelleri ilk olarak 2016 yılında BreakHis adı verilen 82 kanser hastasından alınan toplam 7909 adet iyi huylu ve kötü huylu tümör verileriyle başlanmıştır. Bu alanda ilk çalışmayı bu verileri erişime açan Spanhol ve arkadaşları gerçekleştirmiştir (Spanhol vd. 2016). Çalışmalarında, derin CNN'in en temel modellerinden biri olan AlexNet modelini kullanmışlardır.

Çalışma içerisinde olan farklı büyütme oranları için sırasıyla, 40X'lik büyütme oranında %85,6, 100X'lik büyütme oranında %83,5, 200X'lik büyütme oranında %82,7 ve son olarak 400X'lik büyütme oranında %80,7 doğruluk değerlerine ulaşmışlardır. AlexNet ile elde edilen sonuçların geleneksel yöntemlerden daha iyi performans sergilediğini ifade etmişlerdir. Bayramoğlu ve arkadaşları ise CNN ve çok amaçlı CNN olmak üzere iki farklı mimari ile çalışmalarını gerçekleştirmiştir. Yazarlar farklı büyütme miktarlarına göre de sonuçları detaylı bir şekilde sundular. Histopatolojik görüntülerin iyi huylu mu yoksa kötü huylu mu olduklarını sayısal sonuçlar vererek destekleyen bu araştırmacılar 200X büyütme oranında en yüksek  $84,63 \pm 2,72$  başarımla elde ettiler. Tüm büyütme oranlarında ortalama %83,25 doğruluk değerine ulaştılar. Verilerin doğrudan kullanılması ve sonuçların geleneksel yöntemlerle elde edilen sonuçlarla karşılaştırılabileceklerini ifade ettiler (Bayramoğlu vd. 2016). Bir diğer çalışmalarında Spanhol ve arkadaşları, deCAF dedikleri derin öğrenme modelinden öznelikler çıkarıp, önceden eğitilmiş CaffeNet modelini kullanmışlardır. Sonuçta 200X büyütme oranında en yüksek 90,3% F-skor (F1) başarımla elde ettiler (Spanhol vd. 2017). Gour ve arkadaşları meme kanseri histopatolojik görüntülerinin iyi huylu veya kötü huylu olup olmadıklarını adına ResHist dedikleri 152 katmanlı CNN ile gerçekleştirmişlerdir. ResHist modelinin, histopatolojik görüntülerin ayırımında oldukça başarılı ve ayırt edici olduğunu göstermişlerdir. Sonuç olarak veri artırımı yapılmadan %84,34 doğruluk değeri elde etmişken, veri artırımı yöntemi ile %92,52 doğruluk değerini elde etmişlerdir (Gour vd. 2020).

Gerçekleştirilen bu çalışmada, meme kanserinin erken tespit edilmesinin öneminden yola çıkarak, farklı büyütme oranlarına sahip görüntülerin yer aldığı (Meme Kanseri Histopatolojik Görüntü Sınıflandırması (BreakHis)) verileri kullanılarak tümörün iyi huylu veya kötü huylu olup olmadığını belirlemek için bir çalışma gerçekleştirilmiştir. Farklı büyütme oranlarından hangisinin tespit başarımının daha yüksek olduğu iki farklı derin öğrenme modeli ile kıyaslanmıştır. Derin öğrenme modellerinden özellikle önceden eğitilmiş model olan ResNet50 ve ön eğitimli olmayan VGG16 modeli kullanılmıştır. Bu çalışmada ayrıca, histopatolojik verilerden hangi büyütme oranının, sınıflar arası ayrımı daha iyi ifade ettiğini araştırmanın yanında, iki modelin kıyaslanması da amaçlanmıştır. Çalışmanın öne çıkan yönleri özetlenirse:

- i) Hem ön-eğitilmiş hem de ön eğitimsiz iki model kullanılmıştır.

- ii) Doğrudan ham veri üzerinden uçtan uca denilen bir sistem ile çalışma yapılmıştır.
- iii) Herhangi bir öznitelik çıkarımı işlemi bulunmamaktadır.
- iv) Çalışılan modellerin 40X, 100X, 200X ve 400X büyütme oranlarındaki sınıflandırma doğrulukları araştırılmıştır.

Makalenin devamında, kullanılan veri seti ve özelliklerinden, çalışmada kullanılan ön eğitilmiş Resnet50 ve ön eğitimsiz VGG16 modellerinin mimarilerinden, elde edilen deneysel sonuçlardan bahsedilecektir. Son olarak elde edilen bulguların tartışmasına yer verilecektir.

## 2. Gereç ve Yöntem

### 2.1. Veri seti

Çalışmada, “Meme Kanseri Histopatolojik Görüntü Sınıflandırması (BreakHis)” veri seti (<https://web.inf.ufpr.br/vri/databases/breast-cancer-histopathological-database-breakhis/>) kullanılmıştır (Spanhol vd. 2016, Spanhol vd. 2016b). Veri seti içinde iyi huylu ve kötü huylu olmak üzere toplam 7909 adet histopatolojik tümör görüntüsü bulunmaktadır (Çizelge 1). Görüntüler farklı büyütme oranlarına sahip olmakla birlikte (40X, 100X, 200X ve 400X), 700x460 piksel boyutundadır.


Çizelge 1. Veri setini oluşturan sınıflar ve sayıları.

Büyütme Miktarı	İyi huylu	Kötü huylu	Toplam
40X	625	1370	1995
100X	644	1437	2081
200X	623	1390	2013
400X	588	1232	1820
<b>Toplam</b>	2480	5429	7909


Şekil 1’de, iyi huylu tümöre ait farklı büyütme miktarına sahip görüntüler gösterilmişken, Şekil 2’de kötü huylu tümöre ait farklı büyütme miktarına sahip görüntüler gösterilmiştir.

### 2.2. Ön Eğitilmiş ResNet50 CNN Modeli

ResNet50 CNN modelinin ismi, artık değerli nöral ağların (residual neural network) kısaltmasından oluşmaktadır. İçerisinde çok miktarda evrimsel sinir ağı bulunan geliştirilmiş bir CNN versiyonudur (He vd. 2016). Katmanlar arasında geçişlerin olması ResNet modellerinde ağı derinleştirmektedir. Bu geçişler sayesinde derinleşen ağda meydana gelebilecek bozulmalar önlenmektedir. Bu



Şekil 1. İyi huylu tümöre ait görüntüler.



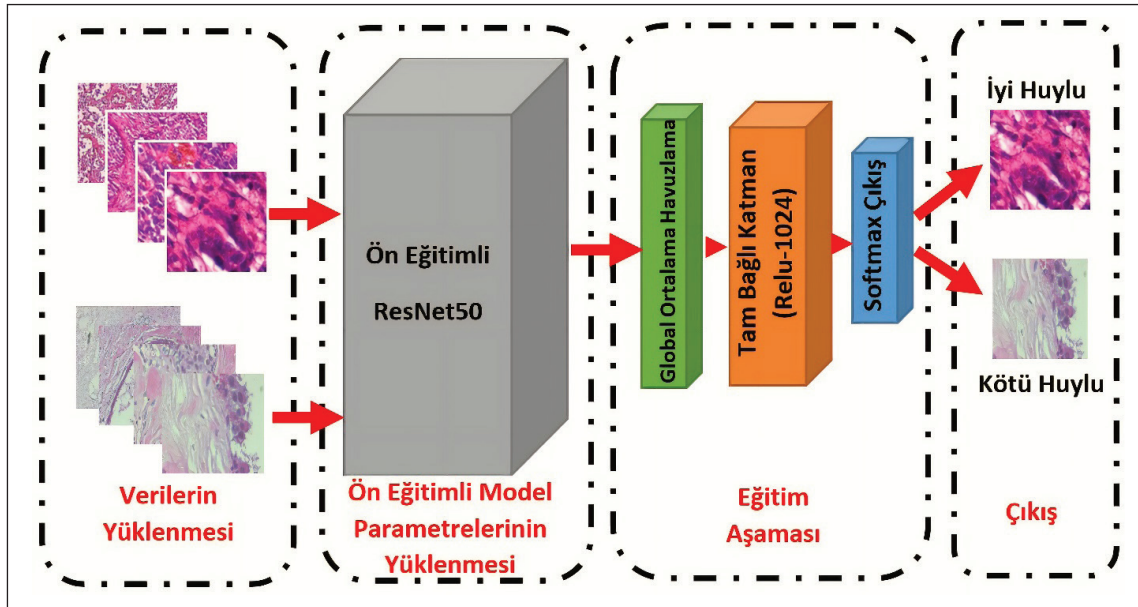
Şekil 2. Kötü huylu tümöre ait görüntüler.




modellerde eğitimin hızlı gerçekleşmesi için darboğaz (bottleneck) denilen bloklar kullanılır. ResNet50 modelinde yaklaşık 23 milyon parametre hesabı yapılmaktadır. Ön eğitilmiş ResNet50 modeli, ImageNet veri kümesi üzerinde eğitilmiş 50 katmanlı bir ağıdır. ImageNet, görüntü tanıma yarışmaları için oluşturulmuş 20 binden fazla kategoriye ait 14 milyondan fazla resmin bulunduğu bir görüntü veri tabanıdır (Russakovsky vd. 2015). Bu çalışmada kullanılan ön eğitilmiş ResNet50 modeli Şekil 3'de gösterilmiştir. İki kısımdan oluşan bu modelde, birinci kısımda ImageNet veri tabanı üzerinden eğitilmiş ResNet50 modeli ve ikinci kısımda yani eğitim aşaması kısmında meme kanseri türü için önerdiğimiz ağı model bulunmaktadır.

### 2.3. Ön Eğitilmiş VGG16 CNN Modeli

VGG16 CNN modelinde 2'li ya da 3'lü evrişim katmanları kullanılmaktadır (Simonyan ve Zisserman 2014). İki tam bağlantı katmanı çıkışında 1000 sınıflı Softmax başarımlı hesaplanır. Diğer bir ifade ile modelin son katmanında Softmax diye bilinen aktivasyon fonksiyonundan geçirilmesiyle çıkışlar elde edilir. Yaklaşık 138 milyon parametre hesabı yapılmaktadır. Şekil 4'de VGG16 mimarisi verilmiştir. Diğer modellerde olduğu gibi girişten çıkışa doğru matrislerin yükseklik ve genişlik boyutları azalırken derinlik değeri (kanal sayısı) artmaktadır.



Şekil 3. Ön Eğitilmiş ResNet50 modelinin gösterimi.



Şekil 4. VGG16 CNN mimarisi.

## 2.4. Performans Ölçütleri

Derin öğrenme modellerinin performansları için 3 ölçüt kullanılmıştır (Duda vd. 2001). Bunlar:

$$\text{Hassaslık (SEN)} = \frac{TP}{TP + FN} \quad (1)$$

$$\text{Seçicilik (SPE)} = \frac{TN}{TN + FP} \quad (2)$$

$$\text{Doğruluk (ACC)} = \frac{TP + TN}{TP + FN + FP + TN} \quad (3)$$

Burada, Gerçek pozitif (TP), gerçek negatif (TN), yanlış negatif (FN) ve yanlış pozitif (FP). Bu değerler bizim problemimiz için ele alınırsa, kötü huylu (pozitif) bir tümörün kötü huylu olarak tespiti (TP), iyi huylu (negatif) bir tümörün iyi huylu olarak tespiti (TN) ile gösterilir. İyi huylu bir tümörün kötü huylu olarak tespiti (FP) ve Kötü huylu bir tümörün iyi huylu olarak tespiti ise (FN) olarak ifade edilir (İşler ve Narin 2012, Narin vd. 2014).

## 3. Bulgular

Bu çalışmada, modellerin oluşturulması ve sonuçların elde edilmesi için Python programlama dili kullanılmıştır. Google Colab üzerinden herkesin ücretsiz (12 saat) bir şekilde kullanabileceği Tesla K80 grafik işlemcisi üzerinde Tensorflow-Keras kütüphanesi kullanılarak çalışmanın tamamı gerçekleştirilmiştir. Çalışmada, meme kanseri histopatolojik görüntülerinden oluşan BreakHis veri seti kullanılmıştır. Veri seti içerisinde 4 farklı büyütme miktarlarına sahip veriler bulunmaktadır. Derin öğrenme modellerinde eğitim sürecinin sağlıklı gerçekleşmesi için veri sayısının fazla olması istenir. Bu nedenle, her bir büyütme miktarı verilerinin %90'ı modellerin eğitimi için ayrılırken %10'u ise eğitilen modellerin testi için ayrılmıştır. Ayrılan bu veriler ile ön eğitilmiş ResNet50 modeli ve ön eğitilmiş VGG16 modeli ile eğitim ve test aşamaları gerçekleştirilmiştir. Burada en önemli konulardan biri bu aşamaların uçtan uca denilen bir süreçle gerçekleşmesidir. Yani, herhangi bir harici öznitelik çıkarımı yada segmentasyon işlemi olmadan modele giren veri, model içerisindeki katmanlarda eğitilir ve sınıflandırma işlemi ile birlikte modelin son katmanında çıktı olarak sunulur.

Her iki modelin eğitimi sırasında aşırı öğrenme probleminden kaçınmak için eğitim aşaması 30 devir (epochs) için gerçekleştirildi. Tüm histopatolojik görüntüler, veri setinde sunulan 700x460 piksel boyutundan 224x224 piksel boyutuna dönüştürülmüştür. Modellerin öğrenme oranı

(learning rate) ise 0,0001 olarak alınmıştır. Modellerin eğitiminde ağırlıkların optimize edilmesi ADAM algoritması ile yapılmıştır.

Ön eğitilmiş ResNet50 ile VGG16 modeline ait 40X, 100X, 200X ve 400X büyütme oranına sahip veriler için 30 devirlik eğitim sürecindeki doğruluk grafikleri Şekil 5'de verilmiştir. Ön eğitilmiş ResNet50 modelinin başlangıç doğruluk değerleri ve genel eğitim başarımları değerleri ön eğitilmiş VGG16 modeline göre daha yüksektir. Ön eğitilmiş ResNet50 modeli ortalama 10 devir sonra %100 eğitim başarımlarına sahip olurken, ön eğitilmiş VGG16 modeli ise 5. devirden sonra çok daha yavaş öğrendiği görülmektedir. Burada, ön eğitilmiş modelin çok hızlı öğrendiğini ve ön eğitilmiş modelin ise çok daha yavaş öğrendiğini ifade edebiliriz. Benzer şekilde, eğitim süresindeki kayıp değerleri Şekil 6'da verilmiştir. Şekilden de görüleceği gibi ön eğitilmiş ResNet50 modelinin ön eğitilmiş VGG16 modeline göre çok daha iyi eğitim performansı gösterdiği görülmektedir. Her iki şekilden de 200X büyütme oranına sahip verilerin diğer büyütme oranına sahip verilerden daha yüksek olduğu söylenebilir.

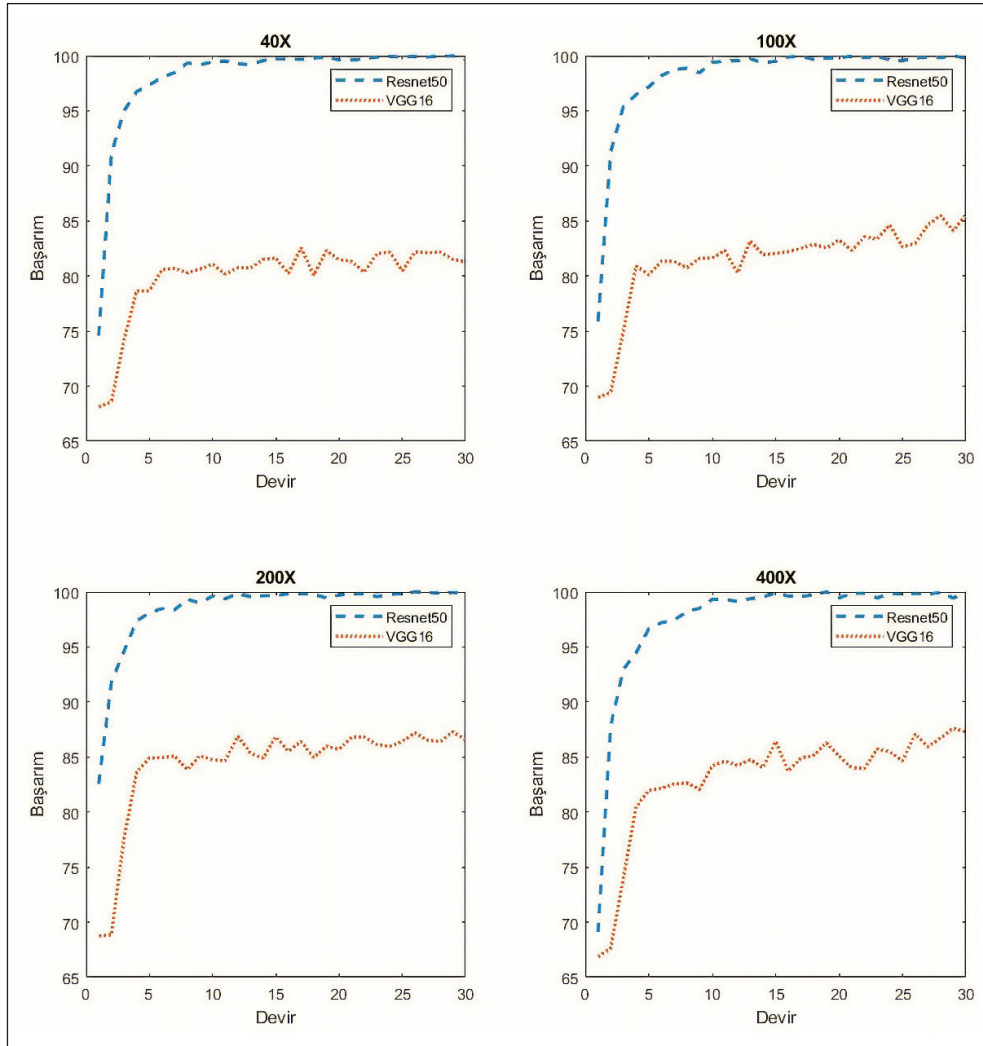
Hem büyütme hem iki farklı derin öğrenme modeli ile elde edilen sonuçlar Çizelge 2'de detaylı bir şekilde verilmiştir. Çizelge 2 incelendiğinde, kötü huylu tümörlerin %99 oranında doğru tespit edildiği gözlemlenirken, İyi huylu tümörlerinde ise %93 oranından doğru tespit edildiği görülmektedir. 200X büyütme oranına sahip görüntülerin performanslarının diğer büyütme oranına sahip görüntülerden daha iyi olduğu söylenebilir. VGG16 modelinin de aslında eğitim sürecindeki düşük başarımları test verilerinde göstermediğini görülmektedir. Bunun nedeni ön eğitilmiş modellerin eğitim süreçlerinin daha geç olmasına karşı daha sağlam olmasıdır. Fakat verilerin çok daha sınırlı olan uygulamalarında iyi sonuçlar vermediği bilinmektedir. Bu problemlerin çözümü için ön eğitilmiş modeller kullanılmaktadır. Çalışmada bu yön düşünülerek ön eğitilmiş model kullanılması uygun görüldü. Ön eğitilmiş VGG16 modeli eğitim sürecinde her ne kadar düşük olsa da test edilen verilerde aslında modelin iyi bir şekilde öğrendiği söylenebilir.


## 4. Tartışma

Meme kanseri türü tespiti konusunda son yıllarda yapılan çalışmalara bakıldığında, genel olarak çalışmaların derin öğrenme modelleri üzerine odaklandığı görülmektedir (Çizelge 3). Bu çalışmalardan Deniz ve arkadaşları, transfer öğrenme denilen ön eğitilmiş AlexNet ve VGG16 CNN'yi

**Çizelge 2.** Büyütme miktarlarına göre modellerin test performansları.

Model	Büyütme Miktarı	TP	TN	FP	FN	Doğruluk ACC(%)	Hassaslık SEN(%)	Seçicilik SPE(%)
<b>Ön Eğitimli Resnet50</b>	40X	136	31	31	1	83,92	99,27	50,00
	100X	134	40	24	9	84,06	93,71	62,50
	200X	129	58	4	10	<b>93,03</b>	92,81	93,55
	400X	106	42	16	17	81,77	86,18	72,41
<b>Ön Eğitimsiz VGG16</b>	40X	131	41	21	6	86,43	95,62	66,13
	100X	141	51	13	2	92,75	98,60	79,69
	200X	138	49	13	1	<b>93,03</b>	<b>99,28</b>	79,03
	400X	115	41	17	8	86,19	93,50	70,69

**Şekil 5.** 40X, 100X, 200X ve 400X büyütme miktarlarına göre modellerin eğitim başarımları.



**Şekil 6.** 40X, 100X, 200X ve 400X büyütme miktarlarına göre modellerin eğitim kayıp değerleri.

kullanarak elde ettikleri öznelikleri destek vektör makinelere sınıflandırıcısı yardımıyla sınıflandırıp sonuçta 200X büyütme oranında en yüksek %91,37 doğruluk değerini elde etmişlerdir (Deniz vd. 2018). Spanhol ve arkadaşları AlexNet için en yüksek 40X'lik büyütme oranında %85,6 doğruluk değerlerine ulaşmışlardır ve bir diğer çalışmalarında Spanhol ve arkadaşları, deCAF dedikleri derin öğrenme modelinden öznelikleri çıkarıp, önceden eğitilmiş CaffeNet modelini kullanmışlardır. Sonuçta 200X büyütme oranında en yüksek 90,3% başarımlarını elde etmişlerdir (Spanhol vd. 2016, Spanhol vd. 2017). Bayramoğlu ve arkadaşları iki farklı evrimsel model ile en yüksek 200X büyütme oranında %84,63±2,72 başarımlarını elde ettiler (Bayramoğlu vd. 2016). Gour ve arkadaşları ResHist adını verdikleri 152 katmanlı CNN ile veri artırımı yapılmadan %84,34 doğruluk değeri elde etmişken, veri artırımı yöntemi ile %92,52 doğruluk değerini elde etmişlerdir (Gour vd. 2020). Gerçekleştirilmiş olan bu çalışmada ise 200X büyütme miktarında %93,03

doğruluk değeri elde edilerek, güncel literatürdeki çalışmalardan daha yüksek sınıflandırma başarımlarını elde edilmiştir. Bunun yanı sıra ön eğitilmiş model olan ResNet50 ve ön eğitimsiz VGG16 modelinin karşılaştırılması yapılmış olup ön eğitilmiş ve eğitimsiz modellerin eğitim süreçlerini ve sonuçları detaylı bir şekilde karşılaştırılmıştır. Literatürde ise bu türden bir karşılaştırma yapılmamış olmakla birlikte ya ön eğitimsiz modeller ya da ön eğitilmiş modeller kullanılmış ve karşılaştırılmıştır. Genel olarak literatürde yapılan çalışmalarda 200X büyütme miktarına sahip görüntülerin iyi ya da kötü huylu meme kanserini ayırt etmede daha yüksek başarımlara ulaştığı görülmektedir. Benzer şekilde bu çalışmada da 200X büyütme miktarındaki görüntülerin diğer büyütme oranlarına göre daha yüksek başarımlara sahip olduğu gösterilmiştir. Bunlara ek olarak, çalışmada kullanılan veri setinin genişletilmesiyle, elde edilen başarımların daha da artacağı öngörülmektedir.



**Çizelge 3.** Elde edilen sonuçların aynı veri seti ile yapılmış literatürdeki diğer çalışmalarla karşılaştırılması.

Çalışma	Büyütme Miktarı	Kullanılan Yöntem	Doğruluk (ACC) (%)
(Deniz vd. 2018).	200X	AlexNet ve VGG16 CNN Modelleri	91,37
(Spanhol vd. 2016)	40X	AlexNet CNN Modeli	85,60
(Spanhol vd. 2017)	200X	deCAF + CaffeNet CNN Modeli	90,30
(Bayramoğlu vd. 2016).	200X	Tek Görevli ve Çok Görevli CNN Modelleri	84,63
(Gour vd. 2020)	100X	ResHist CNN Modeli	84,34
	200X	ResHist CNN + Veri Artırımı	92,52
<b>Bu çalışma</b>	<b>200X</b>	<b>Ön eğitilmiş ResNet50 CNN</b>	<b>93,03</b>
<b>Bu çalışma</b>	<b>200X</b>	<b>Ön eğitimsiz VGG16 CNN</b>	<b>93,03</b>

Önerilen bu yöntemin en önemli kolaylıklarında biri de verilerin ham olarak yani doğrudan kullanılabilir olmasıdır. Sonucun ise bir bütünü çıktısı olarak alınabilmesidir. Bu yönüyle patolojilere kullanım kolaylığı sağlayacağını da düşünmekteyiz. Gelecekteki çalışmalarda ise farklı CNN modelleri ve parametreleri ile çalışma daha detaylı bir şekilde ele alınabilir.

## 5. Kaynaklar

- Al Rahhal, MM. 2018.** Breast cancer classification in histopathological images using convolutional neural network. *Int. J. Adv. Comput. Sci. Appl.* 9(3): 1-5. Doi: 10.14569/IJACSA.2018.090310
- Bayramoğlu, N., Kannala, J., Heikkilä, J. 2016.** Deep learning for magnification independent breast cancer histopathology image classification. *23rd International conference on pattern recognition (ICPR)*, pp: 2440-2445. Doi: 10.1109/ICPR.2016.7900002
- Deniz, E., Şengür, A., Kadiroğlu, Z., Guo, Y., Bajaj, V., Budak, Ü. 2018.** Transfer learning based histopathologic image classification for breast cancer detection. *Health Inf. Sci. Syst.* 6(18): 1-7. Doi: 10.1007/s13755-018-0057-x
- DeSantis, CE., Ma, J., Gaudet, MM., Newman, LA., Miller, KD., Goding Sauer, A., Siegel, RL. 2019.** Breast cancer statistics, 2019. *Cancer J. Clin.* 69(6): 438-451. Doi: 10.3322/caac.21583
- Duda, RO., Hart, PE., Stork, DG. 2001.** Pattern classification, John Wiley and Sons, 2nd ed, New York, USA, 255 pp.
- George, M., Zayed, H., Roushdy, I., Elbagoury, M. 2014.** Remote computer-aided breast cancer detection and diagnosis system based on cytological images. *IEEE Syst. J.* 8(3): 949-964. Doi: 10.1109/JSYST.2013.2279415
- Gour, M., Jain, S., Kumar, TS. 2020.** Residual learning based CNN for breast cancer histopathological image classification. *Int. J. Imag. Syst. Tech.* 2020: 1-15. Doi: 10.1002/ima.22403
- Haliloglu, N., Ustuner, E., Ozkavukcu, E. 2019.** Breast ultrasound during lactation: benign and malignant lesions. *Breast Care.* 14(1): 30-34. Doi: 10.1159/000491781
- Hammad, M., Pławiak, P., Wang, K., Acharya, UR. 2020.** ResNet-Attention model for human authentication using ECG signals. *Expert Syst.* 2020: 125-147. Doi: 10.1111/exsy.12547
- He, K., Zhang, X., Ren, S., Sun, J. 2016.** Deep residual learning for image recognition. *IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, pp: 1-4. Doi: 10.1109/cvpr.2016.90
- Huang, PW., Lai YH. 2010.** Effective segmentation and classification for HCC biopsy images. *Pattern Recognit.* 43(4): 1550-1563. Doi: 10.1016/j.patcog.2009.10.014
- İşler, Y., Narin, A., Özer, M., Perc, M. 2019.** Multi-stage classification of congestive heart failure based on short-term heart rate variability. *Chaos Soliton Fract.* 118: 145-151. Doi: 10.1016/j.chaos.2018.11.020
- Lipponen, P., Aaltomaa, S., Kosma, VM., Syrjänen, K. 1994.** Apoptosis in breast cancer as related to histopathological characteristics and prognosis. *Eur. J. Cancer* 30(14): 2068-2073. Doi: 10.1016/0959-8049(94)00342-3
- Michielli, N., Acharya, UR., Molinari, F. 2019.** Cascaded LSTM recurrent neural network for automated sleep stage classification using single-channel EEG signals. *Comput. Biol. Med.* 106: 71-81. Doi: 10.1016/j.combiomed.2019.01.013
- Narin, A., İşler, Y., Özer, M. 2014.** Konjestif kalp yetmezliği teşhisinde kullanılan çapraz doğrulama yöntemlerinin sınıflandırıcı performanslarının belirlenmesine olan etkilerinin karşılaştırılması. *Dokuz Eylül Üniversitesi Mühendislik Fakültesi Fen ve Mühendislik Dergisi* 16(48): 1-8.



- Narin, A., Kaya, C., Pamuk, Z. 2020.** Automatic detection of coronavirus disease (COVID-19) using X-ray images and deep convolutional neural networks. *arXiv preprint arXiv:2003.10849*.
- Rashmi, R., Prasad, K., Udupa, CBK., Shwetha, V. 2020.** A comparative evaluation of texture features for semantic segmentation of breast histopathological images. *IEEE Access* 8: 64331-64346. DOI: 10.1109/ACCESS.2020.2984522
- Russakovsky, O., Deng, J., Su, H., Krause, J., Satheesh, S., Ma, S., Huang, Z., Karpathy, A., Khosla, A., Bernstein, M., Berg, A.C., Fei-Fei, L. 2015.** Imagenet large scale visual recognition challenge. *Int. J. Comput. Vis.* 115(3): 211-252. Doi: 10.1007/s11263-015-0816-y
- Siegel, RL., Miller, KD., Jemal, A. 2017.** Cancer statistics, 2017. *Cancer J. Clin.* 67(1): 7-30. Doi: 10.3322/caac.21395.
- Simonyan, K., Zisserman, A. 2014.** Very deep convolutional networks for large-scale image recognition. *arXiv: Comp. Res. Repository*, abs/1409.1556.
- Spanhol, FA., Oliveira, LS., Petitjean, C., Heutte, L. 2016.** Breast cancer histopathological image classification using convolutional neural networks. *International Joint Conference on Neural Networks (IJCNN)*, pp: 2560-2567, Vancouver, Canada. Doi: 10.1109/IJCNN.2016.7727519
- Spanhol, FA., Oliveira, LS., Petitjean, C., Heutte, L. 2016b.** A dataset for breast cancer histopathological image classification. *IEEE Trans. Biomed. Eng.* 63(7): 1455-146. Doi: 10.1109/TBME.2015.2496264
- Spanhol, FA., Oliveira, LS., Cavalin, PR., Petitjean, C., Heutte, L. 2017.** Deep features for breast cancer histopathological image classification. *IEEE International Conference on Systems, Man, and Cybernetics (SMC)*, pp: 1868-1873, Banff, Canada. Doi: 10.1109/SMC.2017.8122889
- Talo, M., Yildirim, O., Baloglu, UB., Aydin, G., Acharya, UR. 2019.** Convolutional neural networks for multi-class brain disease detection using MRI images. *Comput. Med. Imaging Graph.* 78: 101673-101685. Doi: 10.1016/j.compmedimag.2019.101673
- Wan, T., Cao, J., Chen, J., Qin, Z. 2017.** Automated grading of breast cancer histopathology using cascaded ensemble with combination of multi-level image features. *Neurocomputing* 229: 34-44. Doi: 10.1016/j.neucom.2016.05.084