

## Derin Öğrenme Yardımıyla Aktif Termogramlar Üzerinden Meme Lezyonlarının Sınıflandırması

Soner Çivilibal<sup>1</sup>, Kerim Kürşat Çevik<sup>2,\*</sup>, Ahmet Bozkurt<sup>3</sup>

<sup>1</sup>Akdeniz Üniversitesi, Fen Bilimleri Enstitüsü, Biyomedikal Mühendisliği Anabilim Dalı, 07070, Antalya, Türkiye

<https://orcid.org/0000-0003-2943-3101>

<sup>2</sup>Akdeniz Üniversitesi, Yönetim Bilişim Sistemleri Bölümü, Uygulamalı Bilimler Fakültesi, 07070, Antalya, Türkiye

<https://orcid.org/0000-0002-2921-506X>

\*yazışılan yazar: [kcevik@akdeniz.edu.tr](mailto:kcevik@akdeniz.edu.tr)

<sup>3</sup>Akdeniz Üniversitesi, Biyomedikal Mühendisliği Bölümü, Mühendislik Fakültesi, 07070, Antalya, Türkiye

<https://orcid.org/0000-0002-3163-0131>

(Alınış / Received: 06.07.2022, Kabul / Accepted: 10.05.2023, Yayınlanma / Published: 22.06.2023)

**Öz:** Son yıllarda bilgisayar donanımları ile paralel olarak gelişim gösteren yapay zeka çalışmaları klinikte uzmanların erken teşhis ile olası metastazın önüne geçerek hasta sağ kalımını artırmaktadır. Literatürde klinikte kanser teşhisini gerçekleştiren çokça çalışma mevcuttur. Bu çalışmalarda, kanser sınıflandırmasının yapılması için makine öğrenmesi ve derin öğrenme uygulamaları sıklıkla uygulanmaktadır. Benzer şekilde çalışmada termal meme görüntüleri üzerinden derin öğrenme yöntemleri ile meme kanseri teşhisi ele alınmıştır. Çalışmada kullanılan görüntüler açık erişim olarak sunulan DMR-IR veri setinden alınmıştır. Veri setinden alınan görüntüler üzerinde bazı ön işlemler yapılmış, ardından meme bölgelerinin bölütlenmesi için manuel ve otomatik olmak üzere iki farklı bölütleme metodu uygulanmıştır. Manuel bölütleme işleminde, VIA ile lokalizasyon bilgisi kaydedilen meme bölgelerinin maskesi oluşturup orijinal görüntüden çıkarılarak bölütleme gerçekleştirilmiştir. Otomatik bölütleme işleminde ise Mask R-CNN ve U-NET ile bölütleme yapılmıştır. Bu iki metod için bölütleme performans analizi yapılmış ve 0.9896 doğruluk, 0.9413 Dice ve 0.8900 Jaccard değerini gerçekleştiren Mask R-CNN ile sınıflandırma işlemleri çalışılmıştır. Manuel ve Mask-RCNN metodu ile bölütlenen görüntülerden oluşan termogramlar ile ön eğitilmiş yedi farklı (InceptionV3, MobileNet, MobileNetV2, ResNet50, VGG16, VGG19 ve Xception) mimari kullanılarak meme kanseri sınıflandırması gerçekleştirilmiştir. Sonuç olarak test verilerinde %100 sınıflandırma başarısını doğruluk, kesinlik, duyarlılık ve F1 Skoru ile MobileNet ve InceptionV3 mimarileri sağlamıştır.

**Anahtar kelimeler:** Termal görüntüleme, Meme lezyonu, Sınıflandırma, Bölütleme, Mask R-CNN, U-Net, Transfer öğrenme

## Classification of Breast Lesions via Active Thermograms with the Help of Deep Learning

**Abstract:** In recent years, artificial intelligence studies, which have developed in parallel with computer hardware, have helped increase patient survival by preventing possible metastasis with early diagnosis of clinicians. There are many studies in literature that carry out diagnosis of cancer in the clinic. In these studies, machine learning and deep learning applications are frequently applied for cancer classification. Similarly, in this study, diagnosis of breast cancer

over thermal images with the help of deep learning methods was discussed. The images used in the study were taken open access made available in the DMR-IR dataset. Some preprocessing was done on the images before manual and automatic segmentation methods were applied to segment the breast regions on images. In the manual segmentation process, the mask of the breast regions whose localization information was recorded with VIA was created and the segmentation was performed by subtracting the mask from the original image. In the automatic segmentation process, segmentation was done using Mask R-CNN and U-NET techniques. Segmentation performance analysis was performed for these two methods and classification operations were done with Mask R-CNN, which realized 0.9896 accuracy, 0.9413 Dice and 0.8900 Jaccard. Breast cancer classification was carried out using seven pre-trained architectures (InceptionV3, MobileNet, MobileNetV2, ResNet50, VGG16, VGG19 and Xception) with thermograms consisting of images segmented by manual and Mask-RCNN methods. As a result, MobileNet and InceptionV3 architectures provided the 100% classification success in test data accuracy, precision, sensitivity and F1 Score.

**Keywords:** Thermal imaging, Breast lesion, Classification, Segmentation, Mask R-CNN, U-Net, Transfer learning

## 1. Giriş

Akciğer ve kolon kanseriyle birlikte kadınlarda en sık görülen kanser türlerinden biri olan meme kanseri, kardiyovasküler kanserlerden sonra ölümü en fazla tetikleyen kanserdir [1]. Küresel Kanser Gözlemevi'nin (GLOBOCON) 2020 yılındaki verilerine göre meme kanserinden ölüm oranının %13.6 ve insidans oranının %11.7 olduğu raporlanmıştır [2]. Diğer kanser türlerinde olduğu gibi meme kanserinde de erken teşhis hasta sağ kalımını artıran oldukça önemli bir etkidir. Klinikte hasta tanısının konulabilmesi için öncelikle lezyonun görüntülenmesi çalışılır ve şüpheli bir durum görüldüğünde ise biyopsi yapılarak patoloji sonucuna göre kanser teşhisi tamamlanır. Ancak bu yöntem kanser teşhisinin konulmasında altın standart olarak gösterilse de biyopsinin uygulanan bölgede kanama, morarma ve enfeksiyon gibi riskler barındırdığı bilinen bir durumdur. Klinikte uygulanan görüntüleme yöntemleri arasında ise mamografi altın standart olarak kabul edilir. Bu yöntemin non-invaziv olması ve küçük boyutlu meme kitlelerini tespit edebilmesi gibi avantajları bulunurken hasta konforunu bozması, iyonlaştırıcı radyasyon içermesi ve yoğun dokularda görüntülemenin zorlaşması gibi dezavantajları da mevcuttur.

Mamografi ve klinikte kullanılan diğer görüntüleme yöntemlerinin (Ultrason, MRG vs.) dezavantajlarının önüne geçilebilen hasta konforunu bozmayan, iyonize radyasyon içermeyen ve uygun maliyetli yeni görüntüleme metotlarının klinikte kullanılması yaygınlaşmalıdır. Bu bağlamda son yıllarda literatürde termal kameraların meme lezyonu görüntüleme yöntemlerinde çalışmaları sıklıkla yer aldığı görülmektedir. Cisimlerden yayılan elektromanyetik radyasyonun elektrik sinyallerine çevrilmesiyle sıcaklık bilgisini tespit edebilen bu kameralar lezyonlu dokuların buldukları bölgedeki metabolizma hızı ve kan akış hızını artırması sebebiyle oluşan sıcaklığın haritalanmasını sağlar. Bu yöntemin girişimsiz olması, iyonize radyasyon içermemesi ve hasta konforunu bozmaması gibi avantajları vardır. Yine de lenf nodülleri gibi yoğun damar yapılarını lezyonlu yapılarla benzetmesi yanlış teşhise sebep olabilmektedir. Ancak görüntü işleme ve yapay sinir ağlarının kullanılması ile bu dezavantajın önüne geçilebilmektedir.

Termal görüntüleme yöntemi aktif ve pasif olmak üzere iki farklı şekilde uygulanmaktadır. Pasif termografi doğrudan nesnelere üzerinden yayılan sıcaklık bilgisinin alınarak görüntünün oluşturulmasını sağlar. Aktif termografi ise görüntülenecek bölgenin bir dış uyaran (ısıtma-soğutma) etkisiyle sıcaklığının

değiştirilmesi ve ısınarak ilk sıcaklığa dönülürken belirli aralıklarda görüntülemenin yapılması şeklinde uygulanır [3]. Literatürde bu yöntemlerle toplanan termogramlar üzerinden kanser teşhisini yapay zeka uygulamaları yardımıyla gerçekleştiren birçok çalışma mevcuttur [4, 5].

Yapay zeka uygulamaları makine öğrenmesi ve derin öğrenme olmak üzere iki şekilde çalışılmaktadır [6, 7]. Makine öğrenmesi çalışmalarında da oldukça başarılı sınıflandırma işlemleri yapılabilir de alınan görüntüler üzerinde çeşitli özellik çıkarımı ve seçimi işlemlerinin manuel olarak yapıldığından görüntünün yapı ve bileşimi ihmal edilebildiği bilinmektedir [8]. Derin öğrenmede ise makine öğrenme algoritmalarının aksine görüntüden özellik çıkarımı işlemleri otomatik olarak yapıldığından daha yüksek doğrulukta sonuçlar elde edilebilmektedir [9]. Ancak bu yöntem ile yapılan çalışmalarda modellerin eğitiminin sağlıklı bir şekilde yapılabilmesi için büyük veriler ile eğitilmesi ve güçlü bilgisayarların kullanılması gerekmektedir. Biyomedikal alanda ise görüntü toplanması işlemleri genellikle sınırlı olduğundan önceden eğitilmiş ağlar kullanılarak az sayıda görüntü ile başarımın artırılmaya çalışıldığı transfer öğrenme çalışmaları sıklıkla tercih edilmektedir [5, 10].

Literatürde yer alan çalışmalara göre meme kanseri teşhisi için derin öğrenme çalışmalarının diğer geleneksel makine öğrenmesi çalışmalarına göre daha başarılı sonuçlar verdiği bilinmektedir. Bu çalışmalarda genellikle meme kanseri teşhisi için algılama, bölütleme ve sınıflandırma çalışmaları yapılmıştır [11-14].

Schaefer, et al. [15] meme kanseri teşhisini ortalama sıcaklık, iki memenin sıcaklık farkı, sıcaklığın standart sapması, medyan sıcaklık gibi istatistiksel özellikler üzerinde bulanık sınıflandırma yöntemi kullanarak çalışmışlardır. Sonuç olarak kanserli ve sağlıklı lezyon tespitini sınıflandırma başarımlarının %80 olduğunu raporlamışlardır.

Acharya, et al. [16] meme kanseri teşhisi için doku özelliklerinin çıkarılmasıyla elde edilen bilgileri Destek Vektör Makinesi (DVM) ile sınıflandırmış ve %88.1 doğruluk, %85.71 duyarlılık ve %90.48 özgüllük elde edildiğini belirtmişlerdir.

Mookiah, et al. [17] meme kanseri teşhisi için doku özellikleri ve Ayrık Dalgacık Dönüşümü (Discrete Wavelet Transform, DWT) ile birlikte makine öğrenmesi algoritmaları ile sınıflandırılmasını çalışmışlardır. Karar Ağacı ve Bulanık Sugeno algoritmalarında %93.3 doğruluk, %86.7 duyarlılık ve %100 özgüllük değerleri ile yüksek başarımlar elde etmişlerdir.

Golestani, et al. [18] termal meme görüntüleri üzerinden lezyonlu bölgelerin bölütlenmesini çalışmışlardır. Bölütleme işlemleri için k-ortalamlar, bulanık c-ortalamlar ve seviye belirleme algoritması kullanılmış ve bu yöntemler arasında en iyi bölütlemeyi seviye belirleme algoritmasının yaptığını nitel olarak ortaya koymuşlardır.

Milosevic, et al. [19] termogramlar üzerinden Gri Düzey Birlikte Oluşum Matrisi (Gray Level Co-Occurrence Matrix, GLCM) kullanarak özellik çıkarımı uygulamış ve SVM, K-NN ve Naive Bayes ile sınıflandırma yapmayı amaçlamış ve sonuç olarak K-NN algoritması ile %92.5 doğruluk başarımının elde edildiğini raporlamışlardır.

Pramanik, et al. [20] Dalgacık Dönüşümü ile özellik çıkarımı işlemleri uygulandıktan sonra İleri Beslemeli Çok Katmanlı Algılayıcı (Feed-Forward Multilayer Perceptron Network, MLP) algoritması ile sınıflandırılma konusunu çalışmışlar ve %90.48 doğruluk, %87.6 hassasiyet ve %89.73 özgüllük değerlerinin elde edildiğini raporlamışlardır.

Baffa and Lattari [3] statik ve dinamik termal görüntüleme ile elde edilen iki farklı veri seti kullanarak meme kanseri teşhisini amaçlamışlardır. Veri setinden alınan görüntüler Evrişimli Sinir Ağı (Convolutional Neural Network, CNN) ile sınıflandırılmış ve statik termal veri setinde %98 doğruluk ve dinamik veri setinde ise %95 doğruluk elde edilmiştir.

Karim, et al. [4] el yordamıyla yapılan bölütleme işlemlerinin ardından GLCM ile özellik çıkarımı ve DVM ile sınıflandırma yaparak termogramlar üzerinden meme kanseri teşhisi konusunu çalışmışlar ve %91.25 doğruluk, %93.3 duyarlılık ve %90 özgüllük değerlerinin elde edildiğini belirtmişlerdir.

Fernández-Ovies, et al. [21] ESA ile transfer öğrenme kullanarak termal meme görüntüleri üzerinden meme kanseri sınıflandırması yapmış ve transfer öğrenme çalışmasında ResNet18, ResNet34, ResNet50, ResNet152, VGG16 ve VGG19 mimarilerini kullanmışlardır. En yüksek sınıflandırma başarımını %100 doğruluk değeri ile ResNet34 ve ResNet50 mimarilerinin elde ettiği raporlanmıştır.

Tello-Mijares, et al. [22] Gradyan Vektör Akış Yılanları (Gradient Vector Flow Snakes, GVFS) ile bölütleme işlemlerini uyguladıktan sonra ESA, TRF, MLP ve Naive Bayes algoritmaları ile termogramlar üzerinden meme kanseri teşhisini çalışmışlardır. Sonuç olarak TRF ile %85.71, MLP ile %88.88 ve NV ile %80.95 sınıflandırma başarımı sağlarken ESA ile %100 doğruluk elde etmişlerdir.

Liang, et al. [23] ultrason görüntüleri üzerinden Mask R-CNN mimarisini kullanarak meme lezyonlarının bölütlenmesi ve sınıflandırılmasını çalışmışlardır. Konvansiyonel elastik (conventional elastic), yalnızca katı (rigid-only) ve çok ölçekli süper piksel elastik (multi-scale super-pixel elastic) olmak üzere üç farklı grupta çalışma yapılmış ve sonuç olarak yalnızca katı grubunda %77.62, konvansiyonel elastik grupta %78.50 ve çok ölçekli süper piksel elastik grubunda %80.42 sınıflandırma başarımlarının elde edildiği bildirmişlerdir.

Chiao, et al. [24] ultrason görüntüleri üzerinden meme kanseri teşhisi için Mask R-CNN mimarisini kullanmışlar ve lezyon bölgesinin tanımlanmasının 0.75 mAP ve sınıflandırma başarımının %85 olduğunu raporlamışlardır.

Farooq and Corcoran [25] termogramlar üzerinden meme kanseri teşhisi için Kontrast Sınırlı Uyum Histogram Eşitleme (Contrast Limited Adaptive Histogram Equalization, CLAHE) ve normalizasyon işlemleri ile ön işlemler gerçekleştirmiş ve ardından önceden eğitilmiş Inception V3 mimarisi ile transfer öğrenme uygulamışlardır. Sonuç olarak test verilerinde %80 doğruluk, %83.33 hassasiyet ve %77.77 özgüllük değerleri elde etmişlerdir.

Zuluaga-Gomez, et al. [5] meme kanseri teşhisi için ön işlem ve bölütleme işlemlerinin ardından önceden eğitilmiş ResNet, SeResNet, InceptionV3, VGG16, InceptionResNetV2 ve Xception mimarileri ile transfer öğrenme ve kendi geliştirdikleri CNN mimarisi ile sınıflandırma konusunu çalışmışlardır. Sonuç olarak kendi mimarileri ile %92 doğruluk, %94 kesinlik ve %91 duyarlılık değerlerinin önceden eğitilmiş mimarilerden daha yüksek olduğunu raporlamışlardır.

Ghayoumi Zadeh, et al. [26] meme bölgelerinin bölütlenmesinde yarı otomatik ve yapay sinir ağları kullanılarak bölütleme işlemleri uygulanmıştır. Uygulanan bölütleme işlemlerinin ardından ortalama, standart sapma, enerji, entropi ve homojenite ile elde edilen özellikler kullanılarak oto kodlayıcı ile sınıflandırma çalışılmıştır. Sonuç olarak test verilerinde %94.87 doğruluk, %87.5 hassasiyet ve %96.77 özgüllük değerleri elde etmişlerdir.

Çivilibal ve arkadaşları 2023 yılında yaptıkları çalışmada termogramlar üzerinden meme lezyonlarının otomatik tespiti, segmentasyonu ve sınıflandırılması için Mask R-CNN kullanarak Res-Net50 mimarisi ile %97.1 Doğruluk, 0.921 Ortalama Hassasiyet (Mean Average Precision, mAP) ve 0.868 Örtüşme Puanı başarımını elde etmişlerdir [27].

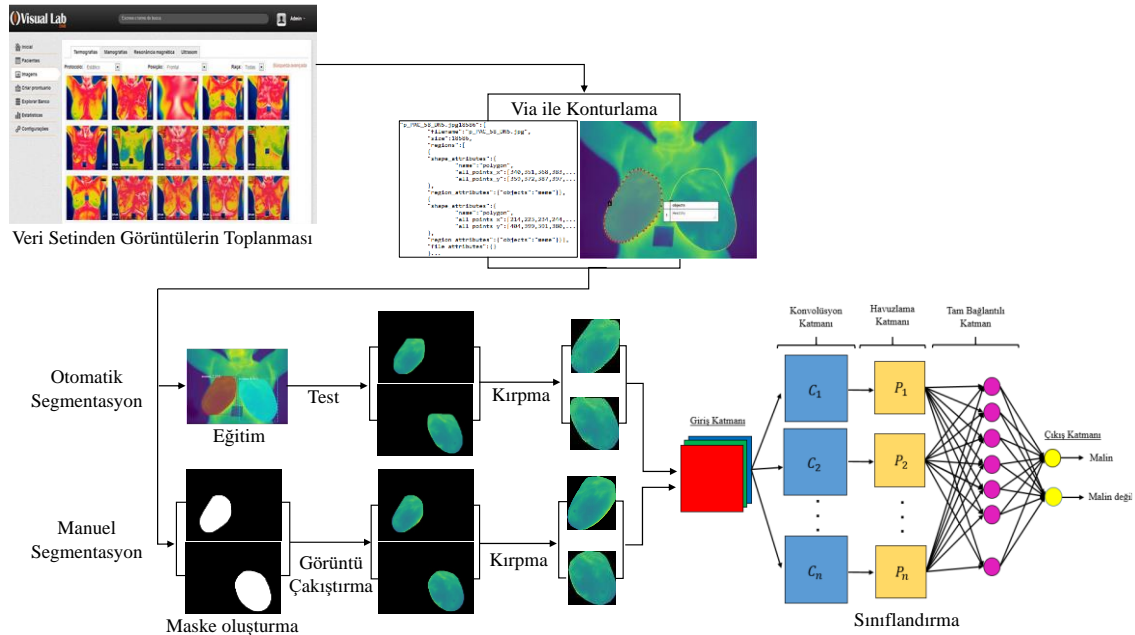
Literatürdeki çalışmalar incelendiğinde, meme kanseri teşhisi için mamogram, ultrason ve termal görüntüleme yöntemlerinin kullanıldığı, elde edilen görüntülerin makine öğrenmesi ve derin öğrenme yöntemleri ile sınıflandırma ve bölütleme çalışmalarında

sıklıkla yer aldığı görülmektedir. Yapılan çalışmalarda genellikle hasta bazında bir sınıflandırma veya termogramlar üzerinde yer alan en sıcak bölgelerin bölütlenmesiyle elde edilen görüntülerin sınıflandırılması çalışılmıştır. Bu çalışmada hasta bazında değil meme bazında çalışılmış ve termogram üzerinde en sıcak bölgenin değil meme bölgesinin bölütlenmesi amaçlanmıştır. Böylece hastanın kanserli birey olduğu bilgisinin yanı sıra hangi memesinin kanserli olduğu tanısı da yapılabilmektedir. Meme bölgesinin bölütlenmesinin ardından termogram üzerinde sadece meme bölgesinde yer alan sıcak bölgeye odaklanılması hedeflenmiş ve ardından elde edilen görüntüler ile transfer öğrenme uygulanarak sınıflandırılması çalışılmıştır. Bu şekilde yapılan kanser teşhisinin girişimsiz olması, hasta konforunu etkilememesi ve zararlı radyasyon içermemesi ile beraber olabildiğince hızlı yapılması hedeflenmiştir.

Bu çalışmada, meme kanseri teşhisi için termogramlar üzerinden derin öğrenme kullanılarak meme bölgelerinin bölütlenmesi ve sınıflandırılması yapılmıştır. Çalışmada kullanılan veriler erişime açık bir kaynakta sunulan [28] veri setinden alınmıştır. Veri setinden alınan görüntüler bölütleme işlemlerinden önce VIA web programı kullanılarak meme bölgeleri işaretlenip “.json” uzantısıyla kaydedilmiştir. Kaydedilen dosya kullanılarak hem manuel hem de otomatik bölütleme işlemleri yapılmıştır. Manuel bölütleme için işaretlenmiş meme bölgeleri kullanılarak meme maskeleri oluşturulmuş ve görüntünün geri kalanından çıkarılarak bölütlenmiştir. Otomatik bölütlemeye ise elde edilen lokalizasyon bilgileri kullanılarak Mask-RCNN ve U-Net ile otomatik bölütleme test edilmiştir. Bölütleme işlemlerinin ardından önceden eğitilmiş evrimsel sinir ağları ile transfer öğrenme uygulanarak sınıflandırma yapılmıştır. Sınıflandırma işlemlerinde manuel ve Mask-RCNN ile elde edilen bölütlenmiş görüntüler ayrı ayrı test edilmiştir. Çalışma sonunda ise kullanılan yöntemlerin sınıflandırma performansları değerlendirilmiştir.

## 2. Materyal ve Metot


Bu çalışmada termal meme görüntüleri üzerinden meme kanseri teşhisi ele alınmıştır. Çalışma kapsamında tasarlanan sistemin akış şeması Şekil 1’de verilmiştir.



Şekil 1. Çalışma kapsamında tasarlanan sistemin akış şeması


Çalışma kapsamında Silva ve ark. (2014) tarafından paylaşılan termal meme görüntüleri kullanılmıştır. Bu veri seti meme kanseri hastalarından ve sağlıklı hastalardan alınan

termogramlar ve mamogramlardan oluşmaktadır. Veri tabanından alınan termal meme görüntüleri FLIR SC-620 termal kamera kullanılarak 19 sağlıklı ve 37 meme kanseri hastadan alınmıştır. Toplanan meme görüntüleri 640\*480 piksel çözünürlükte ve hasta başına 20 adet “.txt” dosyasından oluşmaktadır. Şekil 2’de veri setini temsilen dört hastanın örnek termogram görüntüleri verilmiştir. Hastalardan meme termogramlarının alımı statik ve dinamik termografi olmak üzere iki farklı prosedürde alınmıştır. Statik görüntüleme hastalar belirli bir süre oda sıcaklığında bekledikten sonra kameraya eşit mesafede önden, 45 derece sağ, 90 derece sağ, 45 derece sol ve 90 derece sol olmak üzere farklı pozisyonlarda görüntüler toplanmıştır. Dinamik termografide ise meme bölgeleri soğutucu fan yardımıyla belirli süre soğutulduktan sonra 5 dakika boyunca her 15 saniyede görüntüsü toplanmıştır.



Şekil 2. Veri setinden alınan örnek termogramlar (a) sağlıklı, (b) lezyonlu, (c) mastektomili ve (d) asimetrik meme dokusu [28].

Meme bölgelerinin bölütlenmesi işlemleri için öncelikle görüntüler VGG Image Annotator (VIA) [29] kullanılarak meme dokusunun lokalizasyon bilgileri “.json” dosyası biçiminde kaydedilmiştir. Şekil 3’te verilen görüntülerin VIA ile konturlanmış halleri verilmiştir.



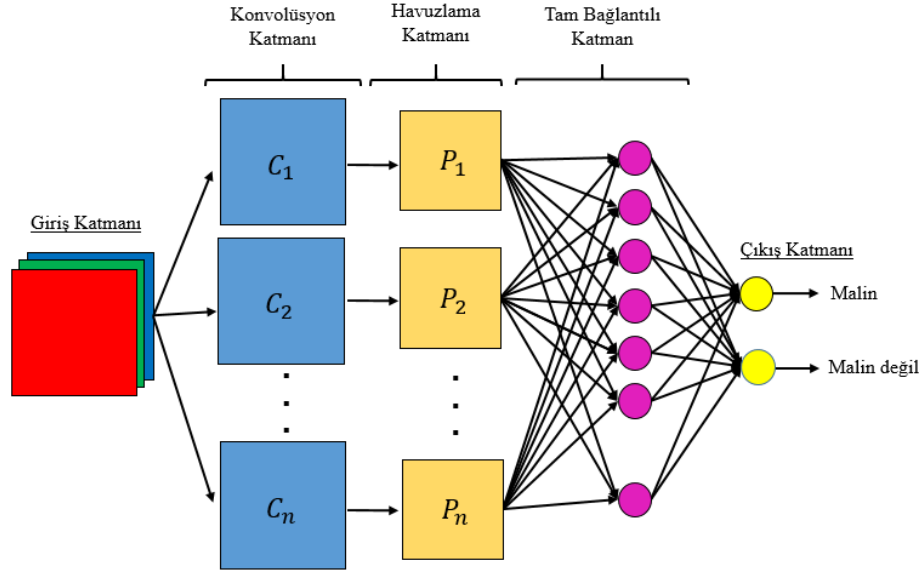
Şekil 3. VIA ile konturlanan termogramlar (a) sağlıklı, (b) lezyonlu, (c) mastektomili ve (d) asimetrik meme dokusu [28].

İşaretlenen meme bölgeleri ile manuel ve otomatik olmak üzere iki farklı bölütleme yöntemi denenmiştir. İlk denemede işaretlenen meme bölgeleri kullanılarak meme maskeleri oluşturulmuş ve orijinal görüntü ile karşılaştırılarak bölütleme yapılmıştır. İkinci denemede ise Mask-RCNN ve U-Net metotları ile otomatik bölütleme çalışılmıştır. Bölütleme işlemlerinin ardından önceden eğitilmiş evrimsel sinir ağları ile transfer öğrenme uygulanarak sınıflandırma yapılmıştır. Sınıflandırma işlemlerinde manuel ve Mask-RCNN ile elde edilen bölütlenmiş görüntüler ayrı ayrı test edilmiştir. Çalışma sonunda ise kullanılan yöntemlerin sınıflandırma performansı değerlendirilmiştir.

### 2.1 Ağ mimarisi

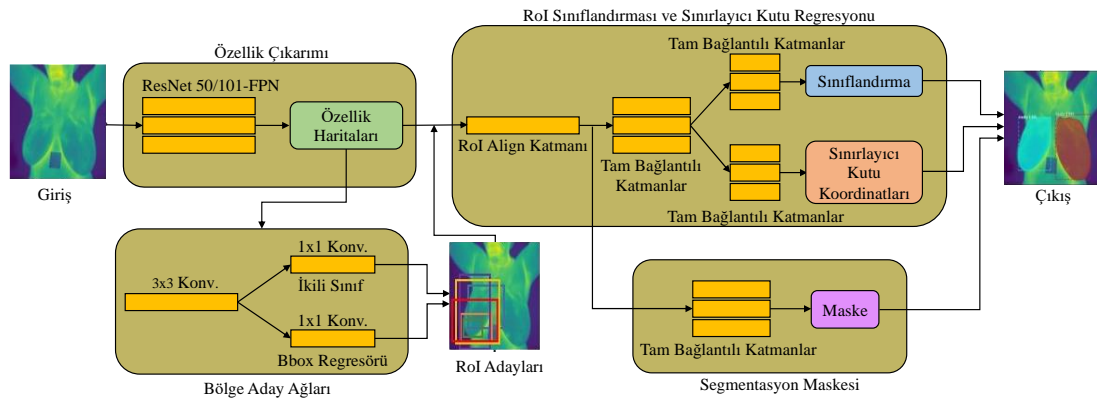
Bu çalışmada sınıflandırma işlemleri için literatürde bir çok çalışmada da kullanılan ve kanser sınıflandırmasında başarılı sonuçlar verdiği raporlanan Evrimsel Sinir Ağları kullanılmıştır. Evrimsel sinir ağları tıbbi görüntüler üzerinde algılama, bölütleme ve sınıflandırma çalışmalarında sıklıkla kullanılan derin öğrenme mimarileridir [30]. Bu mimarilerde giriş katmanı ile alınan görüntülerin boyutlandırılması yapıldıktan sonra evrim ve havuzlama katmanları ile özellik çıkarımları yapılır. Çıkarılan özellikler tam bağlantılı katmanda sınıflandırılarak çıkış katmanına iletilerek sınıflandırma işlemi tamamlanır [31]. Şekil 4’te ESA mimarisinin genel şeması verilmiştir.  $C_1..C_n$  tasarlanan

modelde kullanılan konvolüsyon katmanı sayısını,  $P_1..P_n$  ise modelde kullanılan havuzlama katmanı sayısını belirtmektedir.



Şekil 4. Evrişimsel sinir ağı


Bu çalışmada meme bölgelerinin otomatik olarak bölütlenmesi için ESA mimarisinin bir alt ağı olan Mask R-CNN ve biyomedikal görüntülerin bölütlenmesinde sıklıkla tercih edilen U-NET mimarileri ele alınmıştır. Mask R-CNN mimarisi genellikle sınırlı sayıda veri içeren ve bölütleme işlemlerinin zor olduğu çalışmalarda tıbbi görüntülerde maskeleme ve sınıflandırma işlemlerinde kullanılır [23, 24]. Bu mimari üç basamaktan oluşan ve ilk basamağında görüntü üzerinde bir kez çalıştırılacak olan ResNet, VGG ve Inception gibi mimarileri omurga olarak alıp bölge önerisi verilerek sınırlayıcı kutular oluşturulmasını içerir. İkinci basamakta bölge önerisi verilen sınırlayıcı kutular içerisinde yer alan nesnenin sınıflandırılması yapılır. Üçüncü ve son bölümde ise sınırlandırılmış kutu içine alınmış nesnenin bölütlenmesi yapılır [32]. Şekil 5'te Mask R-CNN mimarisinin çalışma şeması verilmiştir.



Şekil 5. Mask R-CNN mimarisi [33]

U-Net ise sınırlı sayıda veri toplanabilen biyomedikal görüntülerin piksel bazlı bölütlenmesi işlemlerinde sıklıkla kullanılan ve yüksek başarımlar elde edilen bir mimaridir [34]. Şekil 6'da gösterildiği gibi "U" harfine benzeyen iki ayaklı çalışan bir mimari olup "Encoder" olarak adlandırılan ilk ayağında görüntü boyutu sürekli azaltılarak görüntünün ne olduğu öğrenilirken, "Decoder" denen ikinci ayağında görüntü boyutu artırılarak görüntünün nerede olduğu bilgisi öğrenilmeye çalışılır. Mimari ilk katmandan son katmana kadar sadece evrişim katmanlarından oluşur ve çıkış katmanında yüksek çözünürlüklü bölütlenmiş görüntü haritası ile bölütlemeyi çalışır [35].





Şekil 6. U-Net mimarisi [34]

Sınırlı sayıda veri bulunan çalışmalarda model başarımının artırılması için kullanılan transfer öğrenme ile önceden eğitilmiş modellerin nesne tanıyabilme kabiliyetlerinin yeni problemler üzerinde kullanılması sıklıkla kullanılan bir yöntemdir. Bu şekilde modellerin sıfırdan nesne tanımakla uğraşmadan önceden öğrenilmiş bilgiler üzerinden sınıflandırma için kullanılmasıyla çalışma hızlanmış olur [36, 37].

## 2.2 Bölütleme başarımlı değerlendirme yöntemi


Çalışmada bilinen ve bölütlenmiş görüntüler kullanılarak eğitilen modellerin bölütleme performansları Doğruluk, Duyarlılık, Özgüllük, F1 skoru, Kesinlik, MCC, Dice ve Jaccard indeksleri ile değerlendirilmiştir. Şekil 7'de gösterilen iki farklı küme, tespit edilen ve bilinen meme görüntüsü içeresine denk gelen her bir pikselin tek tek sayılması ile kümelenmesini temsil etmektedir

*Doğru Pozitif (DP)*: Referans görüntüde maskelenmiş bir bölgede yer alan bir pikselin bölütlenmiş sonuç görüntüsünde de maskelenmiş bölge içerisinde bulunduğu durum.

*Doğru Negatif (DN)*: Referans görüntüde maskelenmiş bir bölgede yer almayan bir pikselin bölütlenmiş görüntüde maskelenmiş bölge içinde yer almadığı durum.

*Yanlış Pozitif (YP)*: Referans görüntüsünde maskelenmiş bölge içerisinde yer almayan bir pikselin bölütlenmiş görüntüde maskelenmiş bölge içerisinde yer aldığı durum.

*Yanlış Negatif (YN)*: Referans görüntüsünde maskelenmiş bir bölge içerisinde bulunan bir pikselin bölütlenmiş görüntüde maskelenmiş bölge içerisinde yer almadığı durum [38].



Şekil 7. Bölütleme performansının değerlendirilmesi

Bilinen ve bölütlenmiş görüntü içerisinde yer alan tüm piksellerin konum bilgilerinin tespitinin ardından DP, DN, YP ve YN sayıları hesaplanır ve bu değerler yardımı ile bölütleme başarımları aşağıdaki formüller kullanılarak hesaplanır [38].

$$\text{Doğruluk} = \frac{DP + DN}{DP + DN + YP + YN} \quad (1)$$



$$\text{Duyarluluk} = \frac{DP}{DP + YN} \quad (2)$$

$$\text{Özgüllük} = \frac{DN}{DN + YP} \quad (3)$$

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

$$\text{MCC} = \frac{DP * DN - YP * YN}{\sqrt{(DP + YP) * (DP + YN) * (DN + YP) * (DN + YN)}} \quad (5)$$

$$\text{Dice} = \frac{2 * DP}{2 * DP + YP + YN} \quad (6)$$

$$\text{Jaccard İndeksi} = \frac{DP}{DP + YP + YN} \quad (7)$$

### 2.3 sınıflandırma başarımı değerlendirme yöntemleri

Çalışmada sınıflandırma performansının değerlendirilmesi için literatürde sıklıkla rastlanan Karmaşıklık Matrisi (Confusion Matrix) yöntemi kullanılmıştır. Bu matrislerde bilinen gerçek sonuçlar ile tahmin edilen yanıtlar yer alınır [30]. Şekil 8’de karmaşıklık matrisinin tanımı verilmiştir.

*Doğru Pozitif (DP)*: Tümörlü memenin “tümör var” olarak tahmin edilmesi.

*Yanlış Negatif (YN)*: Tümörlü memenin “tümör yok” olarak tahmin edilmesi.

*Yanlış Pozitif (YP)*: Tümörlü olmayan memenin “tümör var” olarak tahmin edilmesi.

*Doğru Negatif (DN)*: Tümörlü olmayan memenin “tümör yok” olarak tahmin edilmesi.

		Tahmin (Prediction)	
		Var	Yok
Bilinen Gerçek (Actual)	Var	Doğru Pozitif (True Positive, TP)	Yanlış Negatif (False Negative, FN)
	Yok	Yanlış Pozitif (False Positive, FP)	Doğru Negatif (True Negative, TN)

Şekil 8. Karmaşıklık matrisi [39]

Karmaşıklık matrisi ile elde edilen bilgiler kullanılarak modelin doğruluğu, hassasiyeti ve özgüllük değerleri aşağıdaki formüller yardımıyla hesaplanmıştır [22].

$$\text{Doğruluk (Accuracy)} = \frac{TP + TN}{TP + TN + FP + FN} \quad (8)$$

$$\text{Kesinlik (Precision)} = \frac{TP}{TP + FP} \quad (9)$$

$$\text{Duyarlılık (Recall)} = \frac{TP}{TP + FN} \quad (10)$$

$$\text{F1 Skor (F1 Score)} = 2 * \frac{\text{Kesinlik} * \text{Duyarlılık}}{\text{Kesinlik} + \text{Duyarlılık}} \quad (11)$$

### 3. Bulgular

Bu çalışmada kullanılan veri setinde 56 hastadan (19 sağlıklı ve 37 hasta) alınan, kişi başı 20 örnekten oluşan, toplamda 1120 adet termal meme görüntüsü yer almaktadır. Her görüntüde yer alan meme bölgelerinin lokalizasyon bilgileri VIA web yazılımı kullanılarak etiketlenmiş ve “.json” uzantısıyla kaydedilmiştir. Elde edilen görüntülerin rastgele %80’i (896 adet görüntü) eğitim seti, geriye kalan %20’si (224 adet görüntü) test seti olarak belirlenmiştir. Toplamda 1182 sağlıklı meme ve 610 kanserli meme görüntüleri ile eğitilip, 298 sağlıklı meme ve 150 kanserli meme görüntüsü ile test


edilmiştir. Meme bölgelerinin bölütlenmesi için iki farklı yöntem önerilmiştir. İlk yöntemde elde edilen lokalizasyon bilgileri yardımıyla meme bölgelerinin maskeleri Şekil 9’da görüldüğü gibi oluşturulmuş ve her maske orijinal görüntüsünden çıkarılarak bölütleme yapılmıştır. İkinci yöntemde ise Mask R-CNN ve U-NET ile otomatik bölütleme çalışılmıştır.

Manuel bölütlenmiş görüntüler ile eğitimi yapılan mimarilerin test işlemlerinde hem manuel bölütlenmiş hem de otomatik bölütlenmiş görüntülerin testi yapılmıştır. Buradaki amaç bir uzman görüşü ile bölütlenmiş meme görüntüleri ile eğitimi yapılan mimarinin tekrardan bölütlenme işleminin olmaması için otomatik bölütlenerek işlem yükünün azaltılması hedeflenmiştir. Bu şekilde yeni görüntülerin sisteme eklenmesi halinde model otomatik bölütleme yapıp ardından test işlemlerini gerçekleştirmektedir. Sonuçlarda hem manuel bölütleme hem de otomatik bölütleme sonuçlarının verilmesi eğitilen bölütleme mimarilerinde uzman gibi bölütleme yapıp sonuçlarının oldukça yakın olduğunu göstermek için verilmiştir.



Şekil 9. Bir hastanın a) meme dokusunun VIA ile bölütlenmiş hali, b) sağ ve sol memenin ikili (binary) maskeleri ve c) sağ ve sol memenin bölütlenmiş halleri

Şekil 9.c’de görüldüğü gibi siyah arka plan meme bölgesine oranla görüntü üzerinde daha fazla yer kaplamaktadır. ESA mimarilerinin eğitiminde giriş katmanlarına görüntüler verilirken yapılan boyut azaltması işleminde siyah bölgenin sınıflandırma açısından herhangi bir önemi olmadığından meme dokusu dışında kalan alan Şekil 10’da gösterildiği gibi kırılmıştır.




Şekil 10. Bir hastanın kırılan (a) sol ve (b) sağ meme görüntüleri

Otomatik bölütleme için U-Net ile yapılan bölütleme işlemlerinde her görüntüdeki konturlanmış meme bölgelerinin x ve y koordinatları kullanılarak oluşturulan maskeler yardımı ile orijinal görüntünün eğitimleri yapılmış ve test verilerinin bölütlenmesi ele alınmıştır. Otomatik bölütleme için uygulanan bir diğer yöntem olan Mask R-CNN mimarisinde ise önceden eğitilmiş ResNet101 mimarisi omurga alınarak “.json” dosyası ile model eğitimi ve sonra test verilerinde bölütleme yapılmıştır.

Bölütleme performanslarının değerlendirilmesi için her iki bölütleme metodu ile elde edilen görüntüler orijinal kırılmış görüntülerle karşılaştırılmıştır. Karşılaştırma işlemleri iki farklı yöntemle elde edilmiş görüntülerdeki pikseller tek tek kontrol edilerek gerçekleştirilmiştir. Kullanılan her iki metodun sonuçları görsel olarak Şekil 11’de ve sayısal olarak Tablo 1’de verilmiştir.


Tablo 1. Otomatik bölütleme için kullanılan metotların başarımları

	Doğruluk	Duyarlılık	Özgüllük	Kesinlik	MCC	Dice	Jaccard
Mask R-CNN	0.9896	0.9253	0.9962	0.9605	0.9366	0.9413	0.8900
U-Net	0.9718	0.8701	0.9917	0.9555	0.8946	0.9086	0.8365



**Şekil 11.** Otomatik bölütleme için kullanılan metotların sonuç görüntüleri, a) orijinal görüntü, b) VIA ile etiketlenmiş referans sağ ve sol meme görüntüleri, c) VIA ile etiketlenmiş U-Net için kullanılan referans sağ ve sol meme görüntüleri, d) Mask R-CNN bölütlemesinin sonucu ve e) U-Net bölütlemesinin sonucu

Şekil 11 ve Tablo 1 incelendiğinde Mask R-CNN mimarisinin U-Net mimarisine göre daha başarılı bölütleme gerçekleştirdiği görülmektedir. Bu sebeple otomatik sınıflandırma çalışmasında Mask R-CNN ile bölütlenen ve Şekil 12’de görüldüğü gibi meme hacmi ilk yöntemde olduğu gibi siyah arka plandan kırılan meme görüntüleri kullanılmıştır.



**Şekil 12.** Bir hastanın meme görüntüsünün Mask R-CNN ile otomatik bölütleme sonucu elde edilmiş a) maskeli hali, b) sol ve sağ memenin bölütlenmiş hali ve c) bölütlenmiş bölgelerin kırılmış hali

Çalışmanın bu aşamasından sonra sınıflandırma işlemi için iki farklı yaklaşım paralel olarak test edilmiştir. İlk yaklaşım elle bölütlenmiş meme görüntüleri, ikinci yaklaşım ise Mask RCNN ile bölütlenmiş meme görüntülerinin kullanıldığı veri setini içermektedir. Çalışmada her iki yaklaşım için transfer öğrenme modelleri aynı eğitim görüntüleri ( $896 \times 2 = 1792$  kırılmış termal meme görüntüsü) ile 100 devir sayısı ve 32 yığın boyutu kullanılarak eğitilmiştir. Eğitim sırasında kullanılan hiperparametreler Tablo 2’de gösterilmiştir.

**Tablo 2.** Transfer öğrenme modellerinin eğitiminde kullanılan hiperparametre ve değerleri

Hiperparametreler	Değerler
Optimizasyon Algoritması	Adam
Aktivasyon Fonksiyonu	Softmax
Öğrenme Hızı	0.001
Devir Sayısı	100
Yığın Boyutu	32

Manuel ve otomatik bölütleme ile kırılma işlemlerinin sonucunda elde edilen görüntülerin sınıflandırılması için transfer öğrenmede kullanılan ön eğitilmiş ESA’lar (InceptionV3, MobileNet, MobileNetV2, ResNet50, VGG-16, VGG-19 ve Xception) ele alınmıştır. Tablo 3’de bu modellerin eğitim ve test işlemlerinin süreleri karşılaştırılmıştır.

**Tablo 3.** Transfer öğrenmede kullanılan transfer öğrenme modellerinin eğitim ve test süreleri

Eğitilmiş Ağlar	Toplam Çalışma Süreleri (sn)		
	Eğitim	Test	
		1. Yaklaşım	2. Yaklaşım
InceptionV3	3200	41	40
MobileNet	3300	25	20
MobileNetV2	3700	21	20
ResNet50	3500	64	62
VGG16	3400	138	141
VGG19	3600	167	171
Xception	4065	72	74

Eğitim ve test işlemlerinin ardından modellerin sınıflandırma performanslarının değerlendirilmesi için karmaşıklık matrisleri kullanılmıştır. Tablo 4’de gösterildiği gibi her model için eğitim, ilk yöntem ve ikinci yöntem olmak üzere üç farklı karmaşıklık matrisi oluşturulmuştur.

**Tablo 4.** Transfer öğrenmede kullanılan transfer öğrenme modellerinin eğitim ve test süreleri

		TP	FN	FP	TN	Süre (sn)
		Eğitim	InceptionV3	610	0	1
	MobileNet	610	0	3	1179	1.84
	MobileNetV2	608	2	6	1176	2.06
	ResNet50	610	0	2	1180	1.95
	VGG16	589	21	3	1179	1.90
	VGG19	594	16	8	1174	2.01
	Xception	610	0	0	1182	2.27
1. Yaklaşım	InceptionV3	150	0	0	298	0.09
	MobileNet	150	0	0	298	0.06
	MobileNetV2	148	2	1	297	0.05
	ResNet50	147	3	1	297	0.14
	VGG16	145	5	2	296	0.31
	VGG19	148	2	4	294	0.37
	Xception	149	1	0	298	0.16
2. Yaklaşım	InceptionV3	150	0	0	298	0.09
	MobileNet	150	0	0	298	0.05
	MobileNetV2	149	1	3	295	0.05
	ResNet50	150	0	1	297	0.05
	VGG16	147	3	4	294	0.32
	VGG19	146	4	4	294	0.38
	Xception	149	1	0	298	0.17

Tablo 4’de verilen karmaşıklık matrisleri incelendiğinde kanserli meme tespitini en yüksek başarımla gerçekleştiren mimarilerin InceptionV3, MobileNet, MobileNetV2 ve ResNet50 olduğu görülürken sağlıklı memelerin tespitini ise en yüksek başarımla Xception, VGG16 ve VGG19 mimarilerinin yaptığı görülmüştür. VGG16 ve VGG19 mimarileri sağlıklı memeleri tespit etmekte gösterdiği başarımın aksine diğer mimarilere göre en düşük kanserli meme tespitini gerçekleştiren mimariler olmuştur. Eğitim başarımları incelendiğinde kanserli meme teşhisinde %100 başarımla en yüksek başarımla gösteren mimariler Xception, InceptionV3, MobileNet ve ResNet50 mimarileri olmuştur. Sağlıklı memelerin tespitini en yüksek özgüllük değeri ile gerçekleştiren mimariler ise Xception ve InceptionV3 olmuştur.

Çalışmanın sonucunda elde edilen karmaşıklık matrisleri kullanılarak Doğruluk, Kesinlik, Duyarlılık ve F1 Skor değerleri hesaplanmış ve elde edilen değerler yardımıyla modellerin sınıflandırma performansları Tablo 5’de verilmiştir.


**Tablo 5.** Transfer öğrenme modellerinin başarımları (E: eğitim; T: birinci yöntem için test; M: ikinci yöntem için test)

Modeller	Doğruluk			Kesinlik			Duyarlılık			F1 Skoru		
	E	T	M	E	T	M	E	T	M	E	T	M
InceptionV3	0.999	1.0	1.0	0.998	1.0	1.0	1.0	1.0	1.0	0.999	1.0	1.0

MobileNet	0.998	1.0	1.0	0.995	1.0	1.0	1.0	1.0	1.0	0.998	1.0	1.0
MobileNetV2	0.996	0.993	0.991	0.990	0.993	0.980	0.997	0.987	0.993	0.993	0.989	0.987
ResNet50	0.999	0.991	0.998	0.997	0.993	0.993	1.0	0.981	1.0	0.998	0.986	0.996
VGG16	0.987	0.984	0.984	0.995	0.986	0.974	0.966	0.967	0.983	0.980	0.976	0.976
VGG19	0.987	0.987	0.982	0.987	0.974	0.973	0.974	0.987	0.973	0.980	0.980	0.973
Xception	1.0	0.998	0.998	1.0	1.0	1.0	1.0	0.993	0.993	1.0	0.996	0.996

Tablo 4 incelendiğinde, eğitim sonuçları içerisinde hasta ve sağlıklı sınıflandırmasını en yüksek başarıyla doğrulukla gerçekleştiren mimariler Xception, InceptionV3, ResNet50 ve MobileNet olurken, test verilerinde ise InceptionV3 ile MobileNet mimarileri olmuştur. İncelenen sonuçlardan görüldüğü üzere en yüksek kesinliği gösteren mimarilerin Xception, InceptionV3 ve MobileNet, en yüksek duyarlılığa sahip mimarilerin ise InceptionV3, MobileNet ve ResNet50 olduğu görülmektedir. Duyarlılık ve kesinlik değerlerinin harmonik ortalaması olan ve az sayıda veri içeren çalışmalarda sıklıkla kullanılan bir metrik olan F1 skor değerinde ise en yüksek değeri yine Xception, InceptionV3 ve MobileNet mimarileri göstermiştir.

Sınıflandırma başarımlarının değerlendirilmesinde tek başına karmaşıklık matrisinin kullanılması mimarilerin performanslarını değerlendirmekte yetersiz kalabilmektedir. Çünkü karmaşıklık matrisleri son devir sayısındaki bilinen gerçek sonuçlar ile tahmin edilen yanıtları göstermektedir. Mimarilerin eğitimleri hakkında daha fazla bilgi sahibi olabilmek için mimarilerin ilk devir sayısından itibaren her devir sayısındaki doğruluk ve kayıp değerlerinin incelenebildiği doğruluk ve kayıp grafikleri oluşturulmalıdır [5]. Çalışmada kullanılan mimarilerin doğruluk grafiği Şekil 13(a)'da ve kayıp grafiği de Şekil 13(b)'de verilmiştir.



Şekil 13. Transfer öğrenme modellerinin (a) doğruluk ve (b) kayıp oranlarının devir sayısına göre değişimi

Bir mimarinin eğitiminin tamamlanmasına doğruluk grafiğindeki yükselme eğiliminin ve kayıp grafiğindeki alçalma eğiliminin durmasına göre karar verilir [5]. Bu bilgi ışığında Şekil 13 incelendiğinde Xception, ResNet50, InceptionV3, MobileNet ve MobileNetV2 mimarilerinin birbirlerine oldukça yakın eğriler göstererek eğitimlerini tamamladıkları görülmektedir. Bu mimarilerin aksine VGG16 ve VGG19 mimarilerinin eğitimlerini çok daha geç tamamladıkları görülmüştür.

Bu çalışmada konu alınan termal görüntüler üzerinden meme kanserinin teşhisini çalışan literatürde farklı çalışmalar mevcuttur [4, 26]. Bu çalışmalara bakıldığında sınıflandırma için makine öğrenmesi kullanan araştırmaların görüntünün yapı ve bileşimini ihmal edebildiği, derin öğrenme çalışmalarında ise otomatik özellik çıkarımı yapıldığı için bu sorunun ortadan kalktığı ve görece daha yüksek başarımlara ulaşılabildiği görülmektedir [9]. Ayrıca genellikle hasta bazında sınıflandırmalar yapıldığından görüntünün alındığı kişinin kanser olup olmadığı bilgisine erişilebilir ancak tümörün hangi memede yer aldığı bilgisi elde edilemez. Bu çalışmada ise hasta bazında değil, meme bazında yapılarak bu problemin önüne geçilmiştir. Meme bölgesinin bölütlenmesinde birçok yöntem kullanılabilirken Mask R-CNN veya U-Net ile yapılan bir çalışmaya rastlanmamıştır. Kullanılan farklı bölütleme çalışmalarında da görüntülerdeki en sıcak bölgelerin

bölütlenmesinin çalışıldığı görülmüştür. Her ne kadar bu yöntemin avantajları olsa da meme bölgesi dışındaki sıcak bölgelerin yanlış sınıflandırmaya sebep olabileceği bilinmektedir [28]. Bu sorunun önüne geçilmesi için bu çalışmada tüm görüntü üzerinden değil bölütlenen meme bölgesinde lezyon taraması yapılmıştır.

Bu çalışmada tercih edilen DMR-IR veri setini [28] baz alan literatür çalışmaları incelendiğinde makine öğrenmesi ve derin öğrenme tekniğinin kullanıldığı çalışmalara rastlanmıştır. Pramanik, et al. [20], %90.48 doğruluk, %87.6 hassasiyet ve %89.73 özgüllük değerlerini elde etmişlerdir. Baffa and Lattari [3], statik görüntülerde %98 ve dinamik görüntülerde %95 doğruluk değerleri rapor etmişlerdir. Karim, et al. [4], %91.25 doğruluk, %93.3 duyarlılık ve %90 özgüllük sonuçlarına ulaşmışlardır. Ghayoumi Zadeh, et al. [26], %94.87 doğruluk, %87.5 hassasiyet ve %96.77 özgüllük değerleri elde etmiştir. Tello-Mijares, et al. [22], kendi geliştirdikleri ESA mimarisinin %100 doğrulukla diğer makine öğrenmesi algoritmalarından daha yüksek başarımları gösterdiğini raporlamışlardır. Zuluaga-Gomez, et al. [5], kendi geliştirdikleri ESA ile %92 doğruluk, %94 kesinlik, %91 duyarlılık ve %92 F1 skoru değerlerini elde etmişlerdir.

Bu çalışmada ise Xception mimarisi %100 eğitim doğruluk, kesinlik ve duyarlılık ile sınıflandırma başarımları göstermiştir. Ancak bu değer çalışmada kullanılan diğer mimarilere göre yüksek olsa da en yavaş (4065 sn. eğitim süresi ve 74 sn. test süresi) çalışan mimarilerden biri olmuştur. En hızlı çalışan (3300 sn. eğitim süresi ve 20 sn. test süresi) mimari ise MobileNet olmuştur. Çalışmadan elde edilen sonuçlar ile literatürdeki sonuçlar karşılaştırıldığında bu çalışmanın yüksek başarımları göstermesinin sebebi olarak yüksek bölütleme başarımlarına sahip olması, rastgele dağıtılan eğitim ve test verilerinin veri setini uygun biçimde temsil etmiş olması, hasta bazında değil, meme bazında çalışılması, önceden eğitilmiş ağlar arasından termal meme görüntülerin sınıflandırılmasına uygun olan mimarilerin seçilmiş olması ve uygun devir sayısında eğitilmiş olmalarının önemli rol oynadığı söylenebilir.

#### 4. Sonuç ve Yorum

Meme bölgelerinin termal meme görüntüleri üzerinden algılanması, bölütlenmesi ve sınıflandırılmasının amaçlandığı bu çalışmada açık erişim olarak paylaşılan DMR-IR [28] veri setinden alınan termogramlar üzerinde öncelikle VIA web yazılımı ile meme bölgeleri konturlanıp “meme” olarak tek sınıfta etiketlendikten sonra “.json” formatında kaydedilmiştir. Kaydedilen “.json” dosyası kullanılarak meme bölgelerinin maskeleri oluşturulmuştur. Oluşturulan her maske ile orijinal görüntüsünün üst üste bindirilmesi ile meme bölgeleri bölütlenmiş ve daha sonra yalnızca meme bölgesi kalacak şekilde bölütlenen görüntülerde otomatik kırpma işlemi yapılmıştır. Kırpılan görüntüler ile önceden eğitilmiş ağlar kullanılarak derin öğrenme modellerinin eğitimi gerçekleştirilmiştir. Bu modellerin test işlemlerinde ise manuel ve otomatik bölütleme olmak üzere iki farklı yöntem kullanılmıştır. Otomatik bölütleme için Mask R-CNN ve U-Net metotları kullanılmıştır. Her iki bölütleme metotları da aynı veriler üzerinden test edilmiştir. Kullanılan iki farklı bölütleme yöntemi arasından 0.9896 doğruluk, 0.9413 Dice ve 0.8900 Jaccard değeri ile Mask R-CNN metodunun daha başarılı olduğu sonucuna varılmış ve sınıflandırma işlemleri Mask R-CNN ile bölütlenmiş görüntüler ile yapılmıştır.

Bu çalışmada meme kanseri teşhisi için literatürdeki rastlanan çalışmaların aksine termogram üzerindeki en sıcak bölgelerin bölütlenmesi değil, yalnızca meme bölgesinin bölütlenmesi ve hasta bazında değil, meme bazında sınıflandırma yolu izlenmiştir. Bu şekilde meme bölgesi dışında bulunan sıcak bölgelerin oluşturacağı yanlış sınıflandırmanın önüne geçilmiş ve kanserli lezyonun hangi memede bulunduğu öngörülebilmiştir. Çalışmada kullanılan yedi farklı önceden eğitilmiş ESA mimarileri

içerisinde en yüksek başarıyı Xception, ResNet50, InceptionV3 ve MobileNet mimarileri vermiştir. Bu dört mimari arasında Xception mimarisi diğer mimarilerine göre daha yüksek sınıflandırma başarıyı gösterse de eğitim ve test aşamaları daha uzun sürmüştür. MobileNet ve Inception mimarileri test verilerinde %100 doğruluk, kesinlik ve duyarlılık başarıyı ile Xception mimarisini geride bırakmıştır. MobileNet mimarisinin eğitim ve test sürecinin kısa zamanda sonuçlandırması ile yüksek sınıflandırma başarımının yanında bir de mobil cihazlara entegre edilebilir olması bu mimariyi diğer mimarilerden ayıran en önemli özellik olarak ön plana çıkmıştır.

---

### ***Araştırmacıların Katkı Oranı Beyanı***

**S. Çivilibal:** modeli kurdu, deneyleri gerçekleştirdi.

**K. K. Çevik:** fikri kavramsallaştırdı ve sonuçları yorumladı.

**A. Bozkurt:** çalışmayı denetledi, sonuçları yorumladı ve makaleyi yazdı.

### ***Çatışma Beyanı***

Bu çalışmanın yazarları olarak herhangi bir çatışma beyanımız bulunmadığını bildiririz.

### ***Destek ve Teşekkür Beyanı***

Bu çalışmanın yazarları olarak herhangi bir destek ve teşekkür beyanımız bulunmadığını bildiririz.

### ***Etik Kurul Onayı ve/veya Aydınlatılmış Onam Bilgileri***

Bu çalışmanın yazarları olarak herhangi bir etik kurul onayı ve/veya aydınlatılmış onam bilgileri beyanımız bulunmadığını bildiririz.

### **References**

- [1] N. Harbeck and M. Gnant, "Early breast cancer: treatment concepts and biology," *J. Breast Cancer*, vol. 18, no. 4, pp. 303-312, 2016.
- [2] H. Sung *et al.*, "Global cancer statistics 2020: GLOBOCAN estimates of incidence and mortality worldwide for 36 cancers in 185 countries," *CA: a cancer journal for clinicians*, vol. 71, no. 3, pp. 209-249, 2021.
- [3] M. d. F. O. Baffa and L. G. Lattari, "Convolutional neural networks for static and dynamic breast infrared imaging classification," in *2018 31st SIBGRAPI Conference on Graphics, Patterns and Images (SIBGRAPI)*, 2018: IEEE, pp. 174-181.
- [4] C. N. Karim, O. Mohamed, and T. Ryad, "A new approach for breast abnormality detection based on thermography," *Medical Technologies Journal*, vol. 2, no. 3, pp. 245-254, 2018.
- [5] J. Zuluaga-Gomez, Z. Al Masry, K. Benaggoune, S. Meraghni, and N. Zerhouni, "A CNN-based methodology for breast cancer diagnosis using thermal images," *Computer Methods in Biomechanics and Biomedical Engineering: Imaging & Visualization*, vol. 9, no. 2, pp. 131-145, 2021.
- [6] B. Alafi, "Artificial Intelligence and Deep Learning," *THE JOURNAL OF COGNITIVE SYSTEMS*, vol. 4, no. 2, pp. 57-61, 2019. [Online]. Available: [https://leonardoaraujosantos.gitbooks.io/artificial-inteligence/content/neural\\_networks.html](https://leonardoaraujosantos.gitbooks.io/artificial-inteligence/content/neural_networks.html).
- [7] M. Goyal, T. Knackstedt, S. Yan, and S. Hassanpour, "Artificial intelligence-based image classification methods for diagnosis of skin cancer: Challenges and opportunities," *Comput Biol Med*, vol. 127, p. 104065, Dec 2020, doi: 10.1016/j.compbimed.2020.104065.
- [8] H. Benbrahim, H. Hachimi, and A. Amine, "Deep convolutional neural network with tensorflow and keras to classify skin cancer images," *Scalable Computing*, vol. 21, no. 3, pp. 379-389, 2020, doi: 10.12694:/scpe.v21i3.1725.
- [9] D. A. Shoieb, S. M. Youssef, and W. M. Aly, "Computer-Aided Model for Skin Diagnosis Using Deep Learning," *Journal of Image and Graphics*, pp. 122-129, 2016, doi: 10.18178/joig.4.2.122-129.
- [10] R. Roslidar *et al.*, "A review on recent progress in thermal imaging and deep learning approaches for breast cancer detection," *IEEE Access*, vol. 8, pp. 116176-116194, 2020.
- [11] H. Dhahri, E. Al Maghayreh, A. Mahmood, W. Elkilani, and M. Faisal Nagi, "Automated breast cancer diagnosis based on machine learning algorithms," *Journal of healthcare engineering*, vol. 2019, 2019.



- [12] N. I. Yassin, S. Omran, E. M. El Houby, and H. Allam, "Machine learning techniques for breast cancer computer aided diagnosis using different image modalities: A systematic review," *Computer methods and programs in biomedicine*, vol. 156, pp. 25-45, 2018.
- [13] Y. Jiménez-Gaona, M. J. Rodríguez-Álvarez, and V. Lakshminarayanan, "Deep-learning-based computer-aided systems for breast cancer imaging: a critical review," *Applied Sciences*, vol. 10, no. 22, p. 8298, 2020.
- [14] L. Abdelrahman, M. Al Ghamdi, F. Collado-Mesa, and M. Abdel-Mottaleb, "Convolutional neural networks for breast cancer detection in mammography: A survey," *Computers in Biology and Medicine*, p. 104248, 2021, doi: 10.1016/j.compbimed.2021.104248.
- [15] G. Schaefer, M. Závisek, and T. Nakashima, "Thermography based breast cancer analysis using statistical features and fuzzy classification," *Pattern recognition*, vol. 42, no. 6, pp. 1133-1137, 2009.
- [16] U. R. Acharya, E. Y.-K. Ng, J.-H. Tan, and S. V. Sree, "Thermography based breast cancer detection using texture features and support vector machine," *Journal of medical systems*, vol. 36, no. 3, pp. 1503-1510, 2012.
- [17] M. R. K. Mookiah, U. R. Acharya, and E. Ng, "Data mining technique for breast cancer detection in thermograms using hybrid feature extraction strategy," *Quantitative InfraRed Thermography Journal*, vol. 9, no. 2, pp. 151-165, 2012.
- [18] N. Golestani, M. EtehadTavakol, and E. Ng, "Level set method for segmentation of infrared breast thermograms," *EXCLI journal*, vol. 13, p. 241, 2014.
- [19] M. Milosevic, D. Jankovic, and A. Peulic, "Thermography based breast cancer detection using texture features and minimum variance quantization," *EXCLI journal*, vol. 13, p. 1204, 2014.
- [20] S. Pramanik, D. Bhattacharjee, and M. Nasipuri, "Wavelet based thermogram analysis for breast cancer detection," in *2015 international symposium on advanced computing and communication (ISACC)*, 2015: IEEE, pp. 205-212.
- [21] F. J. Fernández-Ovies, E. S. Alférez-Baquero, E. J. de Andrés-Galiana, A. Cernea, Z. Fernández-Muñiz, and J. L. Fernández-Martínez, "Detection of breast cancer using infrared thermography and deep neural networks," in *International Work-Conference on Bioinformatics and Biomedical Engineering*, 2019: Springer, pp. 514-523.
- [22] S. Tello-Mijares, F. Woo, and F. Flores, "Breast cancer identification via thermography image segmentation with a gradient vector flow and a convolutional neural network," *Journal of healthcare engineering*, vol. 2019, 2019.
- [23] Y. Liang, R. He, Y. Li, and Z. Wang, "Simultaneous segmentation and classification of breast lesions from ultrasound images using mask R-CNN," in *2019 IEEE International Ultrasonics Symposium (IUS)*, 2019: IEEE, pp. 1470-1472.
- [24] J.-Y. Chiao, K.-Y. Chen, K. Y.-K. Liao, P.-H. Hsieh, G. Zhang, and T.-C. Huang, "Detection and classification the breast tumors using mask R-CNN on sonograms," *Medicine*, vol. 98, no. 19, 2019.
- [25] M. A. Farooq and P. Corcoran, "Infrared Imaging for Human Thermography and Breast Tumor Classification using Thermal Images," Letterkenny, Ireland, 11-12 June 2020 2020: IEEE, doi: 10.1109/ISSC49989.2020.9180164.
- [26] H. Ghayoumi Zadeh, A. Fayazi, B. Binazir, and M. Yargholi, "Breast Cancer Diagnosis Based on Feature Extraction Using Dynamic Models of Thermal Imaging and Deep Autoencoder Neural Networks," *Journal of Testing and Evaluation*, vol. 49, no. 3, 2021, doi: 10.1520/jte20200044.
- [27] S. Civilibal, K. K. Cevik, and A. Bozkurt, "A deep learning approach for automatic detection, segmentation and classification of breast lesions from thermal images," *Expert Systems with Applications*, vol. 212, p. 118774, 2023.
- [28] L. Silva *et al.*, "A new database for breast research with infrared image," *Journal of Medical Imaging and Health Informatics*, vol. 4, no. 1, pp. 92-100, 2014.
- [29] A. Dutta and A. Zisserman, "The VIA annotation software for images, audio and video," in *Proceedings of the 27th ACM international conference on multimedia*, 2019, pp. 2276-2279.
- [30] Y. LeCun, Y. Bengio, and G. Hinton, "Deep learning," *nature*, vol. 521, no. 7553, pp. 436-444, 2015.
- [31] K. O'Shea and R. Nash, "An introduction to convolutional neural networks," *arXiv preprint arXiv:1511.08458*, 2015.
- [32] S. Ren, K. He, R. Girshick, and J. Sun, "Faster R-CNN: towards real-time object detection with region proposal networks," *IEEE transactions on pattern analysis and machine intelligence*, vol. 39, no. 6, pp. 1137-1149, 2016.
- [33] K. He, G. Gkioxari, P. Dollár, and R. Girshick, "Mask r-cnn," in *Proceedings of the IEEE international conference on computer vision*, 2017, pp. 2961-2969.
- [34] Y. Weng, T. Zhou, Y. Li, and X. Qiu, "Nas-unet: Neural architecture search for medical image segmentation," *IEEE Access*, vol. 7, pp. 44247-44257, 2019.
- [35] O. Ronneberger, P. Fischer, and T. Brox, "U-net: Convolutional networks for biomedical image segmentation," in *International Conference on Medical image computing and computer-assisted intervention*, 2015: Springer, pp. 234-241.

- [36] U. Snehalatha and K. Sangamithirai, "Computer aided diagnosis of obesity based on thermal imaging using various convolutional neural networks," *Biomedical Signal Processing and Control*, vol. 63, p. 102233, 2021.
- [37] M. B. Lopez, C. R. del-Blanco, and N. Garcia, "Detecting exercise-induced fatigue using thermal imaging and deep learning," in *2017 Seventh International Conference on Image Processing Theory, Tools and Applications (IPTA)*, 2017: IEEE, pp. 1-6.
- [38] M. Aslanyürek and A. Mesut, "Kümeleme Performansını Ölçmek için Yeni Bir Yöntem ve Metin Kümeleme için Değerlendirmesi," *Avrupa Bilim ve Teknoloji Dergisi*, no. 27, pp. 53-65, 2021.
- [39] O. Bilginer, B. Tunga, and R. M. Demirer, "Classification of skin lesions using convolutional neural networks," *Pamukkale Univ Muh Bilim Derg*, vol. 28, no. 2, pp. 208-214, 2022, doi: 10.5505/pajes.2021.68700.