SAĞLIK BİLİMLERİ ÜNİVERSİTESİ İSTANBUL KANUNİ SULTAN SÜLEYMAN SAĞLIK UYGULAMA VE ARAŞTIRMA MERKEZİ

KADIN HASTALIKLARI VE DOĞUM KLİNİĞİ

MAKİNE ÖĞRENMESİ VE YAPAY ZEKA TABANLI MANYETİK REZONANS GÖRÜNTÜLEME ANALİZİ İLE ADNEKSİYEL KİTLELERİN MALİGNİTE POTANSİYELLERİNİN ÖNGÖRÜLMESİ

Dr. Zeynep Acar

(TIPTA UZMANLIK TEZİ)

İSTANBUL 2025

SAĞLIK BİLİMLERİ ÜNİVERSİTESİ İSTANBUL KANUNİ SULTAN SÜLEYMAN SAĞLIK UYGULAMA VE ARAŞTIRMA MERKEZİ

KADIN HASTALIKLARI VE DOĞUM KLİNİĞİ

MAKİNE ÖĞRENMESİ VE YAPAY ZEKA TABANLI MANYETİK REZONANS GÖRÜNTÜLEME ANALİZİ İLE ADNEKSİYEL KİTLELERİN MALİGNİTE POTANSİYELLERİNİN ÖNGÖRÜLMESİ

Dr. Zeynep Acar

Tez Danışmanı:

Doç. Dr. Merve Aldıkaçtıoğlu Talmaç

Yardımcı Tez Danışmanı:

Op. Dr. Hale Çetin Arslan

(TIPTA UZMANLIK TEZİ)

İSTANBUL 2025

İÇİNDEKİLER

İÇİNDEKİLER……...i

TABLOLAR……iii

ŞEKİLLER……...iv

KISALTMALAR……v

ÖZET……...vii

ABSTRACT……viii

1.GİRİŞ VE AMAÇ……1

2.GENEL BİLGİLER……..3

2.1. ADNEKSİYEL KİTLELERİN ETİYOLOJİSİ……...3

2.2. ADNEKSİYEL KİTLELERİN HİSTOLOJİSİ……...5

2.3. ADNEKSİYEL KİTLELER……6

2.3.1. JİNEKOLOJİK ADNEKSİYEL KİTLELER…….....6

2.3.1.1. Ovulatuar Adneksiyel Kitleler…….7

2.3.1.2. Gebelik İle İlgili Adneksiyel Kitleler……..10

2.3.1.3. Üreme Hormonları Tarafından Uyarılan Adneksiyel Kitleler…….11

2.3.1.4. Enfeksiyöz ve İnflamatuar Adneksiyel Kitleler……...12

2.3.1.5. Benign Neoplazmlı Adneksiyel Kitleler……..13

2.3.1.6. Malign Neoplazmlı Adneksiyel Kitleler……..15

2.3.2. NON-JİNEKOLOJİK ADNEKSİYEL KİTLELER……17

2.4. ADNEKSİYEL KİTLELERDE TANISAL DEĞERLENDİRME……...18

2.4.1. Tümör Belirteçlerinin ve Multimodal Testlerin Rolü……...20

2.4.2. Ek Görüntüleme Yönteminin Rolü……...20

2.5. ADNEKSİYEL KİTLELERDE MANYETİK REZONANS GÖRÜNTÜLEME (MRG)…….21

2.6. ADNEKSİYEL KİTLE TANISINDA YAPAY ZEKA……...25

2.6.1. Yapay Zeka İle Nesne Tanıma…….26

2.6.2. Derin Öğrenme Kullanarak Nesne Tanıma……..26

2.6.3. Görüntü Sınıflandırması……...27

2.6.4. Evrişimli Sinir Ağları……..27

3. GEREÇ VE YÖNTEM……29

3.1. ÇALIŞMANIN YÖNTEMİ…….29

3.2. İSTATİKSEL ANALİZ……...33

3.2.1. Kategorik Değişken Analizi…….33

3.2.2. Hata Matrisi (Confusion Matrix)……..34

4. BULGULAR…….36

5. TARTIŞMA……..50

5.1. Çalışmanın Güçlü Yönleri ve Sınırlılıkları……..53

6. SONUÇ…….54

7. KAYNAKLAR…….55

8. ÖZGEÇMİŞ……..61

9. EKLER…….62

TABLOLAR

Tablo-1: Adneksiyal kitlenin ayırıcı tanısı

Tablo-2: Yumurtalık neoplazmlarının bilateralitesi

Tablo-3: Yumurtalık kanseri için risk faktörleri

Tablo-4: Yumurtalık kanseri olan kadınlarda semptom kategorilerinin sıklığı

Tablo-5: O-RADS™ MRG Risk Sınıflandırma ve Yönetim Sistemi

Tablo-6: Gruplar arasındaki demografik veriler ve MRG'de diffüz kontrastlanma istatistikleri

Tablo-7: Tüm Modellerin Makro Ortalama Performans Değerleri

Tablo-8: Tüm Modellerin Normal Görüntülerdeki Performans Değerleri

Tablo-9: Tüm Modellerin Benign Kitlelerdeki Performans Değerleri

Tablo-10: Tüm Modellerin Borderline Kitlelerdeki Performans Değerleri

Tablo-11: Tüm Modellerin Malign Kitlelerdeki Performans Değerleri

ŞEKİLLER

Şekil-1: Normal folikül

Şekil-2: Hemorajik over kisti

Şekil-3: Overyen tümörlerin kökenleri

Şekil-4: Ultrasonda ovarian folikül

Şekil-5: Ultrasonda ovarian korpus luteum

Şekil-6: Ultrasonda polikistik over

Şekil-7: Ultrasonda yumurtalık endometrioması

Şekil-8: Ultrasonda yumurtalık fibrotekomu

Şekil-9: Benign adneksiyel kitle MRI örneği

Şekil-10: Borderline adneksiyel kitle MRI örneği

Şekil-11: Malign adneksiyel kitle MRI örneği

Şekil-12: Nesne Tanıma Algoritması

Şekil-13: Derin Öğrenme ve Makine Öğrenmesi Şemaları

Şekil-14: Evrişimli sinir ağları mimarisi

Şekil-15: MRG'den elde edilmiş 8 adet farklı sekanstaki fotoğraf karesi örneği

Şekil-16: Gruplar arasındaki yaş dağılım grafiği

Şekil-17: Gruplar arasındaki kitle boyutu dağılım grafiği

Şekil-18: EfficientNetV2B0 modeli hata matrisleri şeması

Şekil-19: EfficientNetV2B0 modeli ROC eğrileri grafiği

Şekil-20: MobilenetV2 modeli hata matrisleri şeması

Şekil- 21: MobilenetV2 modeli ROC eğrileri grafiği

Şekil-22: DenseNet121 modeli hata matrisleri şeması

Şekil-23: DenseNet121 modeli ROC eğrileri grafiği

Şekil-24: InceptionV3 modeli hata matrisleri şeması

Şekil-25: InceptionV3 modeli ROC eğrileri grafiği

Şekil-26: InceptionResNetV2 modeli hata matrisleri şeması

Şekil-27: InceptionResNetV2 modeli ROC eğrileri grafiği

KISALTMALAR

ACR: The American College of Radiology

AI: Artificial Intelligence

AUK: Anormal Uterin Kanama

AUC: The Area Under the Curve

BRCA1: Breast Cancer Susceptibility 1

BRCA2: Breast Cancer Susceptibility 2

BT: Bilgisayarlı Tomografi

CA: Cancer Antigen

CNN: Convolutional Neural Network

DKB: Dual Kernel Bloğu

DL: Deep Learning

DWI: Diffusion-weighted Imaging

EOC: Epithelial Ovarian Cancer

FN: False Negative

FP: False Positive

hCG: human Chorionic Gonadotropin

HE4: Human Epididymis protein 4

HGSC: High-grade Serous Carcinoma

LGSC: Low-grade Serous Carcinoma

MRG: Manyetik Rezonans Görüntüleme

MRI: Magnetic Resonance Imaging

O-RADS: Ovarian-Adnexal Reporting and Data System

PET: Pozitron Emisyon Tomografisi

PID: Pelvic Inflammatory Disease

PKOS: Polikistik Over Sendromu

PPD: Pozitif Prediktif Değer

ROC: Receiver Operating Characteristic

TAH-BSO: Total Abdominal Histerektomi + Bilateral Salpingooferektomi

TN: True Negative

TOA: Tubo-ovaryan Apse

TP: True Positive

US: Ultrasonografi

YZ: Yapay Zeka

ÖZET

GİRİŞ VE AMAÇ: Jinekolojik maligniteler arasında en agresif seyirli olanı over kanseridir. Borderline tümörler ise invaziv ve yıkıcı bir büyüme göstermemeleri nedeniyle fertilite koruyucu cerrahinin uygun bir seçenek olabileceği özgün bir grubu oluşturur. Bu nedenle adneksiyel kitlelerin malignite potansiyelinin doğru bir şekilde öngörülmesi klinik açıdan büyük önem taşımaktadır. Çalışmamızda epitelyal over tümörlerinin manyetik rezonans görüntülerinin (MRG) yapay zekâ tabanlı derin öğrenme modelleri ile analiz edilerek malignite potansiyelinin belirlenmesi ve cerrahi planlamaya katkısının araştırılması amaçlanmıştır.

GEREÇ VE YÖNTEM: Ocak 2010-Ocak 2025 tarihleri arasında Kanuni Sultan Süleyman Eğitim ve Araştırma Hastanesi Jinekolojik Onkoloji Cerrahisi Kliniğinde adneksiyel kitle nedeniyle opere edilen ve patoloji sonucu malign, borderline veya benign epitelyal over tümörü olarak raporlanan, preoperatif MRG verileri mevcut olan hastalar retrospektif olarak incelendi. Toplam 362 hastaya ait 2896 MRG kesiti analiz edildi. Görüntü sınıflandırması amacıyla beş farklı yapay zekâ tabanlı derin öğrenme modeli kullanıldı.

BULGULAR: Çalışmaya 100 benign, 100 malign, 62 borderline tümörlü hasta ile kontrol grubu olarak 100 normal olgu dahil edildi. Borderline tümör grubunda medyan yaş, malign ve benign gruplara göre anlamlı olarak daha düşük bulundu (sırasıyla $p<0,001$ ve $p=0,012$).Tüm evrişimli sinir ağı (CNN) modelleri birbiri ile kıyaslandığında EfficientNetV2B0 modeli, test kümesinde %74,55'lik bir doğruluk, %74,01'lik bir kesinlik, %73,53'lik kesinlik ve duyarlılık arasındaki dengeyi gösteren F-skoru değeri ile en iyi performansı gösterdi.

SONUÇLAR: Çalışmamız, yapay zekâ destekli MRG analizlerinin adneksiyel kitlelerin malignite potansiyelini öngörmede ve cerrahi planlamada umut verici bir araç olabileceğini ortaya koymuştur. Bununla birlikte, nadir görülen veya tanısal olarak karmaşık tümör alt tiplerinde performansın artırılması için daha geniş ve çok merkezli çalışmalara ihtiyaç vardır.

ANAHTAR KELİMELER: adneksiyel kitleler, manyetik rezonans görüntüleme, makine öğrenmesi, yapay zeka, over kanseri

ABSTRACT

INTRODUCTION AND AIM: Ovarian cancer is the most aggressive among gynecological malignancies. Borderline tumors, however, do not exhibit invasive or destructive growth, forming a unique group where fertility-sparing surgery can be a suitable option. Therefore, accurate prediction of the malignancy potential of adnexal masses is of great clinical importance. In our study, we aimed to analyze magnetic resonance imaging (MRI) of epithelial ovarian tumors using artificial intelligence-based deep learning models to determine their malignancy potential and investigate their contribution to surgical planning.

MATERIAL AND METHODS: Patients who underwent surgery for an adnexal mass at the Kanuni Sultan Süleyman Training and Research Hospital's Gynaecological Oncology Surgery Clinic between January 2010 and January 2025 were retrospectively reviewed. The patients included in the study had pathology reports confirming a malignant, borderline, or benign epithelial ovarian tumour and had available preoperative MRI data. A total of 2896 MRI sections from 362 patients were analyzed. Five different AI-based deep learning models were used for image classification.

RESULTS: The study included 100 patients with benign tumors, 100 with malignant tumors, 62 with borderline tumors, and 100 normal cases as a control group. The median age in the borderline tumor group was found to be significantly lower than in the malignant and benign groups ($p<0.001$ and $p=0.012$, respectively). When all Convolutional Neural Network (CNN) models were compared, the EfficientNetV2B0 model demonstrated the best performance in the test set with an accuracy of 74.55%, a precision of 74.01%, and an F-score of 73.53%, which indicates a balance between precision and recall.

CONCLUSIONS: Our study has demonstrated that AI-supported MRI analysis can be a promising tool for predicting the malignancy potential of adnexal masses and for surgical planning. However, larger, multi-center studies are needed to improve performance, particularly for rare or diagnostically complex tumor subtypes.

KEYWORDS: adnexal masses, magnetic resonance imaging, machine learning, artificial intelligence, ovarian cancer

1. GİRİŞ VE AMAÇ

Adneksiyel kitleler; yumurtalık, fallop tüpleri veya çevre bağ dokusunda ortaya çıkan kistik ya da solid yapılar olup kadınlarda sık görülen jinekolojik durumlardan biridir. Her yaş grubunda ortaya çıkabilen bu kitleler, çoğunlukla asemptomatik seyretmekle birlikte bazı olgularda ağrıya veya bası semptomlarına yol açabilirler (1). Adneksiyel kitlelerin değerlendirilmesindeki temel amaç, kitlenin benign, malign veya borderline özellikte olup olmadığının ayırt edilmesi ve acil tıbbi/cerrahi müdahale gerektiren durumların (örneğin ektopik gebelik veya over torsiyonu) dışlanmasıdır.

Jinekolojik maligniteler arasında en agresif seyirli olanı over kanseridir. Over kanseri tedavisinde evresine göre radikal cerrahi ve adjuvan kemoterapi önerilmektedir. Borderline tümörler ise invaziv olmayan, daha sınırlı büyüme paterni göstermeleri nedeniyle fertilite koruyucu cerrahinin uygulanabileceği özel bir grup oluşturmaktadır. Bu nedenle adneksiyel kitlelerin malignite potansiyelinin doğru şekilde öngörülmesi, tedavi yaklaşımının belirlenmesinde kritik öneme sahiptir.

Adneksiyel kitlelerin ilk basamak görüntüleme yöntemi ultrasonografi (US) olmakla birlikte, manyetik rezonans görüntüleme (MRG) özellikle US ile karakterizasyonu güç olan lezyonlarda ikinci basamak inceleme olarak öne çıkmaktadır. US'ye kıyasla daha yüksek özgüllüğe sahip olan MRG, malignite için yanlış pozitif tanıları azaltarak benign veya borderline tümörlerde gereksiz/çok geniş kapsamlı cerrahilerin önüne geçebilirken, malignite olasılığı yüksek olguların hızla onkolojik cerrahiye yönlendirilmesine katkı sağlamaktadır. Günümüzde jinekoloji alanında MRG, adneksiyel lezyon sınıflandırması için cerrahi dışı referans standart olarak kabul edilmekte ve özellikle fertilite koruyucu cerrahi planlanan hastalarda önemli bir rol oynamaktadır. Ancak MRG'nin doğru yorumlanması ileri düzey uzmanlık gerektirmektedir.

Yapay zekâ (YZ), makinelerin insan zekâsını taklit ederek görevleri bağımsız biçimde yerine getirme kapasitesi olarak tanımlanır. Makine öğrenmesi ise YZ'nin bir alt alanı olup otomatik görüntü analizinde öne çıkan en güncel yöntemlerden biridir. Makine öğrenmesi sayesinde insan gözünün ayırt edemeyeceği ince doku özellikleri saptanabilmektedir. Literatürde, adneksiyel kitlelerin tanısında makine öğrenmesi yöntemlerinin kullanılabileceğine dair çeşitli raporlar bulunmaktadır. Ancak mevcut çalışmaların büyük kısmı yalnızca benign ve malign

ayrımı üzerine odaklanmış, borderline tümörlerin ayırt edilmesi veya benign kitlelerin ayrıntılı histopatolojik alt tiplerinin sınıflandırılması yeterince çalışılmamıştır.

Bu çalışmada amacımız, epitelyal over tümörlerinin MRG görüntülerini derin öğrenme tabanlı yapay zekâ modelleri ile değerlendirerek malignite potansiyelini öngörmek ve cerrahi planlamaya katkı sağlamaktır.

2. GENEL BİLGİLER

2.1 ADNEKSİYEL KİTLELERİN ETİYOLOJİSİ

Anatomik olarak adneksiyel kitlelerin büyük kısmı yumurtalık veya fallop tüplerinden kaynaklanmaktadır. Bunun dışında adneksiyel bölgede yer alan diğer jinekolojik yapılar (örneğin mezovaryum ve mezosalpinks) de kitle oluşumuna neden olabilir; paratubal kistler buna örnek olarak verilebilir. Adneksiyel kitleler yalnızca jinekolojik yapılardan değil, komşu organlardan köken alan jinekolojik olmayan patolojilerden de kaynaklanabilir. Bu tür kitleler, adneksiyel kitle olarak palpe edilebilir veya görüntülemede adneksiyel kökenli izlenebilir; bu kitleler uterustan (leiomyomlar), üriner sistemden (mesane divertikülü), bağırsaktan (apandiks apsesi, divertiküler apse, bağırsak neoplazmı), pelvik bağ dokusundan (peritoneal kist) ve sinirlerden (sinir kılıfı tümörü) köken alabilir. Adneksiyel kitleler çok geniş bir etiyolojik spektrumda yer almakta olup, bu çeşitlilik klinik yaklaşım ve tedavi planlamasında güçlükler yaratmaktadır. Çeşitli adneksiyel kitle türleri Tablo 1'de özetlenmiştir.

Jinekolojik: Ovaryan	**Jinekolojik: Tubal**	**Jinekolojik: Ekstraovaryan ve ekstratubal**	**Jinekolojik olmayan**
Benign			
-Fonksiyonel (fizyolojik) kist -Korpus luteal kist -Gebelik luteoması -Teka lutein kisti -Polikistik overler -Endometrioma -Kistadenom -İyi huylu over germ hücreli tümörü (örneğin, matür teratom) -İyi huylu seks kord stromal tümörü	-Ektopik gebelik -Hidrosalpinks	-Paraovaryan kist -Paratubal kist -Uterin miyom (saplı veya servikal) -Tubo-ovaryan apse	-Kabızlık -Apendiks apsesi -Divertikül apsesi -Pelvik apse -Mesane divertikülü -Üreter divertikülü -Pelvik böbrek -Peritoneal kist -Sinir kılıfı tümörü

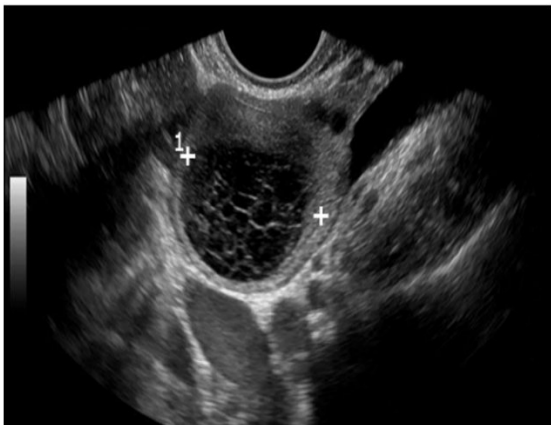
Malign veya borderline			
-Epitelyal karsinom -Epitelyal borderline neoplazm -Malign over germ hücreli tümör -Malign seks kord-stromal tümör	-Epitelyal karsinom -Seröz tubal intraepitelyal neoplazi	-Metastatik endometriyal karsinom - Kistadenokarsinom (nadir)	-Apendiks neoplazmı -Bağırsak neoplazmı -Metastaz (örneğin meme, kolon, lenfoma) -Retroperitoneal sarkom

Tablo-1: Adneksiyal kitlenin ayırıcı tanısı

Adneksiyel kitleler fizyolojik (normal ovülasyon sürecinin doğal bir bileşeni) veya patolojik kökenli olabilir. Premenopozal kadınlarda adneksiyel kitlelerin en sık nedeni, normal ovülatuar fizyolojik süreçtir. Bu nedenle, normal menstrual döngü fizyolojisinin anlaşılması ve sonografide fizyolojik adneksiyel kitle ile uyumlu özelliklerin tanımlanabilmesi (Şekil 1 ve Şekil 2), kitlelerin "neredeyse kesinlikle benign" olarak sınıflandırılabilmesi açısından kritik öneme sahiptir.



Şekil-1: Normal folikül



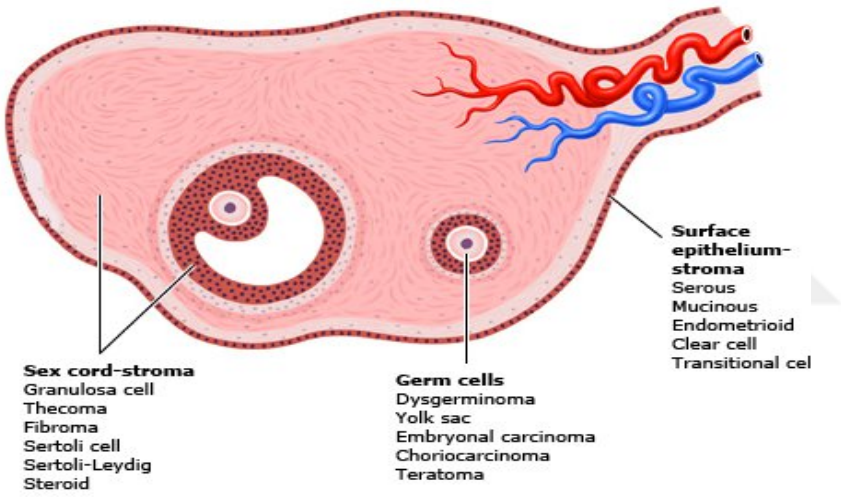
Şekil-2: Hemorajik over kisti

Postmenopozal hastalarda da nonpatolojik over kistleri rutin olarak saptanabilmektedir. Bu durum, söz konusu kistlerin yalnızca premenopozal döneme özgü olmadığını göstermektedir (2). Çoğu olguda bu kistler, anovülatuar döngüden kalan fizyolojik foliküllerı temsil ederken, bazı durumlarda sporadik ovülasyona bağlı olarak gelişebilmekte (3) veya küçük kistadenomları yansıtabilmektedir. Sporadik ovülasyondan kaynaklanan fizyolojik foliküllerin,

son adet döneminden sonra geçen sürenin artmasıyla birlikte daha az yaygın hale geldiği ve çaplarının giderek küçüldüğü bildirilmektedir.

2.2 ADNEKSİYEL KİTLELERİN HİSTOLOJİSİ

Over, çeşitli doku tiplerini içerir. En yaygın neoplazmlar epitelyal olanlardır. Bunlar, normalde fallop tüpü epiteline (çoğu yüksek dereceli seröz karsinom) veya over yüzey epiteline ve inklüzyonlara (örn. kistadenomlar) yol açacak olan kök hücrelerden türemiştir. Over germ hücreli tümörleri, overin primordial germ hücrelerinden (şekil-3) köken alır. Over seks kord-stromal tümörleri ise normalde destekleyici epitelyal hücrelere, over stromasına (örn. fibromlar) ve foliküllere (örn. granüloza hücreli tümörler, Sertoli-Leydig hücreli tümörler) yol açacak olan kök hücrelerden türemiştir.



Şekil-3: Overyen tümörlerin kökenleri

Fallop tüpleri, dışta uzunlamasına düz kas liflerinden oluşan bir musküler tabakaya ve içte dairesel liflerden oluşan bir iç tabakaya sahiptir. Fallop tüpü mukozası, üç tip hücreden oluşan çok sayıda narin, papiller katlantıdan (plika) meydana gelir: silyalı kolumnar hücreler; silyasız, kolumnar salgı hücreleri, ve muhtemelen inaktif salgı hücreleri olan interkale hücreler (4).

2.3 ADNEKSİYEL KİTLELER

2.3.1 JİNEKOLOJİK ADNEKSİYEL KİTLELER

Adneksiyel kitlelerin birçok farklı tipi bulunmaktadır. Bir adneksiyel kitlenin olası etiyolojisi, yaşa ve üreme durumuna göre farklılık gösterir. Bunun nedeni, bazı kitlelerin üreme hormonları tarafından uyarılmasıdır.

Foliküler over kistleri fetuslarda yaygın olup, gebelik yaşı ilerledikçe ve bazı maternal komplikasyonlarla (örn. diabetes mellitus, preeklampsi, Rh izoimmünizasyonu) birlikte sıklığı artar.

Yenidoğanda saptanan bir pelvik kitlenin en olası nedeni, anne hormonal uyarımına bağlı olarak anne karnında (in utero) gelişen fizyolojik bir kisttir. Fetuslarda veya yenidoğanlarda intra-abdominal kitlelerin ayırıcı tanısı, genitoüriner sistem bozukluklarını (örn. üreme sistemi anomalileri, üriner sistem obstrüksiyonu, urakal kist), gastrointestinal sistem bozukluklarını (örn. mezenterik veya omental kist, volvulus, kolon atrezisi, intestinal duplikasyon) veya çeşitli diğer bozuklukları (örn. koledok, dalak veya pankreas kisti, lenfanjiom) içerir.

Yenidoğan dönemi ile ergenlik arasında fizyolojik kistler nadirdir, çünkü gonadotropinlerin yumurtalıkları uyarması bebeklik ve erken çocukluk döneminde azalır, ardından ergenlikte tekrar artar. Buna rağmen, çocuklardaki basit over kistlerinin çoğu fizyolojiktir ve kistik bir folikülün büyümesi sonucu oluşur.

Menarş ile 18 yaş arası dönemde, olgunlaşmamış hipotalamus-hipofiz-yumurtalık aksı nedeniyle ovülatuar disfonksiyon yaygındır. Ergenlik dönemindeki yumurtalıklar, gelişimlerinin farklı aşamalarındaki çok sayıda folikülü ve uniloküler kistleri (olgunlaşan folikülün ovülasyon ve involüsyona uğrayamamasından kaynaklanan) ve hemorajik kistleri içerebilir. Bu disfonksiyonel foliküller genellikle kendiliğinden düzelir ve çoğunlukla klinik olarak önemsizdir.

Over neoplazmları (benign ve malign), çocuk ve ergenlerdeki tüm tümörlerin yaklaşık %1'ini oluşturmaktadır. Over kitlelerinin çoğu fizyolojik veya benign neoplazmlardır; over kanserlerinin %5'inden azı bu yaş grubunda görülmektedir.

Over kanseri, 25 yaş ve altı hastalarda en sık görülen jinekolojik malignitedir ve en yaygın histoloji germ hücreli tümörlerdir (5). Germ hücreli tümörleri, 18 yaşa kadar olan hastalarda over neoplazmlarının yarısından üçte ikisine tekabül ederken, yetişkin hastalarda bu

oran %20'dir. Dokuz yaşın altındaki hastalarda, over neoplazmlarının yaklaşık %80'i malign özelliktedir. Epitelyal neoplazmlar prepubertal yaş grubunda nadir görülür.

Üreme çağındaki hastalarda adneksiyel kitleler için geniş bir ayırıcı tanı yelpazesi bulunmaktadır. Üreme hormonları tarafından uyarılan adneksiyel kitleler neredeyse sadece bu yaş grubunda görülür. Bunlar arasında fizyolojik kistler, endometriomalar ve leiomyomlar yer alır. Over veya tuba malign neoplazmları bu yaş grubunda nadir olsa da, over germ hücreli tümörleri için en sık görülme yaşı 10 ile 30 yaş arasıdır.

Üreme çağındaki hastalarda, üreme hormonları ile ilişkili adneksiyel kitleler, adet döngüsünün bazı yönlerinden kaynaklananları içerir:

- Fonksiyonel/fizyolojik kistler
- Korpus luteum kisti
- Tekalutein kisti

Üreme hormonları tarafından uyarılan diğer kitle türleri şunlardır:

- Endometrioma
- Uterin leiomyom

Premenopozal hastalar, benign veya malign neoplastik adneksiyel kitleler geliştirebilir. Bunlar en sık yumurtalıkta olmak üzere, fallop tüpünde de gelişebilirler.

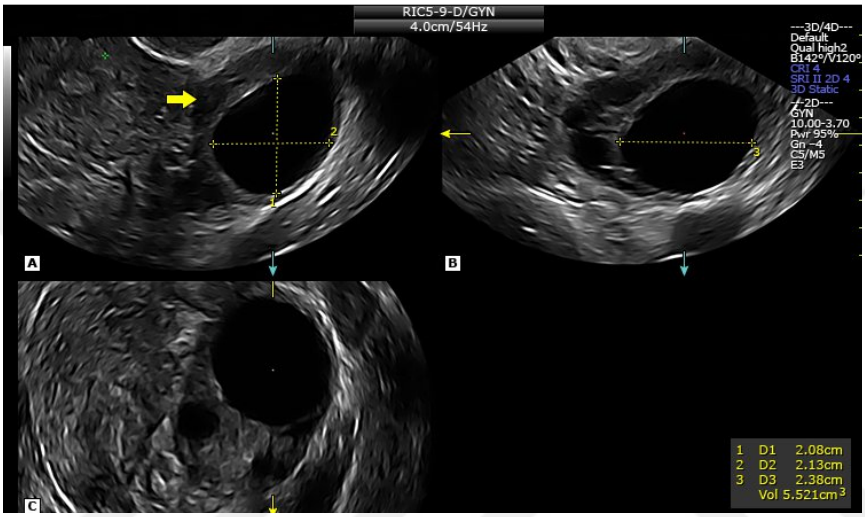
2.3.1.1. Ovulatuar Adneksiyel Kitleler

Normal veya anormal ovülatuar fonksiyon ile ilişkili bazı adneksiyel kitleler bulunmaktadır.

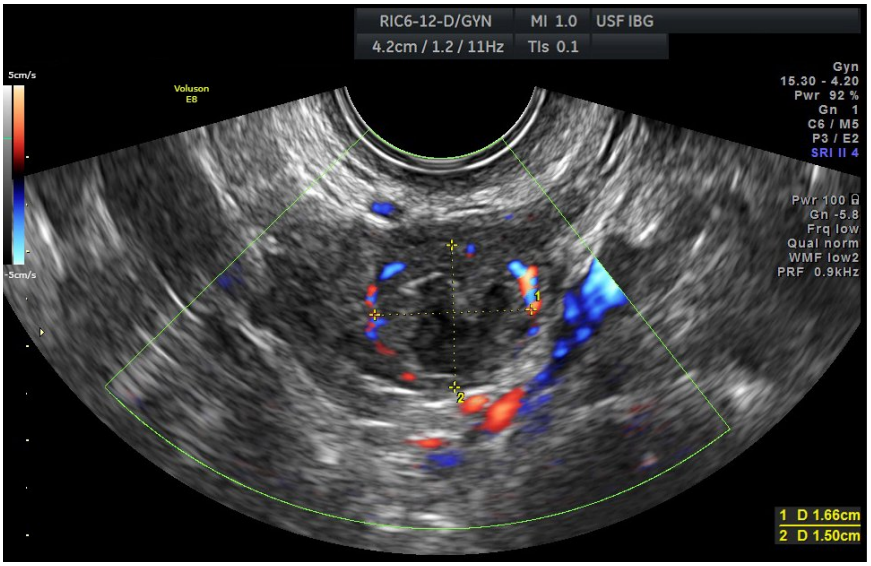
- **Fonksiyonel veya korpus luteal kistler:** Normal ovülasyon sürecinde, bir folikül olgunlaşır ve ardından bir ovumu (yumurta hücresini) serbest bırakmak için çatlar; bunu, korpus luteumun oluşumu ve sonrasında involüsyonu (gerilemesi) takip eder.

Foliküler kistler (aynı zamanda fizyolojik kistler olarak da adlandırılır), yırtılma olmadığında ve folikül büyümeye devam ettiğinde oluşur. Korpus luteum kistleri ise, korpus luteumun involüsyona uğramayıp ovülasyon sonrası büyümeye devam etmesiyle ortaya çıkar (korpus luteum gebeliğin ilk altı haftasında büyür ve gebelik öncesi boyutunun iki katına ulaşır (6)). Bu nedenle bu kistlere fizyolojik veya fonksiyonel denir. Her iki tip de hemorajik hale gelebilir.

Foliküler kistler ultrasonografik incelemede pürüzsüz, ince duvarlı ve uniloküler (şekil 4) görünürken, korpus luteum kistleri kompleks bir yapıya sahip olabilir ve makroskopik olarak sarı renktedir (şekil 5). Çapı 3 cm'den küçük uniloküler kistler normal folikül olarak kabul edilir. Fizyolojik veya foliküler kistler oldukça büyüyebilse de, genellikle 10 cm'den küçüktür. Amerikan Radyoloji Koleji'nin Over-Adneksiyal Raporlama ve Veri Sistemi (O-RADS), hangi kistlerin takip edilmesi gerektiğini ve hangilerinin göz ardı edilebileceğini belirlemeye yardımcı olan bir risk sınıflandırma ve yönetim sistemidir (7).



Şekil-4: Ultrasonda ovarian folikül



Şekil-5: Ultrasonda ovarian korpus luteum

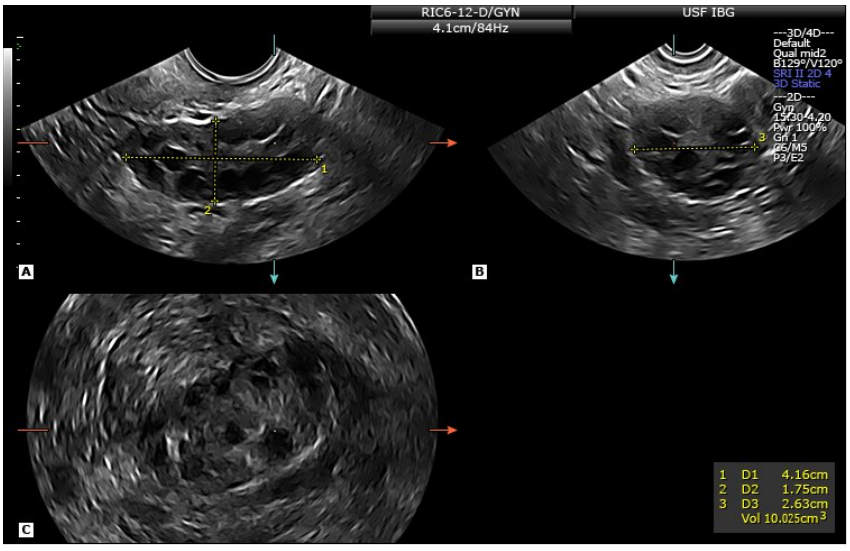
Normal adet döngüsündeki korpus luteum kistleri, ultrasonografide çeşitli görünümlere sahip olabilir. Bu kistler unilokülerdir ve içlerinde enkaz (hemoraji) ile kalın duvarlar içerebilir. Ayrıca 8 cm'ye kadar büyüyebilirler, ancak genellikle kendiliğinden gerilerler (8).

- **Teka lutein kistleri:** Teka lutein kistleri (ayrıca lutein kistleri veya hiperreaktio luteinalis olarak da adlandırılır), yüksek insan koryonik gonadotropin (hCG) seviyelerinden veya hCG'ye karşı aşırı duyarlılıktan kaynaklanan aşırı uyarılma sonucunda oluşan luteinize folikül kistleridir.

Gestasyonel trofoblastik hastalığı, çoğul gebeliği, over hiperstimülasyonu veya fetal hidropsun eşlik ettiği bir gebeliği olan bir hastada görülen bilateral multiseptalı kistik adneksiyel kitlelerin, malign neoplazmlardan ziyade tekalutein kistleri olması muhtemeldir. Bu kist tipi, normal hCG seviyelerine karşı aşırı duyarlılık nedeniyle normal bir gebelikte de oluşabilir.

Çoğu teka lutein kisti asemptomatiktir ancak maternal virilizasyon, hiperemezis gravidarum, preeklampsi veya tiroid disfonksiyonu meydana gelebilir. Kistler, hCG kaynağı ortadan kalktıktan sonra haftalar veya aylar içinde kademeli olarak geriler.

- **Polikistik overler:** Polikistik over sendromu (PKOS), bazı hastalarda çok sayıda küçük periferik folikül içeren büyümüş overlerle sonuçlanır (şekil 6). Overler büyümüş olmasına rağmen, PKOS'lu hastalar nadiren bir adneksiyel kitle ile başvurur.



Şekil-6: Ultrasonda polikistik over

PKOS'un klasik fenotipi, obez, hirsut ve anovülatuar olan bir hastadır. Ultrasonografide görüntülenen polikistik over morfolojisi, antral folikül sayısının >20 olması ve/veya en az bir

overde artmış over hacminin (>10 mL, 0.5 x uzunluk x genişlik x kalınlık formülü kullanılarak hesaplanır) bulunmasıdır. Tipik olarak, overin periferinde çok sayıda küçük folikül (2 ila 9 mm) ve artmış santral stroma da görülür.

Polikistik over sendromu (PKOS), anormal uterin kanama, infertilite, insülin direnci, obezite ve hirsutizm gibi durumları yönetmek amacıyla tedavi edilir. Polikistik overlerin kendisi ise tedavi gerektirmez.

2.3.1.2 Gebelik İle İlgili Adneksiyel Kitleler

- **Gebeliğin korpus luteumu:** Erken dönem bir rahim içi gebelik her zaman korpus luteum kisti ile ilişkilidir.

- **Luteoma:** Luteoma, gebelikle ilişkili non-neoplastik bir over kitlesidir; temel olarak, kistik olmaktan ziyade solid bir korpus luteumdur. Luteomalar bazen klinik, makroskopik veya mikroskobik incelemede bir neoplazm ile karıştırılabilir (9). Luteomalar doğum sonrası kendiliğinden geriler. Tanı, solid bir adneksiyel kitle ve maternal hirsutizm veya virilizm varlığında şüphelenilmelidir.

- **Endometriomanın desidualizasyonu:** Gebelik sırasında endometriomalar desidualize olabilir. Bu durum, solid bir elemanın ve kan akımının (flow) varlığı nedeniyle malign bir kitle şüphesi uyandırabilir. Bu değişiklikler gebelik sonrası düzelir.

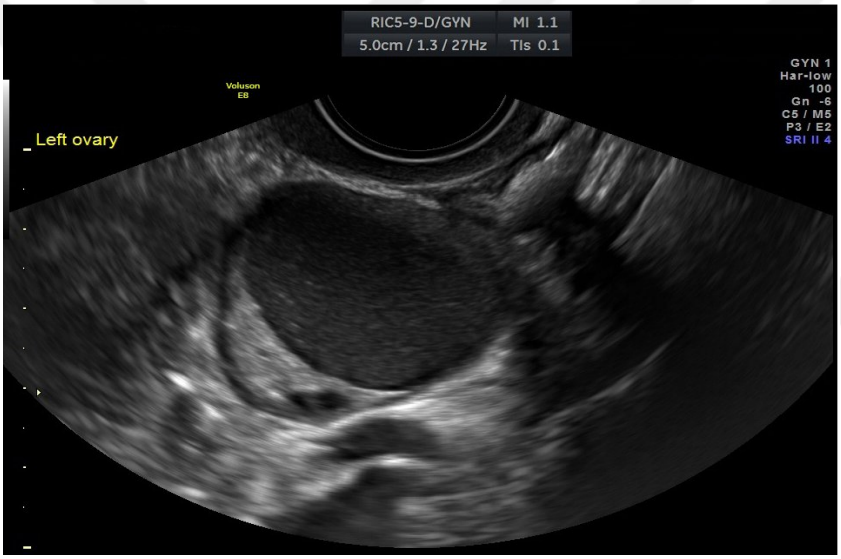
- **Ektopik gebelik:** Ektopik gebelik, pelvik muayene veya ultrasonda saptanan bir adneksiyel kitle olarak ortaya çıkabilir. Ektopik gebeliği düşündüren belirti ve semptomlar arasında adet gecikmesi öyküsü, karın-pelvis ağrısı ve vajinal kanama bulunur. Ektopik gebelik potansiyel olarak hayatı tehdit edici bir durumdur ve olası ektopik gebeliği olan her hasta derhal değerlendirilmelidir.

2.3.1.3 Üreme Hormonları Tarafından Uyarılan Adneksiyel Kitleler

Üreme hormonları tarafından uyarılan adneksiyel kitleler, menopoz sonrası genellikle gerileyerek asemptomatik hale gelir.

- **Endometrioma:** Endometrioma, ektopik endometrium dokusunun büyümesinden kaynaklanan, adneksiyel kitlelerin benign bir nedenidir.

Endometriozisi olan hastalar genellikle pelvik ağrı, dismenore ve disparoni yaşar. Bir endometrioma veya "çikolata kisti", ultrasonda tipik olarak homojen iç ekolar içeren, uniloküler veya multiloküler kistik bir kitle olarak görülür. Endometriomanın ultrason görünümü, sıklıkla "buzlu cam" (ground glass) iç ekoları içermesi olarak tanımlanır (şekil 7). Kistin içinde bulunan çikolata renkli sıvı veya eski kan, klasik bir görünüme sahiptir.



Şekil-7: Ultrasonda yumurtalık endometrioması

- **Leiomyoma:** Bir leiomyom (fibroid), genellikle uterustan kaynaklanan ancak broad ligamentte de bulunabilen, düz kas kökenli benign bir neoplazmdır.

Bunlar, kadınlarda en sık görülen pelvik neoplazmlardır ve semptomatik fibroidleri olan hastaların çoğu 30'lu veya 40'lı yaşlardadır.

Leiomyomun boyutuna ve konumuna bağlı olarak, hastalar genellikle pelvik basınç, ağrı, yoğun adet kanaması ve/veya dismenore şikayetleriyle başvurur. Fizik muayenede genellikle büyümüş, düzensiz şekilli bir uterus saptanır ve ultrason incelemesinde bu durum solid bir uterin tümör veya tümörler olarak görülür.

Uterusun arka kısmından kaynaklanan ve Douglas boşluğuna (pouch of Douglas) doğru uzanan veya fundustan pedinküllü bir kitle olarak çıkan bir fibroid, bir over neoplazmı ile karıştırılabilir. Bir fibroidin kistik dejenerasyonu, ultrasonografide fibroidin içinde sıvı dolu bir merkez görünümüne yol açabilir. Bu durum, fibroidlerin serum kanserojen antijen 125 (CA 125) konsantrasyonunu yükseltebilmesiyle birleşince, kitlenin malign bir over neoplazmı olabileceği endişesini daha da artırır. Transvajinal görüntüleme, adneksteki bir leiomyomu solid bir over tümöründen ayırt etmek için anahtar rol oynar. Öncelikle, yumurtalığın sağlam, normal ve leiomyomdan tamamen ayrı olduğu görülmelidir. Ayrıca, doppler akım incelemesi, uterus ile pedinküllü leiomyom arasındaki vasküler bağlantıyı görüntülemek için kullanılabilir.

2.3.1.4. Enfeksiyöz ve İnflamatuar Adneksiyel Kitleler

- **Tubo-ovaryan abse:** Tubo-ovaryan apse (TOA), fallop tüpü, yumurtalık ve nadiren diğer komşu pelvik organları (örneğin, bağırsak, mesane) etkileyen enflamatuvar bir kitledir. Bu durum, bir tubo-ovaryan kompleks (bu yapıların birbirine yapışması) veya bir apse koleksiyonu (TOA) şeklinde kendini gösterebilir. Bu apseler en sık üreme çağındaki hastalarda görülür ve genellikle üst genital sistem enfeksiyonunun bir sonucu olarak ortaya çıkar. TOA, genellikle pelvik enflamatuvar hastalığın (PID) bir komplikasyonudur.

Karın-pelvis ağrısı, ateş, pürülan servikal akıntı ve servikal hareket duyarlılığı bulgularının bir adneksiyel kitle ile birlikte görülmesi, tubo-ovaryan apse (TOA) tanısını düşündürmektedir.

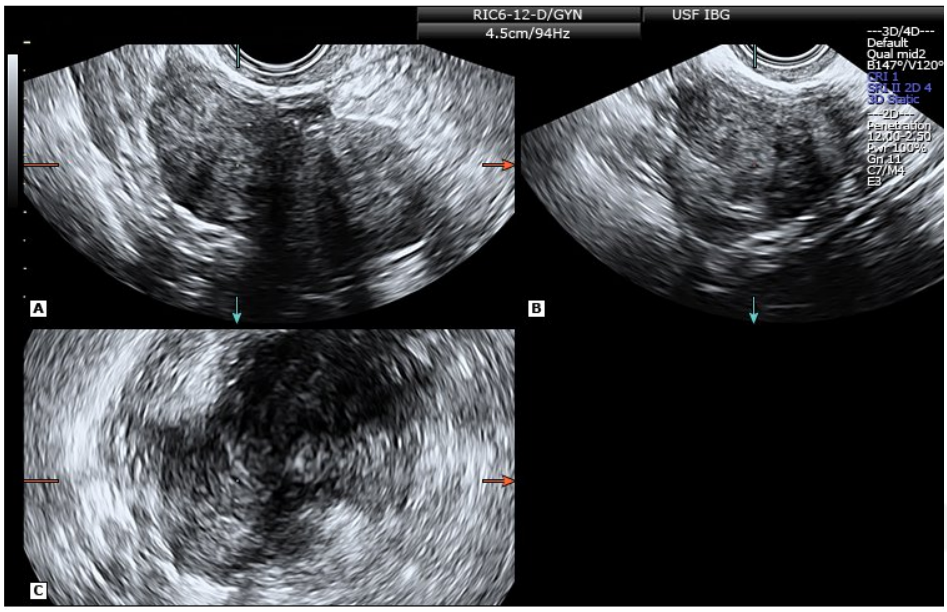
- **Hidrosalpenks:** Tedavi edilmemiş veya yetersiz tedavi edilmiş Pelvik Enflamatuvar Hastalık (PID) olguları, tüp fimbrialarında skarlaşmaya veya "topuzlanmaya" neden olur. Bu durum, sırasıyla hidrosalpenks veya piyosalpenks ile sonuçlanan, tüp salgılarının veya apsenin birikmesine yol açar.

Akut enfeksiyon düzeldiğinde, hidrosalpenks kalıcı olabilir. Tüp fonksiyonu genellikle bozulmuştur ve bu durum infertiliteye katkıda bulunabilir.

Overe komşu, dilate ve tübüler bir kistik yapı görüldüğünde hidrosalpenks düşünülmelidir. Hidrosalpenksler genellikle tamamlanmamış septasyonlara (bölmelere) sahiptir. Kesitsel düzlemler kullanılarak yapılan üç boyutlu ultrasonografi, hidrosalpenksi görsel olarak yeniden yapılandırmak için faydalıdır. Lümen içeriği serözden (hidrosalpenks) kanlıya (hematosalpenks) veya irinliye (piyosalpenks) doğru değişiklik gösterebilir.

2.3.1.5. Benign Neoplazmlı Adneksiyel Kitleler

Over/tuba neoplazmları, tipik olarak yüzey epiteli, fallop tüpü epiteli, germ hücreleri veya seks kord-stromal hücrelerine yol açan kök hücrelerden kaynaklanabilir (şekil 8). Üreme çağındaki hastalarda en sık görülen benign over neoplazm tipleri, sırasıyla matür kistik teratom (dermoid kist), seröz kistadenom ve müsinöz kistadenomdur (10). Matür kistik teratomlar, bir germ hücreli tümör tipidir; bu over neoplazmları en sık 10 ila 30 yaş arası hastalarda görülür (11).



Şekil-8: Ultrasonda yumurtalık fibrotekomu

- **Seröz veya müsinöz kistadenom:** Seröz ve müsinöz kistadenomlar, en sık görülen benign over neoplazmları arasındadır. Bunlar ince duvarlı, uni- veya multilokülerdir ve boyutları 5 ila 20 cm arasında değişir.

Seröz kistadenomlara kıyasla, müsinöz kistadenomlar daha az sıklıkta görülür, multiloküle olma olasılıkları daha yüksektir, daha büyüktürler (çok büyük boyutlara ulaşabilirler) ve bilateral olma oranları daha düşüktür (%5'ten az, seröz kistadenomda ise %20 ila %25) (tablo 2). Kesin tanı, kistleri çevreleyen hücre tipini belirlemek için patolojik değerlendirmeye bağlıdır.

Ovarian tümör histolojisi (Dünya Sağlık Örgütü sınıflandırması)	Bilateralitenin görülme sıklığı (yaklaşık %)
Seröz kistadenom	12 to 23
Seröz borderline tümör	55
Seröz karsinom	60
Müsinöz kistadenom	5
Müsinöz borderline tümör	5
Müsinöz karsinom	5
Matür kistik teratom (dermoid)	15
Disgerminoma	15
Diğer malign germ hücreli tümörler	1
Granüloza-stroma hücre tümörü	5
Sekonder tümörler	70

Tablo-2: Yumurtalık neoplazmlarının bilateralitesi (12)

Bu tümörlerin birçoğu asemptomatiktir ve pelvik muayene veya ultrason sırasında tesadüfen saptanır. Kitleler büyüdükçe, bası veya ağrıya, şişkinliğe ve üriner semptomlara neden olabilirler ve over torsiyonu ile başvurabilirler.

- **Matür kistik teratom:** Matür kistik teratom (dermoid kist), benign bir germ hücreli tümördür ve yaşamın ikinci ve üçüncü dekatlarında en sık görülen over neoplazmıdır (11). Matür teratomlar, her üç germ hücre tabakasına (ektodermal, mezodermal ve endodermal) ait farklılaşmış elementleri içerebilir: ektodermal kökenli (örn. deri, kıl folikülleri, sebase bezler), mezodermal kökenli (örn. kas, üriner sistem) ve endodermal kökenli (örn. akciğer, gastrointestinal sistem).

Transvajinal ultrasonografi genellikle uniloküler kistik bir kitle ortaya koyar ve bu kitle, karma eko (mixed echogenicity) içeriği, hiperekoik çizgiler veya noktalar, sıvı ve akustik gölgelenme alanları içerebilir (13). Matür teratomlar, içerdikleri dokuya bağlı olarak çeşitli görünümlere sahip olabilir. Bu tümörler hastaların %10 ila %15'inde bilateraldir (14).

- **Endosalpingiozis:** Endosalpingiosis, fallop tüpü dışında, fallop tüpü tipi silyalı epitel ile kaplı, non-neoplastik, ektopik, kistik bezlerin varlığıdır (15). Endosalpingiozis, overler, fallop tüpü serozası, uterus serozası, miyometriyum veya pelvik periton dahil olmak üzere pelvik organlarda görülebilir. Ayrıca mesanede, retroperitoneal veya aksiller bir lenf nodunda da oluşabilir (16). Benzer müllerian inklüzyonlar daha az sıklıkla görülür ve müsinöz veya endometrioid epitel ile döşeli olabilir.

Nadir durumlarda, endosalpingiozis uterus serozasını veya mesane epitelini tutan, büyük, tümör benzeri kistik kitleler olarak kendini gösterir (17).

- **Paraovarian/paratubal kistler ve tubal ve broad ligament neoplazmaları:** Fallop tüpü veya broad ligamentinden kaynaklanan neoplazmlar) nadir görülür, ancak adneksteki yüksek dereceli seröz karsinomların çoğunun fallop tüplerinden kaynaklandığına inanılmaktadır. Tüpler ve broad ligamentler genellikle ultrason muayenesinde görüntülenmediğinden, bu tümörlerin kaynağı yanlışlıkla neoplazmlar için daha yaygın bölgeler olan yumurtalık veya uterusa atfedilebilir.

2.3.1.6 Malign Neoplazmlı Adneksiyel Kitleler

Premenopozal hastalarda adneksiyel kitleye sahip olanlarda over malign neoplazmlarının görülme sıklığı yaklaşık %1,5 ila %16 arasında değişmektedir (18). Birincil over neoplazmlarının çoğu kısmen kistiktir ve epitelyal hücrelerden köken alırken, aynı zamanda germ hücreleri, seks kord-stromal ve miks hücre tipleri gibi diğer hücre tiplerinden de kaynaklanabilir. Germ hücreli tümörler, 30 yaşın altındaki kadınlarda en sık görülen ikinci over neoplazm tipidir, ancak bu yaştan sonra nadir görülürler.

Over, jinekolojik sistem veya jinekolojik olmayan primer bölgelerde oluşan metastatik malign neoplazmlar tarafından da tutulabilir. Özellikle endometrium karsinomu, gastrointestinal sistem veya meme kanserinden kaynaklanan metastazlar, "Krukenberg tümörü" olarak adlandırılan tümörleri oluşturabilir.

Postmenopozal hastalarda adneksiyel kistlerin çoğu benign olmakla birlikte, ilerleyen yaşla birlikte over kanseri insidansı artmaktadır (19). Malign adneksiyel kitleler, primer over veya tüp kökenli olanların yanı sıra, diğer primer malign neoplazmlardan (örneğin, endometrial, meme veya gastrointestinal sistem) kaynaklanan metastatik lezyonları da içermektedir.

- **Epitelyal neoplazmlar:** Postmenopozal hastalarda benign veya borderline over epitelyal neoplazmları da görülebilir. Bunlar arasında seröz veya müsinöz kistadenomlar ya da seröz, müsinöz veya endometrioid borderline neoplazmlar yer alır.

Epitelyal karsinom, over, fallop tüpü ve periton kanserlerinin en sık görülen histolojik tipidir ve bu bölgelerdeki tüm kanserlerin %90'ını oluşturur (20). Over karsinomu geleneksel olarak tek bir antite olarak anılsa da, birden fazla histolojik alt tipe sahip heterojen bir neoplazm grubundan oluşmaktadır (21).

Histopatoloji, immünohistokimya ve moleküler genetik analizlere dayalı olarak, epitelyal over, fallop tüpü ve periton karsinomlarının sıklık sırasına göre azalan şekilde beş ana alt tipi şunlardır (21):

- Yüksek Dereceli Seröz Karsinom (HGSC)
- Endometrioid Karsinom
- Berrak Hücreli Karsinom (Clear Cell Carcinoma)
- Müsinöz Karsinom
- Düşük Dereceli Seröz Karsinom (LGSC)

Over, tüp veya periton karsinomu tanısı için ortalama yaş yaklaşık 60'tır. Hastalar genellikle dispepsi, erken doygunluk hissi, anoreksiya, kabızlık ve şişkinlik gibi belirsiz gastrointestinal semptomlarla başvururlar; bu nonspesifik yakınmalar ileri evre hastalıkla ilişkilidir. Fizik muayene bulguları arasında adneksiyel veya karın-pelvis kitlesi, asit ile birlikte karında gerginlik ve/veya plevral efüzyon yer alabilir.

- **Germ hücreli tümörler:** Ovaryen germ hücreli tümörleri, overin primordial germ hücrelerinden köken alır. Bunlar benign veya malign olabilir. Edindiğimiz tecrübeye göre, postmenopozal hastalarda en sık görülen germ hücreli tümör, bir teratomun malign dejenerasyonudur. Bu neoplazmlar, tüm over neoplazmlarının yaklaşık %20 ila %25'ini oluştururken, tüm malign over neoplazmlarının sadece yaklaşık %5'ini oluşturmaktadır (22). Over germ hücreli tümörleri esas olarak 10 ila 30 yaş arasındaki genç hastalarda ortaya çıkar ve bu yaş grubundaki over neoplazmlarının %70'ini temsil eder (23). Matür teratomlar bazen postmenopozal hastalarda görülse de, malign germ hücreli tümörleri postmenopozal yaş grubunda son derece nadirdir.

- **Seks kord-stromal tümörler:** Ovaryen seks kord-stromal tümörler, normalde oositleri çevreleyen hücrelere (gonadların germ hücreli olmayan ve epitelyal olmayan bileşenleri) yol açacak olan bölünen hücre popülasyonundan gelişen, benign veya malign neoplazmların heterojen bir grubudur (24). Bu neoplazmlar, tüm primer over kanserlerinin (malign neoplazmlar) yalnızca küçük bir yüzdesini oluşturmaktadır (25). Ortalama tanı yaşı yaklaşık 50'dir.

2.3.2 NON-JİNEKOLOJİK ADNEKSİYEL KİTLELER

- **Metastatik hastalık:** Overler ve fallop tüpleri, endometrial, meme ve bazı gastrointestinal malign neoplazmların yaygın metastaz bölgeleridir. Overe metastaz yapan neoplazmların 50 veya daha fazla vaka içeren çalışmalarında, primer tümörlerin köken aldığı bölgeler arasında kolon kanseri (%15 ila %32), meme (%8 ila %28), mide (%6 ila %22) ve apendiks (%2 ila %20) yer almıştır (26). Nadiren, lenfoma veya sarkomlar da overe metastaz yaparak over kitlesi şeklinde kendini gösterebilir.
- **Abdominopelvik apse:** Jinekolojik sistemden kaynaklanmayan, adneksiyel kitleye yol açan enfeksiyöz veya enflamatuvar nedenler arasında gastrointestinal sistem lezyonları (özellikle divertikülit ve daha az sıklıkla apandisit) veya diğer herhangi bir pelvik apse tipi yer almaktadır.
- **İdrar yolu kitleleri:** Pelvik muayene veya görüntüleme sırasında adneksiyel kitle olarak ortaya çıkabilen üriner sistem kitleleri arasında mesane divertikülü, üreter divertikülü ve pelvik böbrek yer almaktadır.
- **Diğer kitleler:** Pelvik muayene veya görüntüleme sırasında adneksiyel kitle olarak ortaya çıkabilecek diğer karın-pelvis kitle tipleri arasında peritoneal ve omental kistler, intraligamentöz kitleler ve çeşitli retroperitoneal lezyonlar bulunmaktadır.

Adneksiyel kitleye neden olabilecek bir peritoneal inklüzyon kisti, pelvik adezyonlar (yapışıklıklar) sonucu oluşabilir. Tipik olarak bu durum, daha önce ameliyat (özellikle histerektomi) veya enflamasyon (pelvik enflamatuvar hastalık) öyküsü olan bir hastada, transvajinal ultrasonda net bir şekilde palpe edilemeyen kistik bir kitle olarak ortaya çıkar. Ultrason görünümü, pelviste ince yapışıklıklarla ayrılmış ve hareket edebilen sıvı ceplerini ("yelken kanatları" işareti) içerir (27). Genellikle, eğer mevcutsa, over de bu loküle sıvı içinde yer alır ve çevresindeki pelvik yapılar ile yan duvarlara uyum sağlar. Bu kist, yuvarlak bir kistten ziyade genellikle düzensiz şekilli bir dış sınıra sahiptir (7). İnce yapışıklıklar içinde

hapsolmuş periton sıvısı olduğundan, loküle sıvının zamanla gerilediği veya hacminin azaldığı görülebilir.

Malign peritoneal mezotelyoma, pleura, periton, perikard veya tunica vaginalis testisin seröz zarlarından kaynaklanan nadir bir neoplazmdır. Hastalık dağılımı tipik olarak diffüz olsa da, lokalize hastalık da görülebilir ve potansiyel olarak bir adneksiyel kitle olarak saptanabilir. Malign peritoneal mezotelyoma için spesifik bir belirti veya semptom yoktur. En sık görülen semptomlar arasında karında şişkinlik/ağrı, kilo kaybı, nefes darlığı ve göğüs ağrısı yer almaktadır.

2.4. ADNEKSİYEL KİTLELERDE TANISAL DEĞERLENDİRME

Adneksiyel kitlesi olan ve akut ve/veya şiddetli ağrısı veya hemodinamik instabilitesi bulunan hastalar acil serviste değerlendirilmeli ve stabilizasyonu sağlanmalıdır. Potansiyel olarak acil bir durumdan şüphelenilmeyen hastalar, genellikle ayakta tedavi ortamında (poliklinikte) değerlendirilir.

Tıbbi geçmiş değerlendirmesi aşağıdaki bilgileri içermelidir:

- Premenopozal hastalarda menstrüel öykü (son adet dönemi ve dismenorenin varlığı/şiddeti dahil) veya postmenopozal hastalarda menopoz yaşı
- (Varsa) ağrının özellikleri
- Ateşin varlığı/yokluğu
- Cinsel öykü
- İnfertilitenin varlığı/yokluğu
- Over kanseri risk faktörleri (tablo 3) veya belirtileri (tablo 4)

BRCA1 gen mutasyonu
BRCA2 gen mutasyonu
Lynch sendromu (kalıtsal nonpolipozis kolon kanseri)
Diğer gen mutasyonları **BRIP1* ** RAD51C* ** RAD51D*
Ailede yumurtalık veya fallop tüpü kanseri öyküsü (ailesel yumurtalık kanseri sendromu için negatif test sonucuyla birlikte)
İnfertilite
Endometriozis (berrak hücreli, endometrioid veya düşük dereceli seröz karsinom riskinde artış)
Sigara içmek (müsinöz karsinom riskinde artış)
Rahim içi cihaz
Geçmişte oral kontraseptif kullanımı
Emzirmenin geçmiş süresi (>12 ay)
Tüp ligasyonu
Önceki gebelik

Tablo-3: Yumurtalık kanseri için risk faktörleri

Semptom Tipi	Yüzde
Abdominal	77
Gastrointestinal	70
Ağrı	58
Konstitüsyonel	50
Üriner	34
Pelvik	26

Tablo-4: Yumurtalık kanseri olan kadınlarda semptom kategorilerinin sıklığı (28)

Fizik muayene, (daha önce yapılmadıysa) pelvik muayene dahil olmak üzere, ele gelen bir kitlenin boyutu, kıvamı ve hareketliliğini değerlendirmek için kullanılır. Küçük adneksiyel kitlelerin, yumurtalığın anatomik olarak derin yerleşimi nedeniyle palpe edilmesi zor olabilir. Daha büyük kitleler pelvisten dışarı doğru uzanabilir ve hissedilmesi yine güç olabilir. Daha önce histerektomi geçirmiş hastalarda ise, ligaman bağlarının kaybı nedeniyle yumurtalıklar pelvis dışına doğru yükselebilir ve palpe edilmesi zorlaşabilir.

Muayene sırasında ağrı, karında şişkinlik, asit veya distansiyon ya da düzensiz, fikse ve/veya Douglas boşluğunda nodülarite ile birlikte olan bir kitle gibi bulgular not edilmelidir. Nodülarite ve/veya fiksasyon, endometriozis, enfeksiyon veya malignite belirtisi olabilir.

2.4.1 Tümör Belirteçlerinin ve Multimodal Testlerin Rolü

- **Serum tümör belirteçleri:** Seröz biyobelirteçlerin malignite risk değerlendirmesindeki faydası sınırlıdır.

Kanser antijen 125 (CA 125), epitelyal over kanseri (EOC) şüphesi taşıyan adneksiyel kitlesi olan hastalarda değerlendirilen en yaygın tümör belirtecidir. Başlangıç serum kanser antijen 125 (CA 125) seviyesi ölçülmelidir. Epitelyal over kanseri (EOC) olan hastaların %85'ine kadarı yüksek CA 125 seviyesine sahip olacaktır (29) ve tedavi sonrası CA 125 testi, tedaviye yanıtı ve rekürrensi (nüksü) değerlendirmek için kullanılır (30).

Diğer serum tümör belirteçleri arasında yer alan insan epididimis proteini 4 (HE4), karsinoembriyonik antijen (CEA) ve kanser antijen 19-9; bu değerler pozitif sonuç verirlerse, bu belirteçler hastalığın tedaviye yanıtının izlenmesinde kullanılabilir.

Adneksiyel kitlesi olan ve östrojen fazlalığı (örneğin, anormal uterin kanama [AUK]) veya androjen fazlalığı (örneğin, virilizasyon) belirtileri veya semptomları gösteren hastalarda bir germ hücreli veya seks kord-stromal tümör bulunabilir. Ancak, çoğu vakada bu histolojik tiplerin tanısı, yalnızca ameliyat sonrası overin patolojik değerlendirilmesiyle konulur.

- **Multimodal testler:** Çoklu risk puanlama sistemleri (Risk of Malignancy Index, ADNEX Modeli gibi) benign ve malign adneksiyel kitleleri ayırt etmek için önerilmiştir. Bu sistemler; sonografik özellikleri, menopozal durumu ve serum CA 125 gibi diğer faktörleri içerir. Ancak, bu tür modeller nonspesifiktir ve kullanımı zor olabilir.

2.4.2 Ek Görüntüleme Yönteminin Rolü

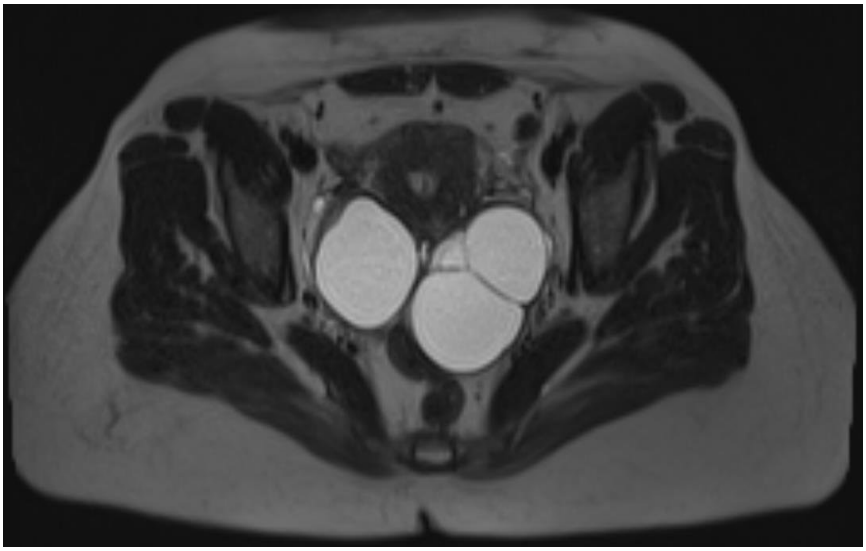
Çoğu hasta için bir adneksiyel kitle tanısı ultrason ile konulur. Ultrasonografide belirsiz özellikler gösteren veya suboptimal görüntüsü olan kitleler için, kitlenin daha ileri karakterizasyonu, MRG (Manyetik Rezonans Görüntüleme) çekilerek veya bir ultrason uzmanına (uygulaması adneksiyel lezyonların ultrason değerlendirmesine odaklanan bir hekim) sevk ile sağlanabilir (31).

Bilgisayarlı tomografi (BT), izole adneksiyel kitlelerin değerlendirilmesi için birincil bir yöntem değildir; ancak, bazı hastalarda farklı bir endikasyonla istenen BT çekimi sırasında

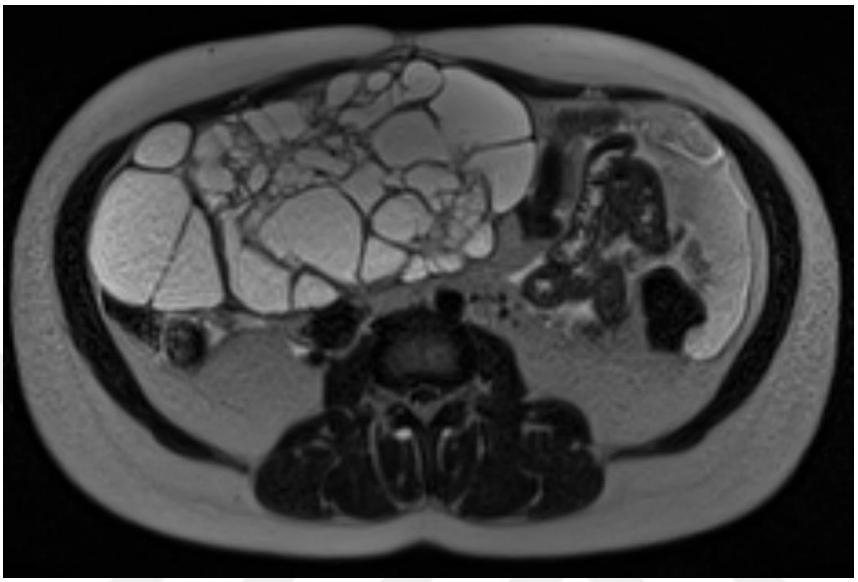
tesadüfen bir adneksiyel kitle saptanabilir. Basit bir kist, dermoid veya hidrosalpenks tanısı, bu lezyonların klasik görüntüleme bulgularıyla tipik olarak konulabilse de, bu kitlelerin daha iyi karakterize edilmesi için çoğu zaman transvajinal ultrason ile ileri görüntülemeye ihtiyaç duyulmaktadır.

2.5. ADNEKSİYEL KİTLELERDE MANYETİK REZONANS GÖRÜNTÜLEME (MRG)

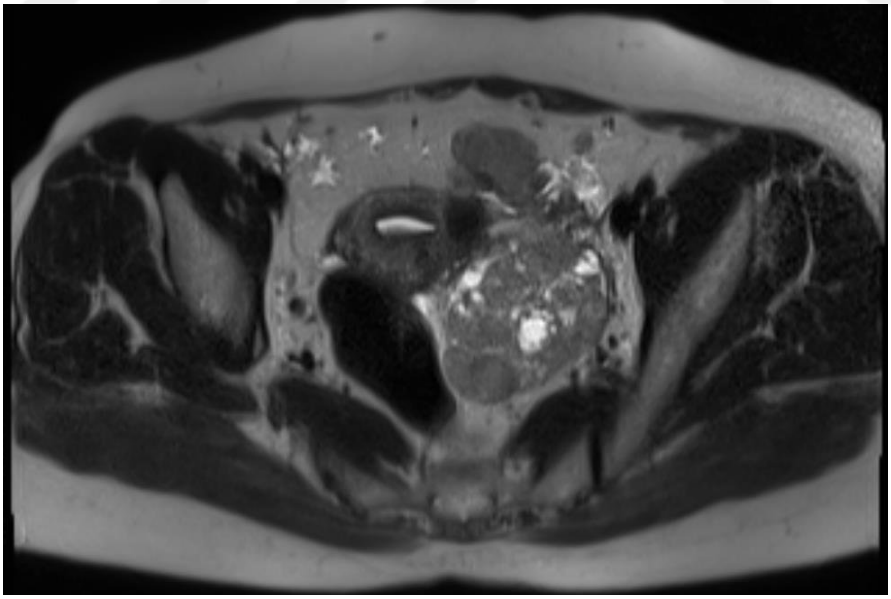
Ultrasonografi (US), klasik benign özellikler mevcut olduğunda maligniteyi dışlamak için yüksek duyarlılığa ve özgüllüğe sahiptir ve bu klasik özelliklerin görüldüğü durumlarda malignite riski %0'a yaklaşır (32). Ancak, basit veya hemorajik kist, dermoid veya endometrioma gibi klasik sonografik görüntüleme özelliklerinin bulunmadığı durumlarda, malignite potansiyeli mevcuttur. Ultrasonografide belirsiz görüntüleme özelliklerine sahip bir lezyonun kanser için pozitif prediktif değeri (PPD) %7 ile %50 arasında değişebilirken, malignite açısından endişe verici özelliklere sahip bir lezyonun kanser için PPD'si %29 ile %50'den daha yüksek bir aralıkta olabilir (33). MRG (Manyetik Rezonans Görüntüleme), kanser için PPD'yi %71'e kadar artırma ve negatif prediktif değeri %98'e çıkarma yeteneğine sahiptir (34). MRG'nin sonografik olarak belirsiz lezyonlar için daha spesifik tanılar sağlama yeteneği, şüphe düzeyini ve dolayısıyla asemptomatik kadınlarda benign tanılar için gerçekleştirilen cerrahi sayısını azaltmaktadır (35).



Şekil-9: Benign adneksiyel kitle MRI örneği



Şekil-10: Borderline adneksiyel kitle MRI örneği



Şekil-11: Malign adneksiyel kitle MRI örneği

MRG'de, adneksiyel bir lezyonda kontrast tutan solid dokunun varlığı, risk sınıflandırmasının birincil belirleyicisidir ve solid dokunun olmadığı durumlarda malignite

riski %0'a yaklaşır (36). Maligniteyi dışlayabilme yeteneği, sonografik olarak belirsiz adneksiyel lezyonların MRG'ye yönlendirilmesinin en büyük avantajlarından biridir. Maligniteyi dışlamanın yanı sıra, yüksek yumuşak doku çözünürlüğü ve farklı sıvı tiplerinin bileşimini karakterize edebilme yeteneği, lezyon tipinin daha doğru belirlenmesini sağlar. Ayrıca, MRG'nin multiplanar yetenekleri, lezyonun boyutu veya konumundan bağımsız olarak tüm lezyonun incelenmesine olanak tanır. Bu durum, hem US ile yetersiz değerlendirilebilecek küçük papiller çıkıntılara veya yumuşak doku nodüllerine sahip lezyonlar hem de büyük adneksiyel lezyonlar için özellikle önemlidir (37). MRG, aynı zamanda kökeni belirsiz büyük bir adneksiyel lezyonun değerlendirilmesinde de kritik öneme sahiptir ve overler lezyondan ayrı bir şekilde net olarak tanımlandığında, lezyonun non-ovaryen olarak yeniden sınıflandırılmasına olanak tanır. Son olarak, jinekoloji topluluğu MRG'yi adneksiyel lezyon sınıflandırması için cerrahi olmayan referans standart olarak kabul etmektedir ve ameliyat öncesi MRG, özellikle fertiliteyi koruyucu cerrahi düşünüldüğünde oldukça faydalıdır (38).

Yakın zamanda, Amerikan Radyoloji Koleji (ACR) Over-Adneksiyal Raporlama ve Veri Sistemi (O-RADS) MRG komitesi, adneksiyel lezyonlar için bir sözlük ve risk sınıflandırma sistemi yayınlamıştır (39). ACR O-RADS MRG sözlüğü, adneksiyel lezyonları değerlendirmek ve raporlamak için standartlaştırılmış terimler ve tanımlar içerirken, O-RADS MRG risk sınıflandırma sistemi (tablo 5), malignite olasılığını belirlemek için veri odaklı bir yöntem sunar (40).

O-RADS MR Skoru	Risk Kategorisi	Malignite İçin Pozitif Tahmin Değeri	Açıklama
0	Eksik Değerlendirme	Yok	Yok
1	Normal Overler	Yok	*Over lezyonu yok *Premenopozal bir kadında ≤ 3 cm basit kist olarak tanımlanan folikül *Premenopozal bir kadında 3 cm'den küçük hemorajik kist *Premenopozal bir kadında corpus luteum +/- kanama ≤ 3 cm
2	Neredeyse Kesinlikle Benign	<0.5 %	*Kist: Uniloküler - herhangi bir sıvı içeriği Duvar zenginleştirmesi yok Zenginleştirme yapan solid doku yok * Kist: Uniloküler – basit veya endometriotik sıvı içeriği Pürüzsüz kontrastlı duvar Kontrastlı solid doku yok * Lipid içerikli lezyon Solid doku artışı yok * "Koyu T2/koyu DWI (difüzyon ağırlıklı görüntüler)" solid dokuya sahip lezyon T2 ve DWI'da homojen hipointens * Genişlemiş fallop tüpü - basit sıvı içeriği İnce, pürüzsüz duvar/endosalpingeal kıvrımlar ve kontrastlanma Kontrastlanan solid doku yok * Para-ovaryan kist - herhangi bir sıvı türü İnce, pürüzsüz duvar +/- kontrastlanma Kontamine solid doku yok
3	Düşük Risk	~5 %	*Kist: Uniloküler – proteinli, hemorajik veya mukuslu sıvı içeriği Pürüzsüz kontrastlı duvar Kontrastlı solid doku yok * Kist: Multiloküler - Herhangi bir sıvı türü, lipid içeriği yok Kontrastlı düz septalar ve duvar Kontrastlı solid doku yok * Solid doku içeren lezyon (T2 koyu/DWI koyu hariç) DCE (15 saniye veya daha kısa zaman çözünürlüğü ile dinamik kontrastlı görüntüleme**)** MRI'da düşük risk zaman yoğunluk eğrisi * Genişlemiş fallop tüpü –

			Basit olmayan sıvı: İnce duvar/kıvrımlar Basit sıvı: Kalın, pürüzsüz duvar/kıvrımlar Kontrast tutulumu gösteren solid doku yok
4	Orta Düzey Risk	~50 %	*T2'de koyu/DWI'da koyu olmayan solid dokuya sahip lezyon DCE MRG'de orta riskli zaman yoğunluk eğrisi Non-DCE MRG'de 30-40 saniyede miyometriyuma eşit veya daha az kontrastlanma gösteren solid dokuya sahip herhangi bir lezyon * Lipid içeriği olan lezyon Geniş hacimli kontrastlanan solid doku
5	Yüksek Risk	~90 %	*T2'de koyu/DWI'da koyu olmayan solid dokuya sahip lezyon DCE MRG'de yüksek riskli zaman yoğunluk eğrisi Non-DCE MRG'de 30-40 saniyede miyometriyumdan daha fazla kontrastlanma gösteren solid dokuya sahip herhangi bir lezyon * Periton, mezenter veya omental nodülarite veya düzensiz kalınlaşma, asit ile birlikte veya asit olmaksızın

Tablo-5: O-RADS™ MRG Risk Sınıflandırma ve Yönetim Sistemi (41)

2.6. ADNEKSİYEL KİTLE TANISINDA YAPAY ZEKA

Sağlık bilimlerinde veri istatistiksel analiz yöntemlerinin gelişmesiyle birlikte, bilgisayarlı karar destek sistemleri de önemli bir ilerleme kaydetmiştir. Bu sistemler, cerrahlar için acil vakaların tanısal değerlendirmelerinde ve hastalık prognozunun belirlenmesinde kritik bir araç haline gelmektedir.

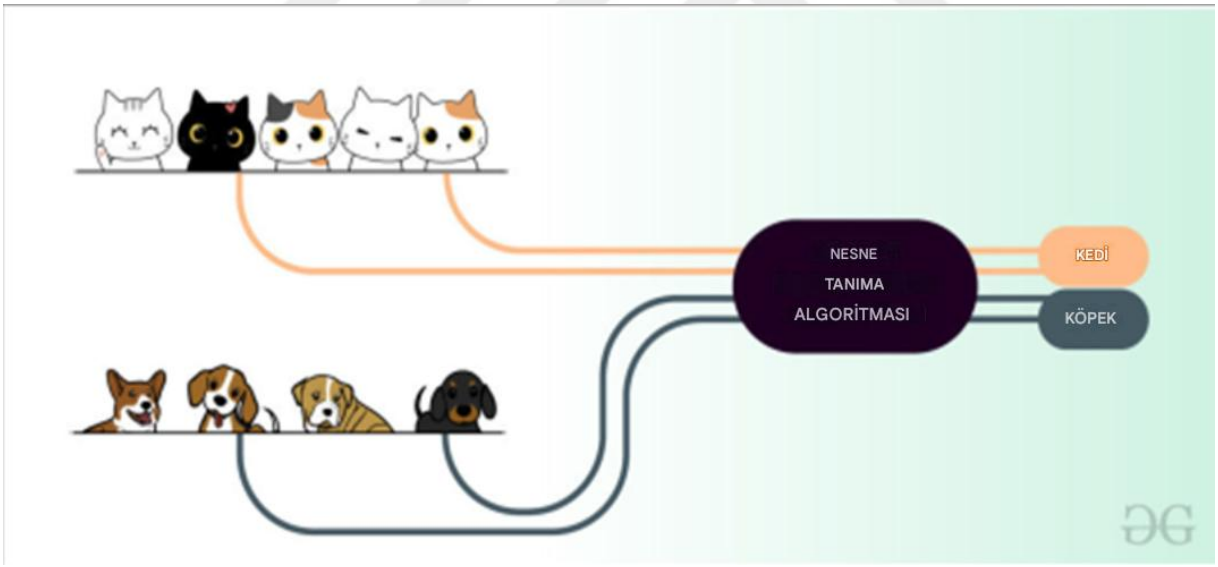
Aynı zamanda, karmaşık vakaların analizinde yapay zekâdan faydalanılmasına olanak sağlayarak klinik karar alma süreçlerini destekler (42). Bu teknolojik gelişmeler, hasta yönetiminin daha etkin ve verimli bir şekilde yürütülmesine katkıda bulunur.

Derin öğrenme (DL), otomatik görüntü analizi için en son teknolojiye sahip bir yapay zekâ (YZ) tekniğidir (43). DL, insan gözünün ötesinde olan hassas özellikleri tespit ederek, tanısal

görüntülerden hastalıkları teşhis etme ve sınıflandırma yeteneğini artırabilir; bu durum, diyabetik retinopati; ekokardiyografi; fetal kalp hastalığı; ve deri, tiroid ve mide kanserleri gibi alanlarda zaten kanıtlanmıştır (44). Adneksiyel tümörlerin tanısında DL'nin uygulanmasına dair bazı raporlar da bulunmaktadır (45). Bununla birlikte, literatürde mevcut olan diğer modeller yalnızca benign ve malign tümörleri ayırt etmiştir ve borderline tümörlerin ayrımı ile benign kitlelerin ayrıntılı patolojik alt tiplere sınıflandırılması henüz YZ kullanılarak elde edilememiştir.

2.6.1. Yapay Zeka İle Nesne Tanıma

Nesne tanıma, görüntü ve videolardaki nesneleri belirleme tekniğidir. Makine öğrenimi ve derin öğrenmenin en önemli uygulamalarından biridir. Bu alanın amacı, tıpkı insanların yaptığı gibi, makinelerin bir görüntünün içeriğini anlamasını (tanımasını) öğretmektir.

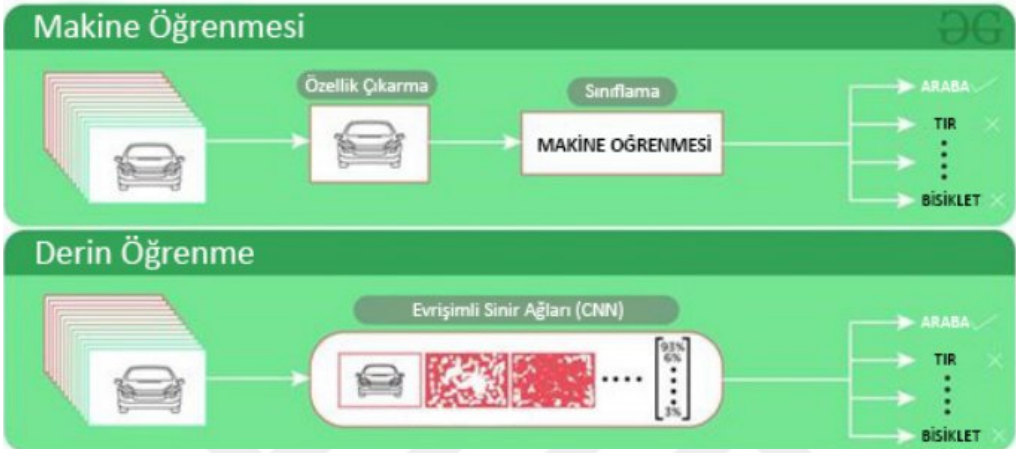


Şekil-12: Nesne Tanıma Algoritması (46)

2.6.2. Derin Öğrenme Kullanarak Nesne Tanıma

Evrişimsel Sinir Ağı (CNN), nesne tanıma için en popüler yöntemlerden biridir. Yaygın olarak kullanılır ve görüntü sınıflandırma gibi nesne tanımayla ilgili çeşitli görevlerde en son teknolojiye sahip sinir ağlarının çoğu bu yöntemi kullanır. Bu CNN ağı, girdi olarak bir görüntü

alır ve farklı sınıfların olasılığını çıktı olarak verir. Görüntüde nesne mevcutsa, çıktı olasılığı yüksektir; aksi takdirde, diğer sınıfların çıktı olasılığı ya ihmal edilebilir düzeyde ya da düşüktür. Derin öğrenmenin bir avantajı, makine öğrenimine kıyasla verilerden özellik çıkarımı yapmaya gerek olmamasıdır (şekil 13) (46).



Şekil-13: Derin Öğrenme ve Makine Öğrenmesi Şemaları (46)

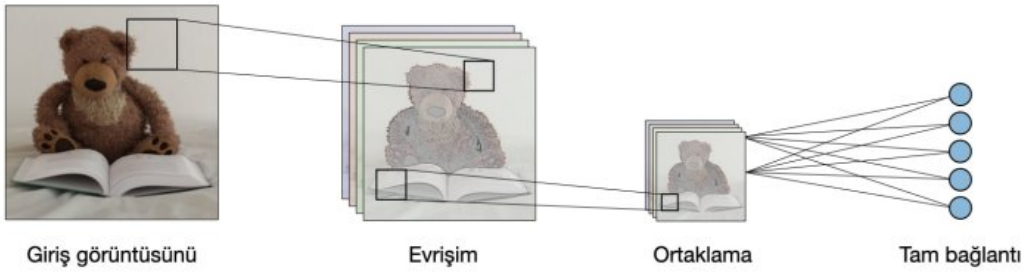
2.6.3. Görüntü Sınıflandırması

Görüntü sınıflandırmasında, girdi olarak bir görüntü alınır ve bu görüntünün sınıflandırma etiketi, belirli bir metrikle (olasılık, kayıp, doğruluk vb.) birlikte çıktı olarak verilir. Örneğin, bir kedi görüntüsü "kedi" sınıfı etiketi olarak, bir köpek görüntüsü ise belirli bir olasılıkla "köpek" sınıfı etiketi olarak sınıflandırılabilir (46).

2.6.4. Evrişimli Sinir Ağları

Evrişimli sinir ağları (CNN), ilk olarak 1989 yılında LeCun ve meslektaşları tarafından ileri beslemeli bir yapay sinir ağı ve derin öğrenme mimarisi olarak sunulmuştur (47). Bu mimari, insanlar ve makineler arasındaki algısal farklılıkları azaltmak amacıyla biyolojik görsel algı

sistemlerinden esinlenerek geliştirilmiştir. CNN'lerin başlıca hedefleri arasında, görüntü verilerinden anlamlı bilgiyi çıkarmak, derin öğrenme yaklaşımlarıyla yeni görüntüler üretmek ve görüntülerdeki karmaşık özellikleri çözümlemek yer almaktadır. Bu sistem, görüntüleri analiz etme, içerisindeki nesneleri saptama ve farklı nesneleri birbirinden ayırma yeteneği gösterecek şekilde tasarlanmıştır (şekil 14).



Şekil-14: Evrişimli sinir ağları mimarisi (48)

Görüntü özelliklerinin çıkarılması aşamasında evrişimli sinir ağı (CNN) mimarilerinden yararlanılmıştır. Bu bağlamda kullanılan bazı CNN mimarileri aşağıda listelenmiştir.

- EfficientNet
- EfficientNetV2B0
- Mobilenet
- MobilenetV2
- VGG16
- VGG19
- DenseNet121
- ResNet
- ResNetV2
- InceptionV3
- InceptionResNetV2
- Xeption

3. GEREÇ VE YÖNTEM

Çalışmamız için etik onay, İstanbul Kanuni Sultan Süleyman Eğitim ve Araştırma Sağlık Uygulama ve Araştırma Merkezi Etik Kurulu'ndan alınmıştır (tarih: 16.05.2025, karar no: 2025.05.123). Etik kurul onay belgesi, makalenin Ekler bölümünde Ek 1 olarak sunulmuştur.

3.1. ÇALIŞMANIN YÖNTEMİ

Ocak 2010 – Ocak 2025 tarihleri arasında Kanuni Sultan Süleyman Eğitim ve Araştırma Hastanesi Jinekolojik Onkoloji Cerrahisi Kliniği'nde adneksiyel kitle tanısı ile ameliyat edilen, patoloji sonucu malign, borderline veya benign epitelyal over tümörü olarak raporlanan ve operasyon öncesinde manyetik rezonans görüntüleme (MRG) incelemesi yapılmış hastalar çalışmaya dahil edildi.

Dahil Edilme Kriterleri

- 18 yaş ve üzeri olmak
- Adneksiyel kitle tanısı almış olmak
- Belirtilen tarih aralığında kliniğimizde opere edilmiş olmak
- Patoloji sonucunda malign, benign veya borderline epitelyal over tümörü tanısı almış olmak
- Operasyon öncesi tanı sürecinde alt batın MRG incelemesi yapılmış olmak

Dahil Edilmeme Kriterleri

- 18 yaşın altında olmak
- Patoloji sonucunda malign, benign veya borderline epitelyal over tümörü dışında tanı almak
- Gebelik durumu bulunması
- Eşlik eden başka jinekolojik veya sistemik patoloji varlığı
- Patoloji sonucunda birden fazla farklı malignite potansiyeline sahip tümör tipinin bulunması (ör. malign tümör yanında borderline tümör varlığı)

- MRG görüntülerinin yetersiz kaliteye sahip olması veya sekans/kesit sayısının tanısal açıdan yetersiz olması

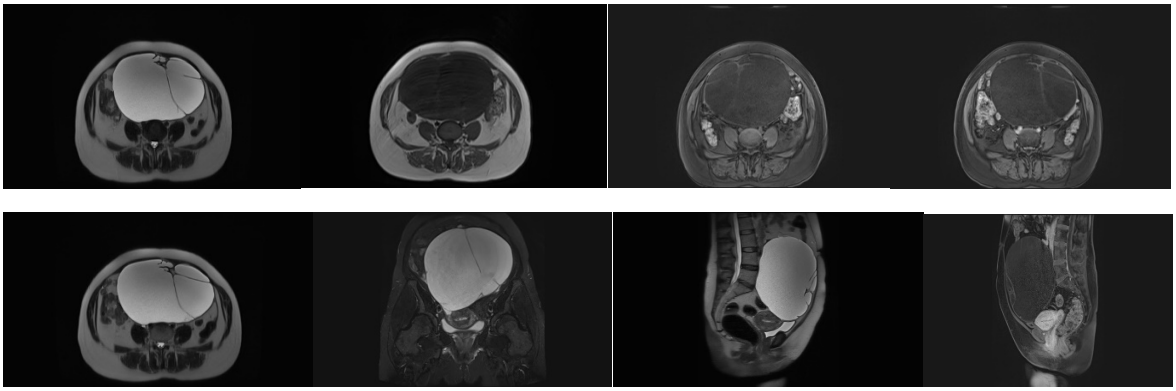
Veri Toplama

Belirtilen kriterlere göre çalışmaya dahil edilen olgularda yaş, gravida, parite, ek hastalık varlığı, serum tümör belirteçleri (CA-125, CA 19-9, CA 15-3), kitlenin lokalizasyonu, boyutu, lenf nodu pozitifliği, uygulanan cerrahi yöntemi ve difüzyon kısıtlanması gibi klinik, laboratuvar ve radyolojik veriler kaydedildi. Aynı tarih aralığında hastanemizde adneksiyel patolojisi bulunmayan ve MRG görüntüleri mevcut olan hastalar ise sağlıklı kontrol grubunu oluşturdu.

Toplamda 362 hastanın verileri çalışmaya dahil edildi: 100 malign, 100 benign, 62 borderline epitelyal over tümörü olan hasta ve 100 sağlıklı kontrol. Görüntü sınıflandırmaya yönelik ("image classification") beş farklı yapay zekâ modeli kullanıldı.

Her epitelyal over tümörü grubundan ve sağlıklı kontrolden, preoperatif MR görüntülerinden over tümörünü temsil eden, kitlenin en büyük boyutunu ve karakteristik özelliklerini yansıttığı düşünülen 5 aksiyal, 1 koronal ve 2 sagital olmak üzere toplam 8 görüntü karesi seçildi. Sağlıklı kontrol grubundan da aynı şekilde 8 görüntü randomize olarak alındı. Bu şekilde toplam 800 malign**,** 800 benign**,** 496 borderline ve 800 sağlıklı over kesitini içeren görüntüler elde edildi. Tüm kesitler Joint Photographic Experts Group (*.jpeg) formatında, 1164x734 piksel çözünürlükte kaydedildi.

- **Aksiyal kesitler**: T2_HASTE (Half-Fourier Acquired Single-shot Turbo Spin Echo), T1, T1_FS (Fat Saturation)_PRE, T1_FS_POST ve T2_HASTE_FS sekanslarından elde edildi.
- **Koronal kesit**: T2_TIRM (Turbo Inversion Recovery Magnitude) sekansından elde edildi.
- **Sagital kesitler**: T2_HASTE ve T1 sekanslarından ikişer görüntü seçildi.



Şekil-15: MRG'den elde edilmiş 8 adet farklı sekanstaki fotoğraf karesi örneği

Bu çalışmada her bir hasta için elde edilen tüm MRG görüntüleme düzlemleri (aksiyal, sagital ve koronal) derin öğrenme modellerinin eğitimi ve değerlendirilmesi amacıyla tek bir örneklem birimi olarak kabul edilmiştir.

Veri seti, modellerin eğitimi, doğrulanması ve test edilmesi amacıyla %70 eğitim, %15 doğrulama ve %15 test olacak şekilde üç alt gruba ayrılmıştır:

- **Eğitim Veri Seti (%70):** Modellerin öğrenme sürecinde kullanılan ana veridir. Modeller bu veri kümesindeki örneklerden öğrenerek görüntüdeki örüntüleri tanımayı amaçlar.
- **Doğrulama Veri Seti (%15):** Modelin eğitim sırasında ne kadar iyi performans gösterdiğini kontrol etmek için kullanılır. Bu veri seti, modelin aşırı öğrenmesini (overfitting) engellemeye yardımcı olur ve modelin hiperparametrelerini ayarlamak için kullanılır.
- **Test Veri Seti (%15):** Modelin nihai performansını değerlendirmek için kullanılan, eğitim ve doğrulama aşamalarında görülmemiş bağımsız bir veri kümesidir. Modelin genelleme yeteneğini ve gerçek dünya verilerindeki başarısını gösterir.

Bu çalışmada beş farklı evrişimli sinir ağı (Convolutional Neural Network, CNN) mimarisi kullanılmıştır. Seçilen modeller, görüntü sınıflandırma görevleri için tasarlanmış ve optimize edilmiş, literatürde yaygın olarak kullanılan derin öğrenme yaklaşımlarıdır:

- **EfficientNetV2B0:** Yüksek doğruluk oranlarını düşük hesaplama maliyetiyle birleştirme hedefiyle tasarlanmış modern bir mimaridir. Özellikle performans ile model

boyutu arasındaki ideal dengeyi kurmak amacıyla geliştirilmiş, önceden eğitilmiş bir versiyondur (49).

- **MobileNetV2:** Mobil cihazlar için tasarlanmış, hafif ve hızlı bir modeldir. Geleneksel yapay zeka modelleri, veriyi önce dar bir alana sıkıştırıp sonra genişletirken, MobileNetV2 tam tersini yapar. Yani, önce veriyi genişleterek ona daha fazla "düşünme alanı" verir, sonra tekrar daraltır. Bu, modelin hem daha az işlem gücü kullanmasını hem de daha doğru sonuçlar vermesini sağlar. Bu genişletme ve daraltma işlemi sırasında MobileNetV2, standart işlemler yerine daha az hesaplama gerektiren özel bir teknik kullanır. Bu sayede, daha hızlı ve daha az enerji tüketerek çalışır (50).
- **DenseNet121:** Özelliklerin yeniden kullanımını teşvik eden "yoğun bağlantılar" ile bilinir. Bellek sınırlamaları nedeniyle daha küçük yığın boyutu (batch size=4) ile çalışır.
- **InceptionV3:** Farklı boyutlardaki evrişim filtrelerini aynı katmanda kullanarak çok ölçekli özellikleri yakalar.
- **InceptionResNetV2:** Inception mimarisini, ResNet'in kalıntı (residual) bağlantılarıyla birleştirerek performansı artırmayı hedefler.

Her bir model için belirtilen farklı yığın boyutları, kullanılan bilgisayar belleğinin (GPU hafızasının) sınırlamalarından kaynaklanmaktadır. Modellerin son test doğruluğu, doğrulama veri setinde en yüksek başarıya ulaştığı dönemden alınmaktadır.

Modellerin öğrenme yeteneğini en üst düzeye çıkarmak amacıyla, eğitim süreci boyunca ağın tüm katmanlarındaki parametrelerin güncellenmesine izin veren bir strateji benimsenmiştir. Bu yaklaşım, modelin görüntü verisinden en karmaşık özellikleri dahi öğrenmesini sağlamayı amaçlamaktadır.

Modelin genelleme yeteneğini artırmak ve sınırlı veri setinin olumsuz etkilerini azaltmak için görüntü kalitesini iyileştirmeye yönelik ön işleme adımları uygulanmıştır. Buna ek olarak, veri kümesi veri artırımı (data augmentation) teknikleri ile genişletilmiştir. Bu süreçte ayrıca Lesion-ScanNet adında, bilgisayar destekli tanıda üstün performans gösteren yeni bir CNN modeli de kullanılmıştır. Lesion-ScanNet, daha az parametreye sahip olmasına rağmen yüksek doğruluk sağlayabilen hafif ve sağlam bir ağ yapısı sunmaktadır. Bu özelliği sayesinde yalnızca adneksiyel kitlelerin değerlendirilmesinde değil, farklı tıbbi görüntüleme alanlarında da kullanılabilecek potansiyele sahiptir (51).

Lesion-ScanNet mimarisi, farklı çekirdek boyutlarına sahip iki ayrı işleme yolundan oluşan beş adet Dual Kernel Bloğu (DKB) içermektedir. Bir DKB yapısındaki her yol, bir evirişim katmanı, genişletmeler, ayrılabilir evirişim katman ve atlama bağlantıları dizisiyle birlikte gelir (52). Her yolun çıktıları, bir maksimum havuzlama işlemiyle takip edilen birleştirme katmanı aracılığıyla birleştirilir. Her DKB, kanal sayısını artırırken özellik haritalarının genişliğini ve yüksekliğini azaltır (51) .

Batch boyutu, modelin karmaşıklığına ve bellek kapasitesine bağlı olarak 8 ile 16 arasında değişmiştir. Öğrenme oranı 0.0001 olarak sabitlenmiş ve ince ayar (fine tuning) süresince parametre güncellemeleri için Adam optimize edicisi kullanılmıştır. Doğrulama başarımı izlenerek erken durdurma (early stopping) stratejisi uygulanmıştır. Üst üste 20 epoch boyunca iyileşme gözlemlenmediğinde eğitim sonlandırılmış ve model ağırlıkları, en iyi doğrulama performansına karşılık gelen epoch'a geri yüklenmiştir.

Tüm modeller, 224 × 224 × 3 giriş çözünürlüğü ile eğitilmiştir. Backbone mimarilerine ait toplam öğrenilebilir parametre sayıları şu şekilde hesaplanmıştır:

- MobileNetV2 → 2.426.212 parametre
- InceptionV3 → 22.069.316 parametre
- InceptionResNetV2 → 54.746.916 parametre
- EfficientNetV2B0 → 6.087.540 parametre
- DenseNet121 → 7.172.964 parametre

Ayrıca, sınıf dengesizliği sorununu gidermek amacıyla özellikle borderline tümör grubu için aşırı örnekleme (oversampling) tekniği uygulanmıştır.

3.2. İSTATİKSEL ANALİZ

3.2.1. Kategorik Değişken Analizi

Çalışmada sürekli değişkenleri normal dağılıma uygunluğu Shapiro-Wilk testi ile incelenmiştir. Sürekli değişkenler normal dağılıma uygunluk göstermesi durumunda ortalama ve standart sapma; normal dağılıma uygunluk göstermemesi durumunda ise medyan, minimum ve maksimum değerleriyle birlikte verilmiştir. Kategorik değişkenler ise n(%) olarak verilmiştir. Sürekli değişkenlerin gruplar arasında yapılan karşılaştırmalarında Kruskal Wallis

testi kullanılmıştır. Kruskal-Wallis testi sonrasında genel anlamlılık bulunması durumunda alt grup analizler Dunn-Boenferroni testi kullanılarak yürütülmüştür. Kategorik değişkenler arasında yapılan karşılaştırmalarda ise Pearson Ki-Kare testi kullanılmıştır. Analizler SPSS (IBM Corp. Released 2011. IBM SPSS Statistics for Windows, Version 20.0.0. Armonk, NY: IBM Corp.) programı kullanılarak gerçekleştirilmiş olup, analizlerde anlam düzeyi $\alpha=0.05$ olarak alınmıştır.

3.2.2. Hata Matrisi (Confusion Matrix)

Makine öğrenmesi ve yapay zeka üzerine yapılan çalışmalarda modellerin performansını değerlendirmek için kullanılan bir tablodur. Modelin tahminlerinin gerçek sınıflara göre ne derece doğru veya yanlış olduğunu özetleyen $N \times N$ boyutunda bir tablodur; burada N sınıf sayısını temsil eder. Matrisin bir ekseni gerçek (actual) sınıfları, diğer ekseni ise modelin tahmin ettiği (predicted) sınıfları gösterir. Bu yapı, modelin hatalarının türlerini ve dağılımını ayrıntılı olarak analiz etmeye imkan sunar.

Modelin tahminleri dört ana kategoriye ayırır:

- **Doğru Tahminler:**

  Doğru Pozitif (True Positive-TP): Model, gerçekten hasta olan bir kişiyi doğru bir şekilde "hasta" olarak tahmin etti.

  Doğru Negatif (True Negative-TN): Model, hasta olmayan bir kişiyi doğru bir şekilde "hasta değil"olarak tahmin etti.

- **Yanlış Tahminler:**

  Yanlış Pozitif (False Positive-FP): Model, hasta olmayan bir kişiyi yanlış bir şekilde "hasta" olarak tahmin etti. Buna Tip I Hatası denir.

  Yanlış Negatif (False Negative-FN): Model, gerçekten hasta olan bir kişiyi yanlış bir şekilde "hasta değil"olarak tahmin etti. Buna Tip II Hatası denir.

• **Doğruluk (Accuracy):**

Tüm doğru tahminlerin (TP + TN) toplam tahminlere (TP + FP + FN + TN) oranıdır.

• **Kesinlik (Precision):**

Pozitif olarak tahmin edilen durumlardan kaç tanesinin gerçekten pozitif olduğunu gösterir. TP/(TP+FP)

• **Duyarlılık (Recall/Sensivity) / Yakalama Oranı:**

Gerçekte pozitif olan durumlardan kaç tanesinin model tarafından doğru bir şekilde yakalandığını gösterir. (TP)/(TP+FN)

• **Özgüllük (Specificity):**

Modelin gerçekte negatif olanlar arasından doğru bir şekilde negatif olarak tespit edebildiği orandır. (TN/(TN+FP)). Duyarlılığın negatif sınıf için karşılığıdır.

• **F1 Skoru:**

Kesinlik ve duyarlılığın harmonik ortalaması olarak hesaplanır (2×(Precision×Recall)/(Precision+Recall)). Aynı anda kesinlik ve duyarlılığı ölçmeye yardımcı olur.

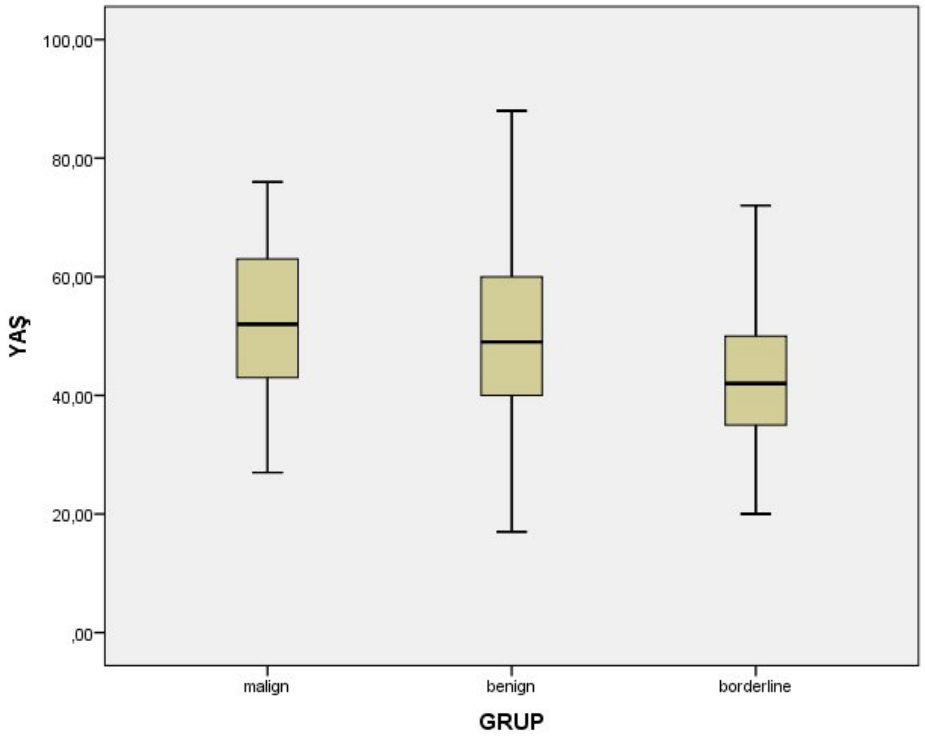
• **ROC Eğrisi:**

Modelin tüm olası eşik değerleri genelinde pozitif ve negatif sınıfları ayırt etme yeteneğinin görsel bir göstergesidir. Eğri altında kalan alan (AUC), modelin genel ayrımcılık performansını özetler.

4. BULGULAR

Çalışmaya, Ocak 2010 – Ocak 2025 tarihleri arasında adneksiyel kitle tanısı ile Kanuni Sultan Süleyman Eğitim ve Araştırma Hastanesi Jinekolojik Onkoloji Cerrahisi Kliniği'nde ameliyat edilen ve preoperatif MRG verileri mevcut olan toplam 362 hasta dahil edildi. Hastaların dağılımı; 100 benign, 100 malign, 62 borderline tümörlü ve 100 sağlıklı kontrol grubundan oluşmaktaydı.

Yaş ortalamaları değerlendirildiğinde; benign grupta 49,3 yıl, malign grupta 51,8 yıl ve borderline grupta 42,7 yıl olarak hesaplandı. Gruplar arasındaki yaş dağılımlarında istatistiksel olarak anlamlı fark saptandı ($p<0,001$). Alt grup analizlerinde borderline grubundaki hastaların medyan yaşının, hem malign ($p<0,001$) hem de benign ($p=0,012$) gruplara kıyasla daha düşük olduğu belirlendi. Buna karşılık, malign ve benign gruplar arasında yaş dağılımları açısından anlamlı fark bulunmadı ($p=0,326$) (Şekil-16).



Şekil-16: Gruplar arasındaki yaş dağılım grafiği

Menopoz durumu değerlendirildiğinde gruplar arasında istatistiksel olarak anlamlı farklılık saptandı (p=0,001). Malign gruptaki hastaların %62'si postmenopozal, %38'i premenopozal; benign grupta %50,5 postmenopozal, %49,5 premenopozal; borderline grupta ise %30,6 postmenopozal ve %69,4 premenopozal olarak bulundu. Borderline gruptaki postmenopozal hasta oranı, malign ve benign gruplara kıyasla anlamlı derecede daha düşük bulundu. Tüm hasta grupları birlikte değerlendirildiğinde hastaların %50,2'sinin postmenopozal, %49,8'inin ise premenopozal olduğu belirlendi. Parite açısından gruplar arasında istatistiksel olarak anlamlı farklılık izlenmedi (p=0,058).

Ek hastalık (komorbidite) varlığı açısından gruplar karşılaştırıldığında da anlamlı fark bulunmadı (p=0,526). Malign gruptaki hastaların %51'inde, benign grupta %48,5'inde ve borderline grupta %41,9'unda ek hastalık saptandı.

MRG'de diffüz kontrastlanma varlığına göre yapılan karşılaştırmalarda, gruplar arasında anlamlı farklılık bulundu (p<0,001). Malign gruptaki hastaların %82'sinde, benign grupta %23,7'sinde ve borderline grupta %62,9'unda diffüz kontrastlanma izlendi. Malign grupta diffüz kontrastlanma oranı, benign ve borderline gruplara göre belirgin derecede yüksek bulundu. Ayrıca, borderline gruptaki oran da benign gruba göre anlamlı olarak yüksekti (Tablo 6).

	Malign	**Benign**	**Borderline**	**p-değeri**
Yaş	52(27:76)	49(17:88)	42(20:72)	**<0,001[a]**
Menopoz				
Men	62(%62)	51(%50,5)	19(%30,6)	**0,001[b]**
Pre	38(%38)	50(%49,5)	43(%69,4)	
Parite	3(0:11)	2(0:14)	2(0:14)	0,058[b]
Ek Hastalık				
Var	51(%51)	49(%48,51)	26(%41,94)	0,526[b]
Yok	49(%49)	52(%51,49)	36(%58,06)	
Diffüz Kontrastlanma				
Var	82(%82)	24(%23,76)	39(%62,90)	**<0,001[b]**
Yok	18(%18)	77(%76,24)	23(%37,10)	

Veriler medyan(minimum:maksimum) ve n(%) olarak ifade edilmiştir.
a: Kruskal-Wallis testi, b: Pearson Ki-Kare testi

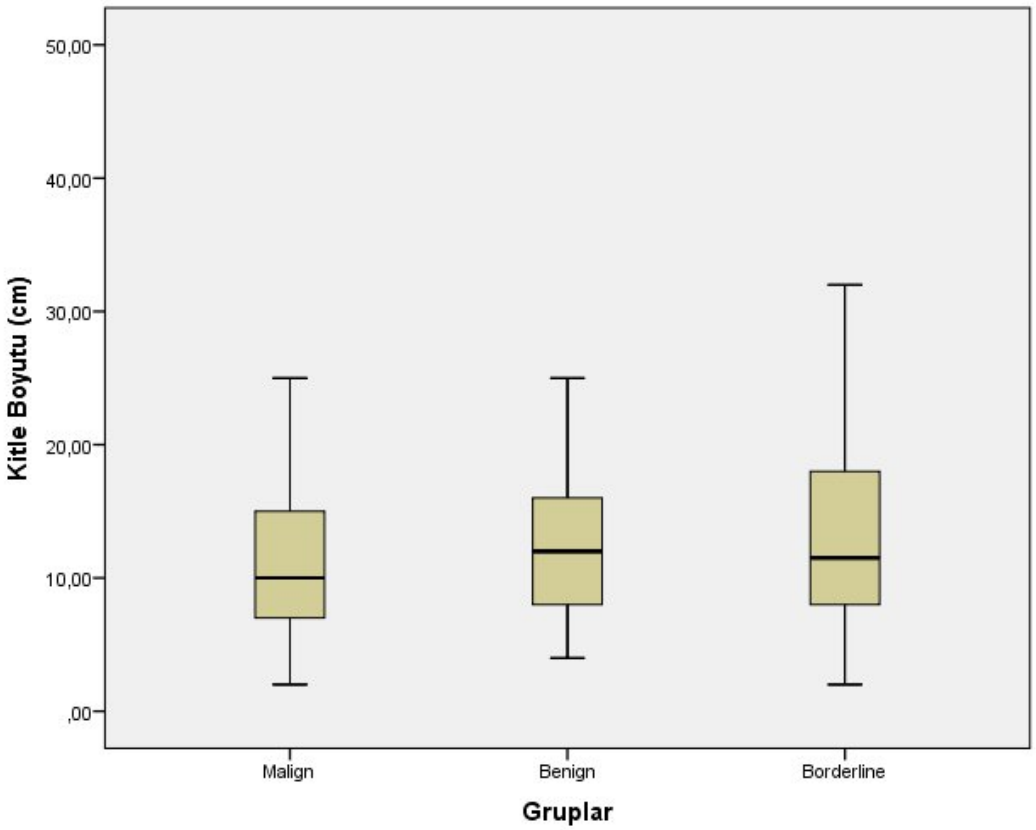
Tablo-6: Gruplar arasındaki demografik veriler ve MRG'de diffüz kontrastlanma istatistikleri

Preoperatif CA-125 değerleri incelendiğinde; benign grupta %19, malign grupta %88 ve borderline grupta %46,7 oranında pozitiflik saptandı.

Cerrahi yaklaşımlar değerlendirildiğinde; benign grupta en sık uygulanan cerrahi yöntem %59 oranıyla total abdominal histerektomi + bilateral salpingooferektomi (TAH-BSO) idi. Malign grupta hastaların %93'üne debulking cerrahisi uygulanırken, borderline grupta en sık uygulanan yöntem %69 oranla debulking cerrahisi oldu. Borderline grupta ayrıca %21 hastaya fertilite koruyucu debulking cerrahisi ve %10 hastaya kistektomi uygulandı.

Postoperatif patoloji sonuçlarına göre; benign grupta en sık görülen histopatolojik tanı %52 oranıyla benign müsinöz kistadenom, malign grupta %55 oranıyla seröz adenokarsinom, borderline grupta ise %50 oranıyla borderline seröz tümör olarak saptandı. Lenf nodu diseksiyonu benign grupta yapılmazken, malign grupta hastaların %94'üne uygulanmış ve bunların %31,9'unda lenf nodu metastazı pozitif bulundu. Borderline grupta %69,3 hastaya lenf nodu diseksiyonu yapıldı, bunların %4,6'sında metastaz saptandı.

Kitlenin lokalizasyonu değerlendirildiğinde; benign grupta kitlelerin %55'i sol overde yerleşmiş ve bilateralite oranı %5 olarak bulundu. Malign grupta ise kitlelerin %39'u sağ overde izlenmiş, bilateralite %35 oranında saptandı. Borderline grupta kitlelerin %50'si sağ over yerleşimli olup, bilateralite oranı %20,9 olarak belirlendi. Kitle boyutu açısından karşılaştırıldığında, benign kitlelerin medyan boyutu 12 cm, malign kitlelerin medyan boyutu 10 cm, borderline kitlelerin medyan boyutu ise 11,5 cm olarak hesaplandı (Şekil-17).

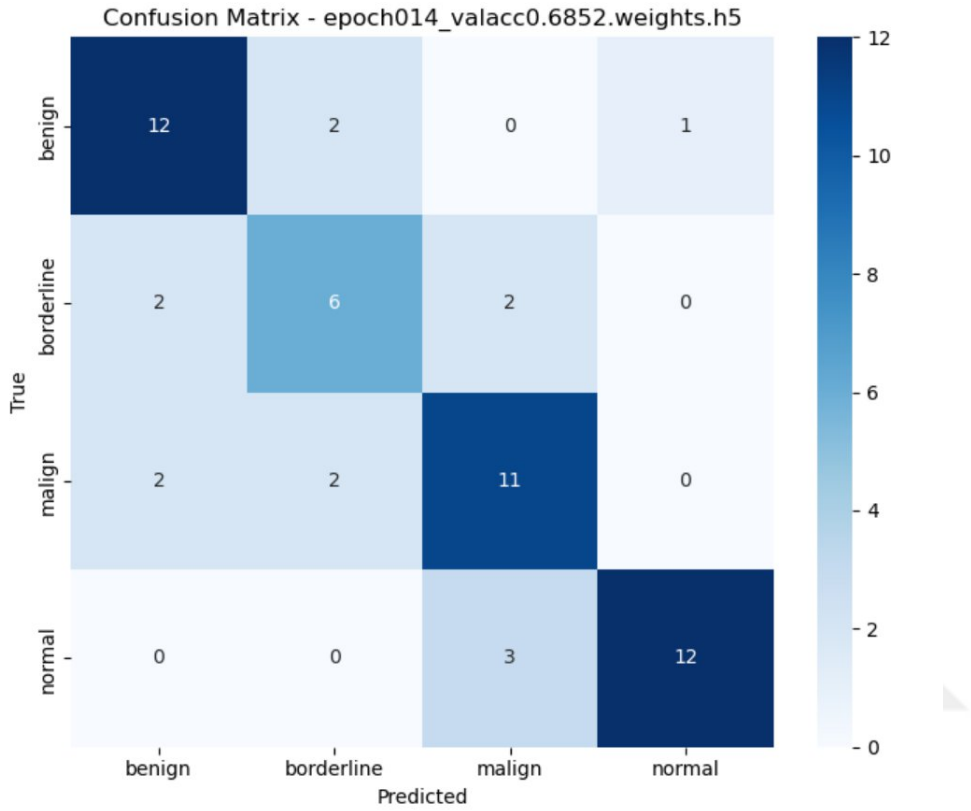


Şekil-17: Gruplar arasındaki kitle boyutu dağılım grafiği

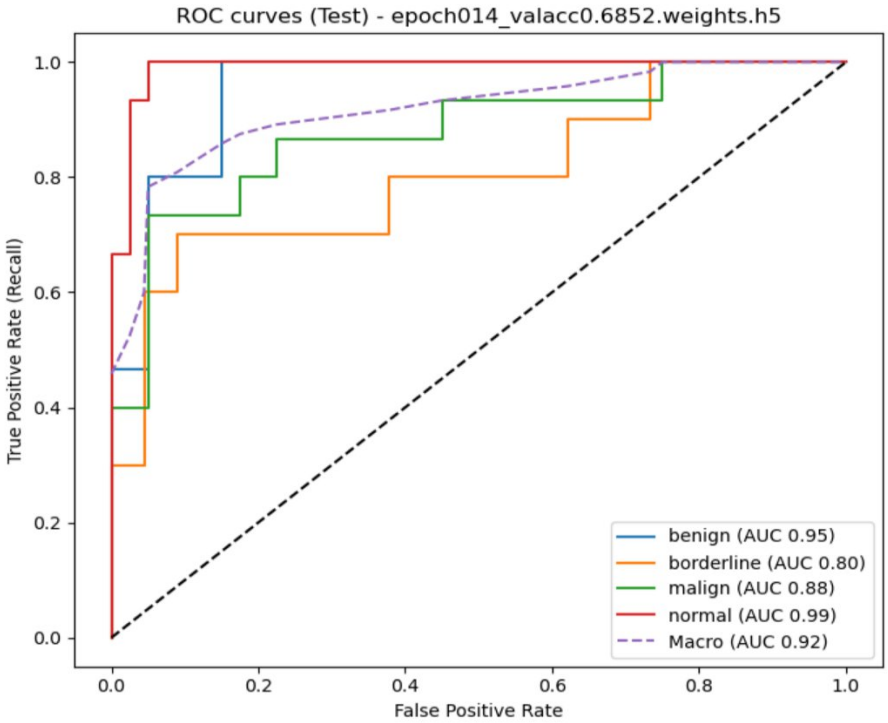
Bu çalışmada, adneksiyel kitlelerin MRG görüntülerini sınıflandırmak amacıyla beş farklı derin öğrenme mimarisi (EfficientNetV2B0, MobileNetV2, DenseNet121, InceptionV3 ve InceptionResNetV2) kullanılarak yapılan analizlerin sonuçları sunuldu. Veri kümesi, eğitim (%70), doğrulama (%15) ve test (%15) alt gruplarına ayrıldı. Her modelin test performansı, doğrulama kümesinde en yüksek doğruluk değerine ulaşılan epoch'tan elde edildi.

EfficientNetV2B0 modeli, test kümesinde %74,55 doğruluk (accuracy) ile en iyi performansı gösterdi. Modelin makro ortalama duyarlılık (recall) değeri %73,33, makro ortalama kesinlik (precision) değeri %74,01 ve makro ortalama F1-skoru %73,53 olarak hesaplandı. Sınıf bazlı analizlerde, modelin "normal" görüntüleri ve "benign" kitleleri yüksek doğrulukla sınıflandırdığı görüldü. Normal görüntüler için %92,31 kesinlik ve %80,00 duyarlılık; benign kitleler için %75,00 kesinlik ve %80,00 duyarlılık elde edildi. Buna karşın, borderline ve malign kitlelerde duyarlılık değerleri daha düşük bulunmuş olup, sırasıyla %60,00 ve %73,33 olarak hesaplandı (Şekil-18).

ROC eğrisi analizi, modelin genel olarak güçlü bir sınıflandırma yeteneğine sahip olduğunu göstermektedir (AUC = 0,9170). Özellikle normal görüntüler (AUC = 0,9900) ve benign kitlelerin (AUC = 0,9533) tespitinde yüksek AUC değerleri modelin başarısını desteklemektedir (Şekil-19).



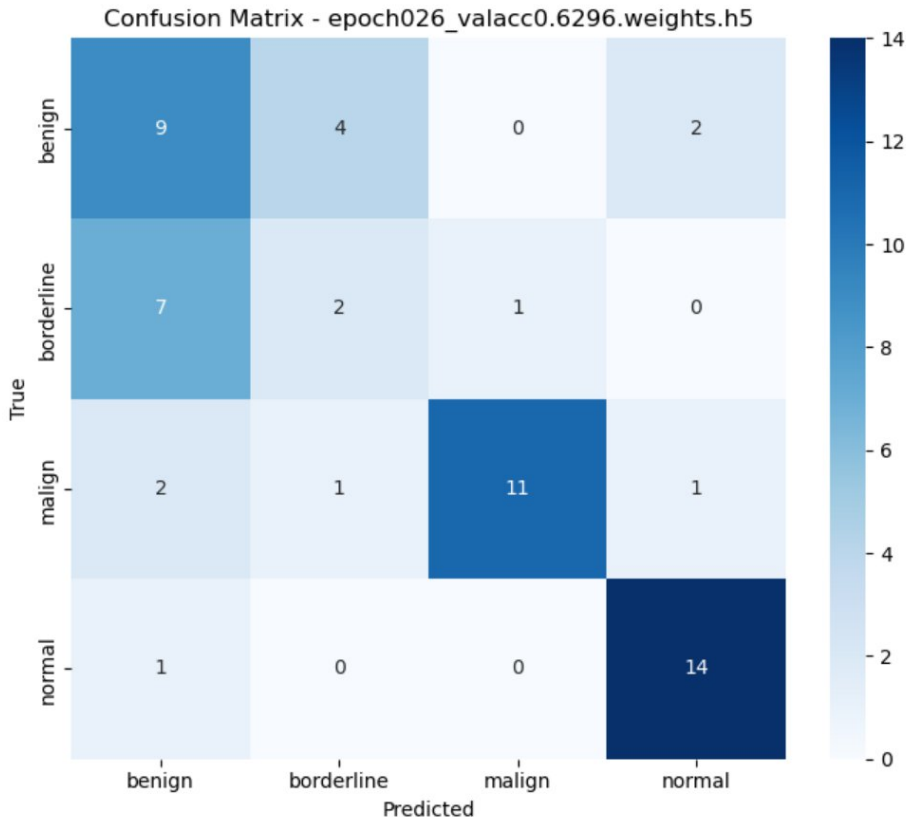
Şekil-18: EfficientNetV2B0 modeli hata matrisleri şeması



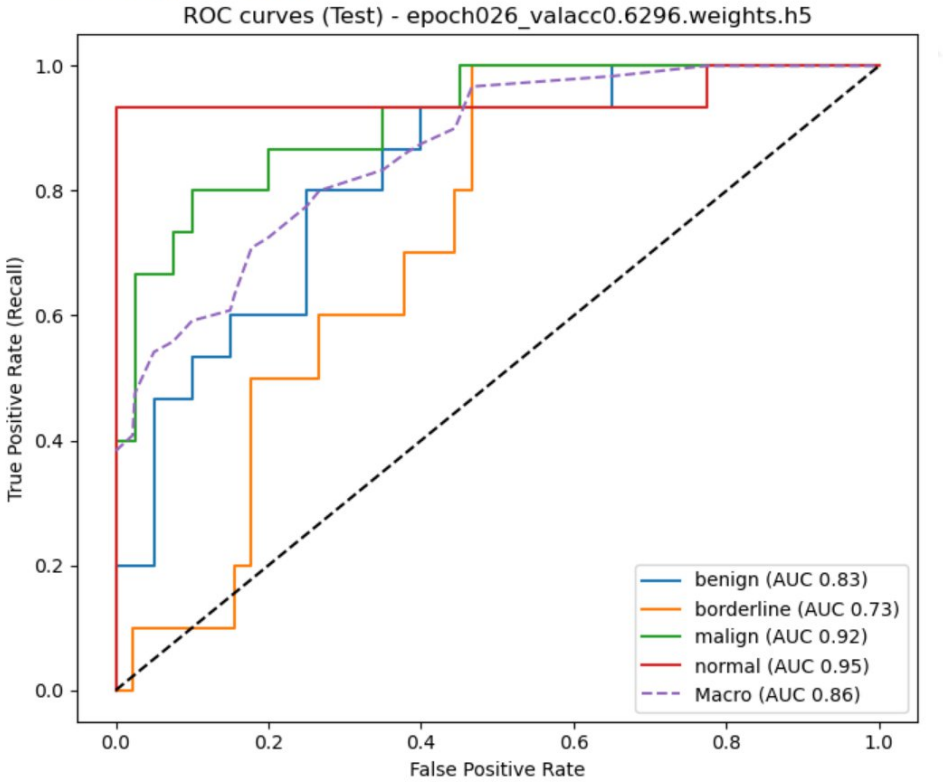
Şekil-19: EfficientNetV2B0 modeli ROC eğrileri grafiği

MobileNetV2 modeli, %65,45 test doğruluğu ile diğer modellere kıyasla daha düşük performans gösterdi. Modelin makro ortalama duyarlılık değeri %61,67, kesinlik değeri %62,49 ve F1-skoru %61,36 olarak hesaplandı. Hata matrisi incelendiğinde, özellikle borderline kitlelerin sınıflandırılmasında ciddi zorluklar yaşandığı görüldü. Bu sınıfa ait 10 vakanın yalnızca 2'si doğru tahmin edilmiş olup duyarlılık %20,00'de kaldı (Şekil-20).

Buna karşın MobileNetV2, malign kitlelerin sınıflandırılmasında daha yüksek bir performans sergiledi ve %91,67 kesinlik ile %73,33 duyarlılık değerlerine ulaştı. ROC analizi sonuçları da modelin genel sınıflandırma gücünün sınırlı olmakla birlikte kabul edilebilir düzeyde olduğunu gösterdi (makro ortalama AUC = 0,8645) (Şekil-21).



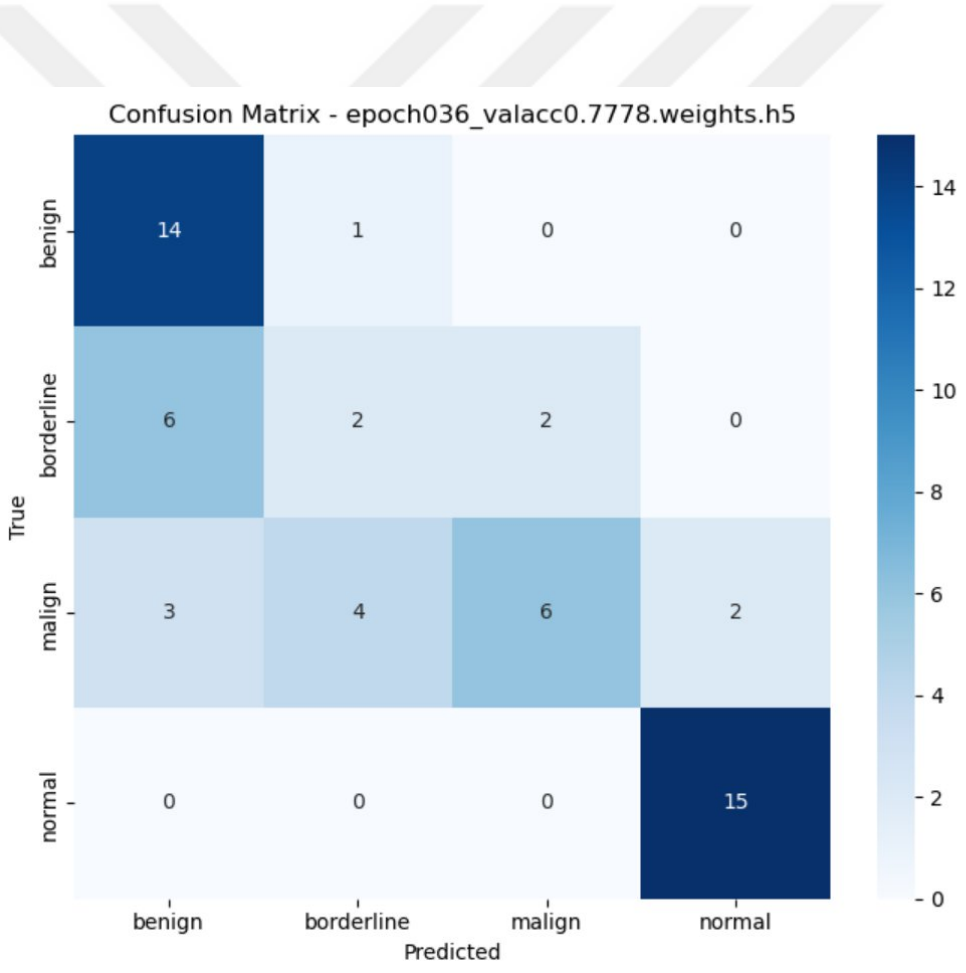
Şekil-20: MobilenetV2 modeli hata matrisleri şeması



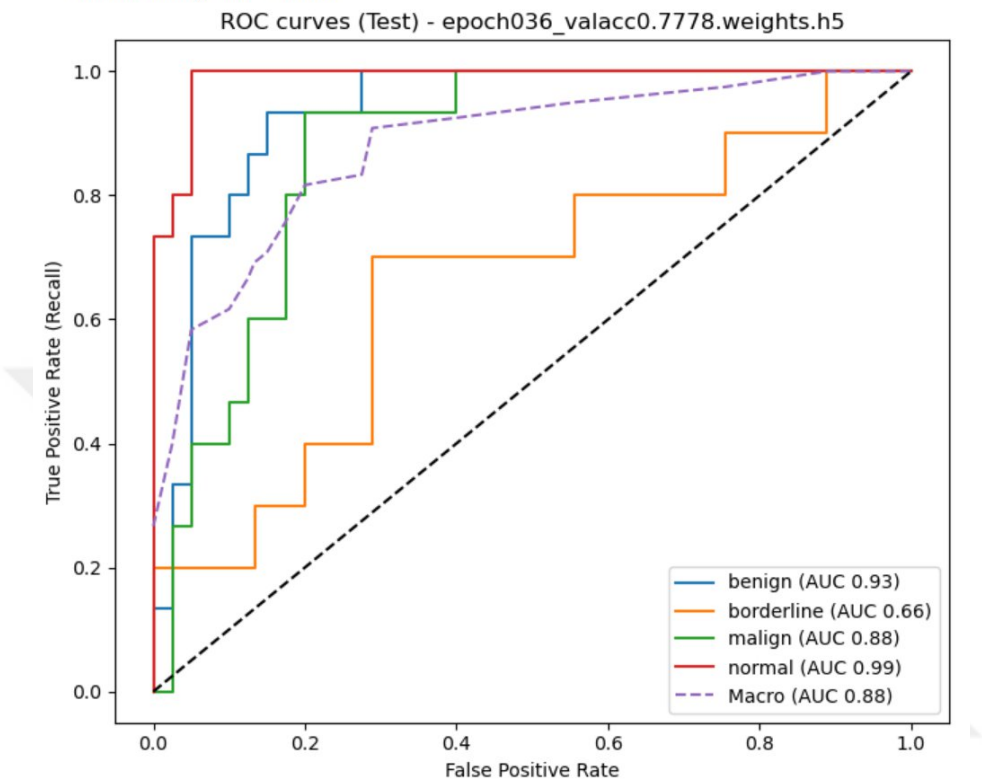
Şekil- 21: MobilenetV2 modeli ROC eğrileri grafiği

DenseNet121 modeli, bellek kısıtlamaları nedeniyle daha küçük bir parti boyutu (batch size = 4) ile eğitilmiş ve test kümesinde %67,27 doğruluk elde etti. Modelin makro ortalama duyarlılık değeri %63,33, kesinlik değeri %63,17 ve F1-skoru %60,78 olarak hesaplandı. Sınıf bazlı analizlerde, modelin özellikle "borderline" kitleleri sınıflandırmada yetersiz kaldığı görülmüş; bu grupta duyarlılık yalnızca %20,00'de kaldı. Buna karşılık, "normal" görüntülerin sınıflandırılmasında son derece başarılı sonuçlar elde edilmiş; %88,24 kesinlik ve %100,00 duyarlılık oranlarına ulaşıldı (Şekil-22).

ROC eğrisi analizi, DenseNet121'in genel sınıflandırma gücünün kabul edilebilir düzeyde olduğunu gösterdi (makro ortalama AUC = 0,8789) (Şekil-23).



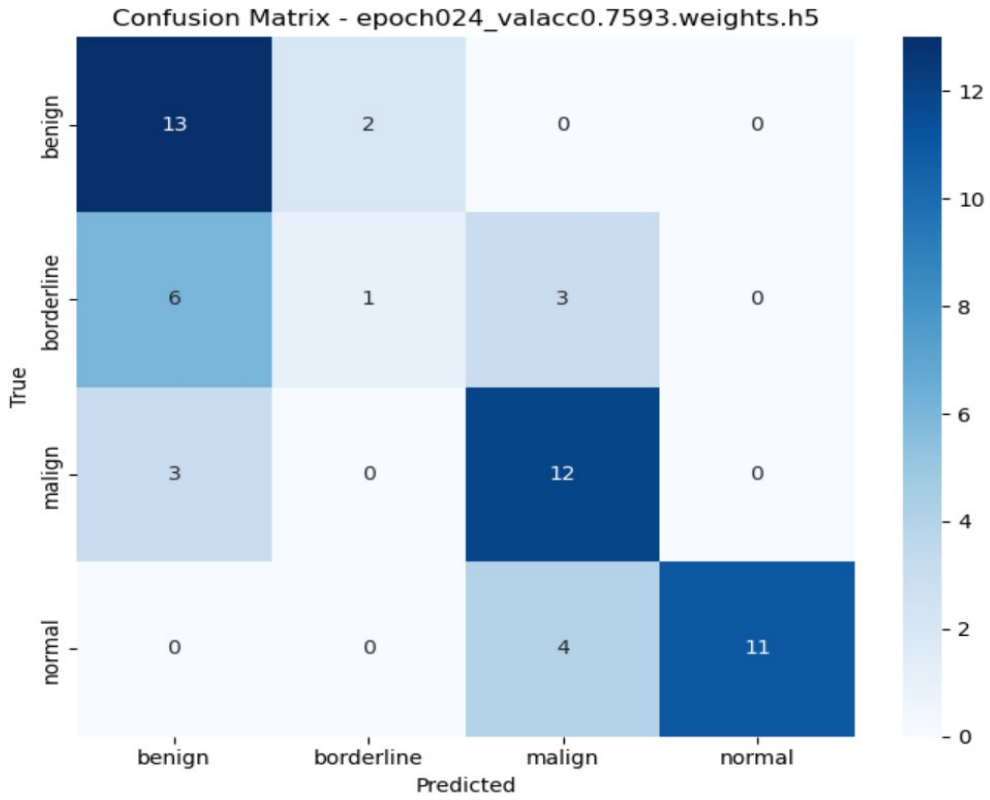
Şekil-22: DenseNet121 modeli hata matrisleri şeması



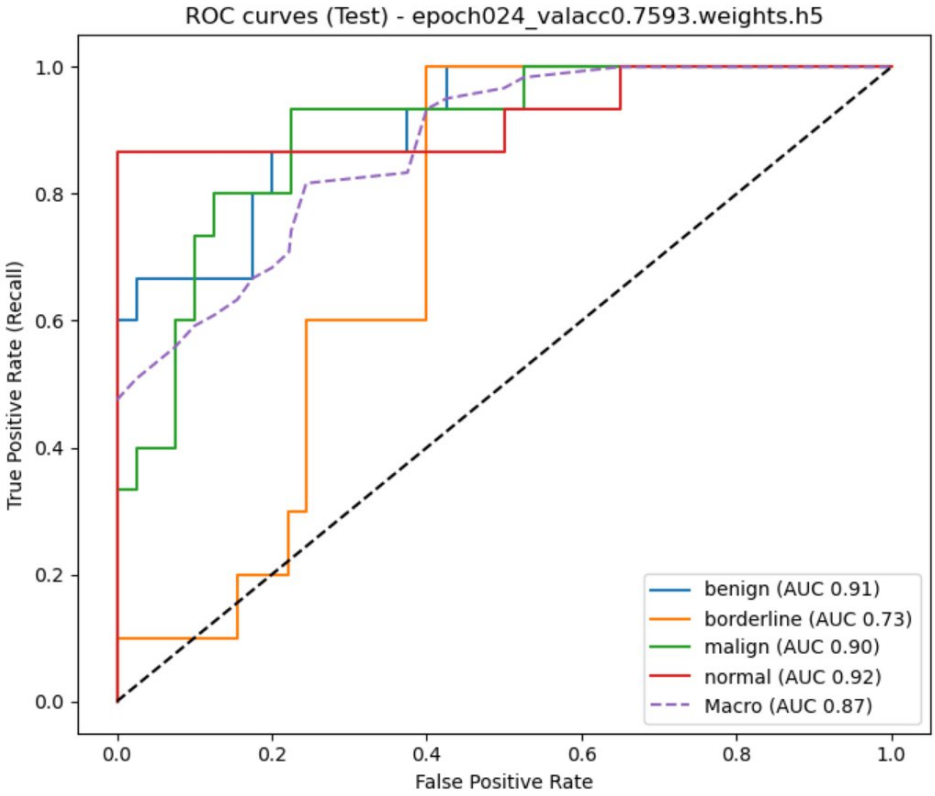
Şekil-23: DenseNet121 modeli ROC eğrileri grafiği

InceptionV3 modeli, test kümesinde %67,27 doğruluk elde etmiştir. Modelin makro ortalama duyarlılığı %62,50, kesinliği %63,90 ve F1-skoru %60,21 olarak hesaplandı. Hata matrisi incelendiğinde, modelin özellikle "borderline" kitleleri sınıflandırmada yetersiz kaldığı ve bu grupta duyarlılığın yalnızca %10,00 olduğu görüldü. Ayrıca bazı malign kitlelerin yanlış şekilde "normal" görüntü olarak sınıflandırıldığı tespit edildi (Şekil-24).

ROC eğrisi analizi, InceptionV3'ün genel sınıflandırma gücünün makro ortalama AUC = 0,8730 ile kabul edilebilir düzeyde olduğunu gösterdi (Şekil-25).



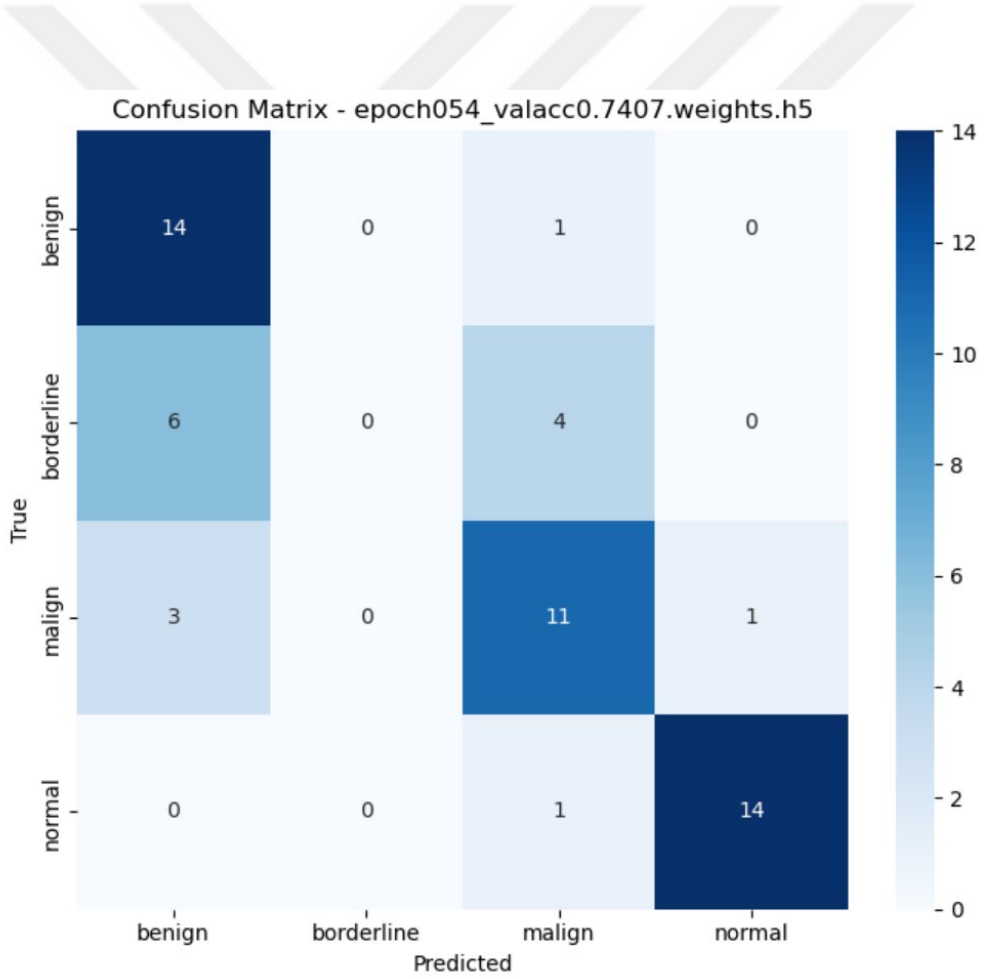
Şekil-24: InceptionV3 modeli hata matrisleri şeması



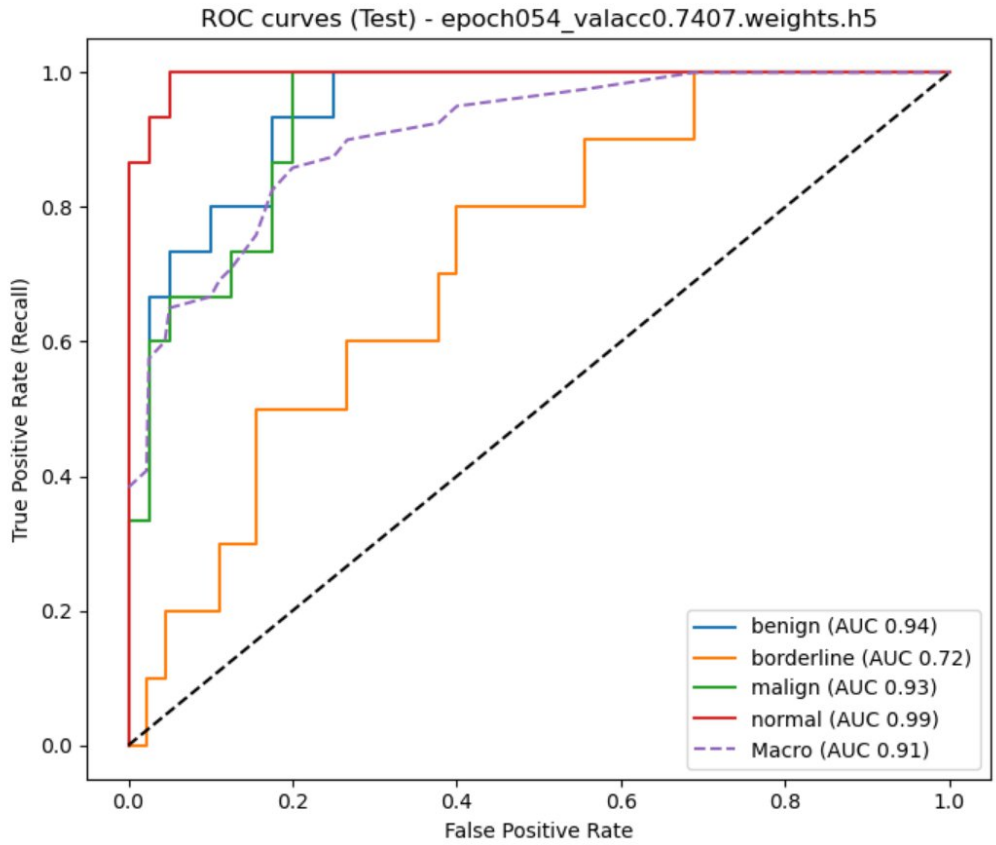
Şekil-25: InceptionV3 modeli ROC eğrileri grafiği

InceptionResNetV2 modeli, %70,91 test doğruluğu ile EfficientNetV2B0'dan sonra en yüksek ikinci performansı gösterdi. Modelin makro ortalama duyarlılığı %65,00, kesinliği %54,73 ve F1-skoru %58,94 olarak hesaplandı. Sınıf bazlı analizlerde, modelin özellikle "borderline" kitleleri sınıflandırmada başarısız olduğu görüldü; bu grupta duyarlılık %0,00 olarak bulunmuş ve hiçbir vakanın doğru tahmin edilemediği tespit edildi. Buna karşın, model benign kitleler ve normal görüntüleri oldukça başarılı şekilde sınıflandı, her iki grup için de %93,33 duyarlılık elde edildi (Şekil-26).

ROC eğrisi analizi, modelin genel sınıflandırma gücünün yüksek olduğunu ortaya koymuştur (makro ortalama AUC = 0,9069) (Şekil-27).



Şekil-26: InceptionResNetV2 modeli hata matrisleri şeması



Şekil-27: InceptionResNetV2 modeli ROC eğrileri grafiği

Analiz sonuçları, kullanılan derin öğrenme mimarileri arasında EfficientNetV2B0 modelinin en yüksek genel performansı sergilediğini göstermektedir. Bu model, diğerlerine kıyasla daha dengeli bir kesinlik (precision) ve duyarlılık (recall) oranı sunmuş, özellikle benign kitlelerin ve normal görüntülerin doğru sınıflandırılmasında üstün başarı sağlamıştır.

Çalışmada değerlendirilen tüm modellerin makro ortalama performans değerleri ile sınıf bazlı (alt grup) analiz sonuçları, karşılaştırmayı kolaylaştırmak amacıyla aşağıda ayrı tablolar halinde sunulmuştur:

Model Adı	Doğruluk	Duyarlılık	Kesinlik	F-Skoru	ROC-AUC
EfficientNetV2B0	0,7455	0,7333	0,7401	0,7353	0,917
MobileNetV2	0,6545	0,6167	0,6249	0,6136	0,8645
DenseNet121	0,6727	0,6333	0,6317	0,6078	0,8789
InceptionV3	0,6727	0,625	0,639	0,6021	0,873
InceptionResNetV2	0,7091	0,65	0,5473	0,5894	0,9069

Tablo-7: Tüm Modellerin Makro Ortalama Performans Değerleri

Model Adı	Duyarlılık	Kesinlik	F-Skoru	ROC-AUC
EfficientNetV2B0	0,8	0,9231	0,8571	0,99
MobileNetV2	0,9333	0,8235	0,875	0,9483
DenseNet121	1,0	0,8824	0,9375	0,9883
InceptionV3	0,7333	1,0	0,8462	0,9233
InceptionResNetV2	0,9333	0,9333	0,9333	0,995

Tablo-8: Tüm Modellerin Normal Görüntülerdeki Performans Değerleri

Model Adı	Duyarlılık	Kesinlik	F-Skoru	ROC-AUC
EfficientNetV2B0	0,8	0,9231	0,7742	0,9533
MobileNetV2	0,6	0,4737	0,5294	0,8267
DenseNet121	0,9333	0,6087	0,7368	0,9317
InceptionV3	0,8667	0,5909	0,7027	0,9083
InceptionResNetV2	0,9333	0,6087	0,7368	0,9417

Tablo-9: Tüm Modellerin Benign Kitlelerdeki Performans Değerleri

Model Adı	Duyarlılık	Kesinlik	F-Skoru	ROC-AUC
EfficientNetV2B0	0,6	0,6	0,6	0,8044
MobileNetV2	0,2	0,2857	0,2353	0,7267
DenseNet121	0,2	0,2857	0,2353	0,66
InceptionV3	0,1	0,3333	0,1538	0,7289
InceptionResNetV2	0,0	0,0	0,0	0,7222

Tablo-10: Tüm Modellerin Borderline Kitlelerdeki Performans Değerleri

Model Adı	Duyarlılık	Kesinlik	F-Skoru	ROC-AUC
EfficientNetV2B0	0,7333	0,6875	0,7097	0,8767
MobileNetV2	0,7333	0,9167	0,8148	0,915
DenseNet121	0,4	0,75	0,5217	0,875
InceptionV3	0,8	0,6316	0,7059	0,8967
InceptionResNetV2	0,7333	0,6471	0,6875	0,9317

Tablo-11: Tüm Modellerin Malign Kitlelerdeki Performans Değerleri

5. TARTIŞMA

Yumurtalık kanseri, tanısı güç bir jinekolojik malignite olup, görüntüleme yöntemleri tanı sürecinde vazgeçilmez bir rol oynamaktadır. Bu amaçla sıklıkla kullanılan görüntüleme yöntemleri arasında ultrasonografi (US), manyetik rezonans görüntüleme (MRG), bilgisayarlı tomografi (BT) ve pozitron emisyon tomografisi (PET) yer almaktadır. MRG, tümörün boyutu ve lokalizasyonunun belirlenmesinde; BT, karın ve pelvik metastazların saptanmasında; PET ise metabolik aktivite ve uzak yayılımın değerlendirilmesinde avantaj sağlar. Derin öğrenme tabanlı yöntemler, bu modalitelerden elde edilen görüntülerin analizi ile tanısal doğruluğu artırma potansiyeli göstermiştir. Literatürde, özellikle MRG ve BT verilerine dayalı makine öğrenmesi çalışmalarının ön planda olduğu görülmektedir (56).

Wang ve ark. (2020), over tümörlerinin MRG görüntülerinin makine öğrenmesi ile değerlendirilmesi üzerine yaptıkları çalışmada, tek merkezden 451 hastaya ait 554 lezyonu (379 benign, 166 malign) analiz etmiş ve verileri 7:2:1 oranında eğitim, doğrulama ve test setlerine ayırmıştır. Modelin performansı test setinde dört genç ve üç kıdemli radyolog ile karşılaştırılmıştır. Çalışmada benign hastaların yaş ortalaması 45,7 ± 16,7 yıl, malign hastaların yaş ortalaması ise 49,9 ± 18,1 yıl olarak bildirilmiştir (53). Bizim çalışmamızda ise benign grupta ortalama yaş 49,3, malign grupta 51,8, borderline grupta ise 42,7 olarak hesaplanmış olup, literatürle uyumlu şekilde borderline hastaların daha genç yaş grubunda görüldüğü saptanmıştır. Veri setimizde %70 eğitim, %15 doğrulama ve %15 test oranı kullanılmıştır. Ancak çalışmamızın önemli bir sınırlılığı, Wang ve ark.'nın çalışmasında olduğu gibi model performansının radyolog değerlendirmeleriyle doğrudan karşılaştırılmamış olmasıdır. Bu durum, modelimizin klinik pratikteki potansiyelini tam olarak ortaya koyma noktasında bir kısıtlılık oluşturmaktadır.

Wang ve ark. çalışmasında geliştirilen model, genç radyologların ortalama performansına kıyasla daha üstün bulunmuştur. Örneğin, EfficientNet modeli test setinde %87 doğruluk, %92 özgüllük ve %75 duyarlılık sağlamış; genç radyologların ise doğruluk (%64), özgüllük (%64) ve duyarlılık (%63) değerlerinin üzerinde performans göstermiştir. Kıdemli radyologlarla karşılaştırıldığında da modelin doğruluk (%87'ye karşı %74) ve özgüllük (%92'ye karşı %70) açısından daha başarılı olduğu, duyarlılığın ise benzer seviyede kaldığı görülmüştür (%75'e

karşı %83). Ayrıca yapay zekâ desteğiyle genç radyologların özgüllükleri, kıdemlilere göre daha yüksek bulunmuştur (%81'e karşı %70) (53).

Çalışmamızda ise borderline, malign, benign ve sağlıklı olgular birlikte değerlendirilmiş, en yüksek doğruluk EfficientNet modeli tarafından %74 olarak elde edilmiştir. Bu görece daha düşük doğruluk oranının, borderline tümörlerin ayrı bir grup olarak ele alınmasından ve bu grubun heterojen doğasından kaynaklandığı düşünülmektedir. Bununla birlikte, sınıflandırma performansını değerlendirmede kritik öneme sahip ROC-AUC değerimiz %91 olarak hesaplanmış, Wang ve ark.'nın %79–82 aralığındaki sonuçlarından daha yüksek bulunmuştur. Bu bulgu, modelimizin pozitif ve negatif sınıfları ayırt etme yeteneğinin belirgin şekilde daha güçlü olduğunu ve klinik uygulamalarda doğru tanı ve tedavi planlamasına daha etkin katkı sağlayabileceğini göstermektedir.

Liu ve ark. (54), makine öğrenmesi kullanarak MRG verileriyle malign ve borderline epitelyal tümörlerin ayrımını incelemiş ve çalışmaya 95 borderline ile 101 malign hasta dahil etmiştir. Araştırmada, T2-ağırlıklı görüntüleme (T2WI) tabanlı radyomik imza özelliklerinin ayırt edici gücü değerlendirilmiş, ayrıca 2D ve 3D segmentasyon modellerinin performansları karşılaştırılmıştır. Test grubunda 2D ve 3D koronal T2WI tabanlı radyomik modellerin doğruluk değerleri sırasıyla %79 ve %83; 2D ve 3D sagital yağ baskılı (fs) T2WI tabanlı modellerin doğrulukları ise sırasıyla %78 ve %99 olarak bulunmuştur. Çalışmamızda elde edilen doğruluk değerleri, Liu ve ark.'nın 2D MRG verileri ile yaptıkları analizlere benzerlik göstermektedir. Bununla birlikte, 3D segmentasyonun görüntüleri farklı açılardan değerlendirme olanağı sunması nedeniyle model başarısını artırdığı görülmekte, bu yaklaşımın gelecekte daha yüksek tanısal doğruluk sağlayabileceği öngörülmektedir.

Saida ve ark. (55), over kanserlerinde MRG ile derin öğrenme tabanlı modellerin ve radyologların tanısal performanslarını karşılaştırmışlardır. Çalışmada hastalar her MRG sekansı için malign ve malign olmayan olmak üzere iki gruba ayrılmış, borderline over tümörleri de malign grubuna dahil edilmiştir. Toplamda 146 malign hastadan 1798 görüntü ve 219 malign olmayan hastadan 1865 görüntü eğitim amacıyla kullanılmış, test için ise 48 malign ve 52 malign olmayan görüntü ayrılmıştır. Uygulanan CNN modelleri her bir sekans için %77–85 duyarlılık, %77–92 özgüllük, %81–87 doğruluk ve 0.83–0.89 AUC değerleri ile radyologların performansına eşdeğer bir başarı sergilemiştir. Bununla birlikte, bu çalışmada her sekansın ayrı ayrı değerlendirilmesi, klinik pratikte olduğu gibi tüm sekansların birlikte yorumlandığı kapsamlı bir tanısal yaklaşımı tam olarak yansıtmamaktadır. Ayrıca borderline tümörlerin

malign grubuna dahil edilmesi, patolojik ve klinik yönetim açısından farklılık arz eden bu lezyonların özgün özelliklerinin göz ardı edilmesine yol açmış ve modelin gerçek ayırt etme kapasitesinin daha derinlemesine incelenmesini kısıtlamıştır.

Li Y ve ark. (56), MRG tabanlı makine öğrenmesi ile malign ve benign epitelyal over tümörlerinin ayrımını incelemiş, 165 borderline ve 338 malign epitelyal tümörü çalışmaya dahil etmiştir. Modellerin özellikle borderline epitelyal over tümörleri ile erken evre malign epitelyal tümörler arasındaki ayırt edici gücü de değerlendirilmiş ve sırasıyla 0.909 ve 0.920 AUC değerleri elde edilmiştir. Radyologların performansı ise hem iç (ortalama AUC = 0.792; aralık 0.679–0.924) hem de dış (ortalama AUC = 0.797; aralık 0.744–0.867) doğrulama gruplarında modelin belirgin şekilde altında kalmıştır. Bu çalışmanın önemli sınırlılıklarından biri, modelin yalnızca borderline ve malign epitelyal tümörler arasındaki ayrımı hedeflemesidir. Bizim çalışmamızda ise benzer AUC değerleri elde edilmiş olmakla birlikte, ek olarak benign epitelyal tümörler ve sağlıklı kontrol grupları da analize dahil edilmiştir. Bu durum, modelimizin daha geniş bir klinik spektrumda uygulanabilirliğini göstermektedir.

Barcroft ve ark. (57), makine öğrenmesi ve radyomik analiz yöntemlerini kullanarak ultrason tabanlı adneksiyel kitle segmentasyonu ve sınıflandırmasını incelemişlerdir. Çalışma, İngiltere'deki Imperial College Healthcare'den 577 kitleye ait 1444 görüntü ile İtalya'daki Morgagni-Pierantoni Hastanesi'nden 184 kitleye ait 476 görüntüden oluşan iki ayrı kohort üzerinde gerçekleştirilmiştir. Geliştirilen modelin tahminsel performansı (AUC = 0.90), uzmanların öznel değerlendirmeleri ve mevcut risk modellerinin literatürde bildirilen performansları ile karşılaştırılabilir düzeyde bulunmuştur. Bizim çalışmamızda ultrason yerine MRG görüntüleri kullanılmış olmasına rağmen, elde edilen AUC değerleri Barcroft ve ark.'nın bulgularıyla benzerlik göstermektedir. Bu durum, farklı görüntüleme modalitelerinden elde edilen verilerin makine öğrenmesi yöntemleri ile analiz edildiğinde karşılaştırılabilir düzeyde yüksek performans sağlayabileceğini göstermektedir.

Sıbıç ve ark. (58), makine öğrenmesi ve yapay zekâ tabanlı bilgisayarlı tomografi (BT) görüntü analizi ile akut apandisit tanısının değerlendirilmesine yönelik yaptıkları çalışmada, BT verilerini kullanarak %80 doğruluk oranı elde etmişlerdir

5.1. Çalışmanın Güçlü Yönleri ve Sınırlılıkları

Çalışmamızın güçlü yönleri arasında, benign, malign, borderline tümörler ile sağlıklı kontrollerin birlikte değerlendirilmiş olması ve böylelikle literatürde sınırlı sayıda ele alınan borderline tümör grubuna özel katkı sağlanması yer almaktadır. Ayrıca geniş bir MRG veri setinden yararlanılmış, farklı derin öğrenme mimarileri karşılaştırılmış ve ROC-AUC performansının literatüre kıyasla yüksek bulunması, çalışmanın özgün değerini artırmıştır.

Bununla birlikte bazı sınırlılıklar da mevcuttur. Öncelikle borderline hasta sayısının sınırlı kalması, bu alt grupta modelin genellenebilirliğini kısıtlamıştır. Ayrıca çalışmanın retrospektif tasarımı, prospektif bir araştırmanın sağlayabileceği sistematik veri toplama ve standardizasyon avantajlarını barındırmamaktadır. Tek merkezli bir tasarımın kullanılması da modellerin farklı merkezlerde uygulanabilirliğini sınırlandırmaktadır. Gelecekte yapılacak çok merkezli, prospektif ve daha dengeli örneklem büyüklüklerine sahip çalışmaların, yapay zekâ tabanlı modellerin klinik kullanıma entegrasyonunu güçlendireceği düşünülmektedir.

6.SONUÇ

Bu çalışmada, adneksiyel kitlelerin manyetik rezonans (MR) görüntülerini sınıflandırmak amacıyla EfficientNetV2B0, MobileNetV2, DenseNet121, InceptionV3 ve InceptionResNetV2 olmak üzere beş farklı derin öğrenme modeli karşılaştırılmıştır. Elde edilen bulgular, bu modellerin genel olarak adneksiyel kitlelerin sınıflandırılmasında potansiyel sunduğunu, ancak performans düzeylerinde belirgin farklılıklar bulunduğunu göstermiştir.

Analizler sonucunda EfficientNetV2B0, %74,55'lik test doğruluğu ve 0,917'lik ROC-AUC değeri ile en yüksek genel performansı sergileyen model olmuştur. Özellikle benign kitleler ve normal olguların sınıflandırılmasında yüksek doğruluk sağlamıştır. Bununla birlikte, tüm modellerin borderline tümörleri ayırt etmede güçlük yaşadığı gözlenmiştir. Bu durum, borderline tümörlerin heterojen yapısı ve benign–malign özellikler arasında geçişkenlik göstermesiyle açıklanabilir. Borderline olguların doğru sınıflandırılması, modellerin klinik pratiğe entegrasyonu açısından kritik bir zorluk oluşturmaktadır.

Sonuç olarak, çalışmamız yapay zekâ destekli görüntü analizinin jinekolojik onkoloji alanında umut verici bir tanısal araç olabileceğini ortaya koymaktadır. Ancak, makine öğrenimi modellerinin klinik karar verme süreçlerinde güvenilir bir şekilde kullanılabilmesi için özellikle nadir görülen veya tanısal açıdan karmaşık tümör tiplerinde performansın artırılması gerekmektedir. Gelecekte yapılacak araştırmaların, borderline lezyonların doğru sınıflandırılmasına yönelik daha gelişmiş algoritmalara, daha geniş ve dengeli veri setlerine ve çok merkezli çalışmalara odaklanması önerilmektedir.

7. KAYNAKLAR

1) Rauh-Hain JA, Melamed A, Buskwofie A, Schorge JO. Adnexal mass in the postmenopausal patient. Clin Obstet Gynecol 2015; 58:53.
2) Healy DL, Bell R, Robertson DM, et al. Ovarian status in healthy postmenopausal women. Menopause 2008; 15:1109.
3) Seungdamrong, A., & Weiss, G. (2007). Ovulation in a postmenopausal woman. Fertility and Sterility, *88*(5), 1438.e1. https://doi.org/10.1016/j.fertnstert.2007.03.047
4) Kumar V, Abbas AK, Fausto N, et al. Robbins and Cotran Pathologic Basis of Disease, Professional Edition, 8th ed, Saunders, Philadelphia 2009.
5) You, W., Dainty, L. A., Rose, G. S., et al. (2005). Gynecologic malignancies in women aged less than 25 years. *Obstetrics & Gynecology*, *105*(6), 1405–1409. https://doi.org/10.1097/01.AOG.0000164628.79975.d4
6) Gilman, J., & Stein, H. (1941). The corpus luteum of pregnancy. Surgery, Gynecology & Obstetrics, *72*, 129.
7) Levine, D., Brown, D. L., Andreotti, R. F., et al. (2010). Management of asymptomatic ovarian and other adnexal cysts imaged at US: Society of Radiologists in Ultrasound Consensus Conference Statement. *Radiology*, *256*(3), 943–956. https://doi.org/10.1148/radiol.10100418
8) Jain, K. A. (2002). Sonographic spectrum of hemorrhagic ovarian cysts. *Journal of Ultrasound in Medicine*, *21*(8), 879–886. https://doi.org/10.7863/jum.2002.21.8.879
9) Clement, P. B. (1993). Tumor-like lesions of the ovary associated with pregnancy. *International Journal of Gynecological Pathology*, *12*(2), 108–115.
10) Nowak, M., Szpakowski, M., Malinowski, A., et al. (2002). [Ovarian tumors in the reproductive age group]. *Ginekologia Polska*, *73*(4), 354–358.
11) Killackey, M. A., & Neuwirth, R. S. (1988). Evaluation and management of the pelvic mass: a review of 540 cases. *Obstetrics & Gynecology*, *71*(3), 319–322.
12) Kurman, R. J., Ellenson, L. H., & Ronnett, B. (2011). *Blaustein's Pathology of the Female Genital Tract* (6th ed.). Springer.

13) Heremans, R., Valentin, L., Sladkevicius, P., & van den Bosch, T. (2022). Imaging in gynecological disease (24): clinical and ultrasound characteristics of ovarian mature cystic teratomas. *Ultrasound in Obstetrics & Gynecology*, *60*(4), 549–559. https://doi.org/10.1002/uog.26084

14) Caspi, B., Appelman, Z., Rabinerson, D., et al. (1996). Pathognomonic echo patterns of benign cystic teratomas of the ovary: classification, incidence and accuracy rate of sonographic diagnosis. *Ultrasound in Obstetrics & Gynecology*, *7*(4), 275–279.

15) Batt, R. E., & Yeh, J. (2013). Müllerianosis: Four developmental (embryonic) mullerian diseases. *Reproductive Sciences*, *20*(9), 1030–1043. https://doi.org/10.1177/1933719113483925

16) Rajarubendra, N., Leang, Y., & Monsour, M. (2015). Mullerianosis of the urinary bladder. *ANZ Journal of Surgery*, *85*(4), 292–293. https://doi.org/10.1111/ans.12643

17) Baker, P. M., Clement, P. B., & Young, R. H. (2014). Selected topics in peritoneal pathology. *International Journal of Gynecological Pathology*, *33*(4), 393–404. https://doi.org/10.1097/PGP.0000000000000091

18) Cancer Stat Facts: Ovarian Cancer. National Cancer Institute. National Institutes of Health. https://seer.cancer.gov/statfacts/html/ovary.html.

19) Kinkel, K., Lu, Y., Mehdizade, A., et al. (2005). Indeterminate ovarian mass at US: Incremental value of second imaging test for characterization—meta-analysis and Bayesian analysis. *Radiology*, *236*(1), 85–94. https://doi.org/10.1148/radiol.2361040854

20) Heintz, A. P., Odicino, F., Maisonneuve, P., et al. (2001). Carcinoma of the ovary. *Journal of Epidemiology and Biostatistics*, *6*(1), 107–121.

21) Lee K, Tavassoli FA, Prat J, et al. Tumors of the ovary and peritoneum. In: World Health Organization Classification of Tumours: Pathology and Genetics of Tumours of the Breast and Female Genital Organs, IARC Press, Lyon, France 2003. p.117.

22) Sagae, S., & Kudo, R. (2000). Surgery for germ cell tumors. *Seminars in Surgical Oncology*, *19*(1), 76–81. https://doi.org/10.1002/1098-2974(200007)19:1<76::AID-SSU11>3.0.CO;2-4

23) Zalel, Y., Piura, B., Elchalal, U., et al. (1996). Diagnosis and management of malignant germ cell ovarian tumors in young females. *International Journal of Gynaecology and Obstetrics*, *55*(1), 1–5. https://doi.org/10.1016/S0020-7292(96)02720-9

24) Young, R. H. (2005). Sex cord-stromal tumors of the ovary and testis: their similarities and differences with consideration of selected problems. *Modern Pathology*, *18*(Suppl. 2), S81–S96. https://doi.org/10.1038/modpathol.3800244

25) Quirk, J. T., & Natarajan, N. (2005). Ovarian cancer incidence in the United States, 1992-1999. *Gynecologic Oncology*, *97*(2), 519–525. https://doi.org/10.1016/j.ygyno.2005.02.030

26) Moore, R. G., Chung, M., Granai, C. O., et al. (2004). Incidence of metastasis to the ovaries from nongenital tract primary tumors. *Gynecologic Oncology*, *93*(1), 87–91. https://doi.org/10.1016/j.ygyno.2003.12.012

27) Savelli, L., de Iaco, P., Ghi, T., et al. (2004). Transvaginal sonographic appearance of peritoneal pseudocysts. *Ultrasound in Obstetrics & Gynecology*, *23*(3), 284–288. https://doi.org/10.1002/uog.980

28) *Goff BA, Mandel L, Muntz HG. Melancon CH. Ovarian carcinoma diagnosis. Cancer 2000; 89:2068.*

29) González-Martín, A., Harter, P., Leary, A., et al. (2023). Newly diagnosed and relapsed epithelial ovarian cancer: ESMO Clinical Practice Guideline for diagnosis, treatment and follow-up. *Annals of Oncology*, *34*(10), 833–851. https://doi.org/10.1016/j.annonc.2023.07.009

30) Prat, J., & FIGO Committee on Gynecologic Oncology. (2014). Staging classification for cancer of the ovary, fallopian tube, and peritoneum. *International Journal of Gynaecology and Obstetrics*, *124*(1), 1–5. https://doi.org/10.1016/j.ijgo.2013.10.001

31) Andreotti, R. F., Timmerman, D., Strachowski, L. M., et al. (2020). O-RADS US Risk Stratification and Management System: A Consensus Guideline from the ACR Ovarian-Adnexal Reporting and Data System Committee. *Radiology*, *294*(1), 168–180. https://doi.org/10.1148/radiol.2019191140

32) Andreotti RF, Timmerman D, Strachowski LM, et al. O-RADS US Risk Stratification and Management System: A Consensus Guideline from the ACR Ovarian-Adnexal Reporting and Data System Committee. Radiology 2020;294(1):168–185.

33) Timmerman D, Ameye L, Fischerova D, et al. Simple ultrasound rules to distinguish between benign and malignant adnexal masses before surgery: prospective validation by IOTA group. BMJ 2010;341:c6839

34) Thomassin-Naggara I, Poncelet E, Jalaguier-Coudray A, et al. Ovarian-Adnexal Reporting Data System Magnetic Resonance Imaging (O-RADS MRI) Score for Risk Stratification of Sonographically Indeterminate Adnexal Masses. JAMA Netw Open 2020;3(1):e1919896.
35) Sadowski EA, Paroder V, Patel-Lippmann K, et al. Indeterminate Adnexal Cysts at US: Prevalence and Characteristics of Ovarian Cancer. Radiology 2018;287(3):1041–1049.
36) Kaijser J, Vandecaveye V, Deroose CM, et al. Imaging techniques for the presurgical diagnosis of adnexal tumours. Best Pract Res Clin Obstet Gynaecol 2014;28(5):683–695.
37) Kinkel K, Lu Y, Mehdizade A, Pelte MF, Hricak H. Indeterminate ovarian mass at US: incremental value of second imaging test for characterization— meta-analysis and Bayesian analysis. Radiology 2005;236(1):85–94.
38) Anthoulakis C, Nikoloudis N. Pelvic MRI as the "gold standard" in the subsequent evaluation of ultrasound-indeterminate adnexal lesions: a systematic review. Gynecol Oncol 2014;132(3):661–668.
39) ACR-O-RADS-MRI-Lexicon. https://www.acr.org/Clinical-Resources/Reporting-and-Data-Systems/O-Rads#MRI. Accessed November 3, 2020.
40) O-RADS-MR-Risk-Stratification-System-Table. https://www.acr.org/Clinical-Resources/Reporting-and-Data-Systems/O-Rads#MRI. Accessed October 16, 2020.

41) Thomassin-Naggara, I., Aubert, E., Rockall, A. G., et al. (2020). O-RADS MRI Score for Risk Stratification of Sonographically Indeterminate Adnexal Masses. *JAMA Network Open, 3*(1), e1919896. https://doi.org/10.1001/jamanetworkopen.2019.19896

42) Hashimoto DA, Rosman G, Rus D, Meireles OR. Artificial Intelligence in Surgery: Promises and Perils. Ann Surg. 2018;268(1):70-76. doi:10.1097/SLA.0000000000002693
43) Arnaout, R.; Curran, L.; Zhao, Y.; Levine, J.; Chinn, E.; Moon-Grady, A. An ensemble of neural networks provides expert-level prenatal detection of complex congenital heart disease. Nat. Med. 2021, 27, 882–891.

44) Gulshan, V.; Peng, L.; Coram, M.; Stumpe, M.; Wu, D.; Narayanaswamy, A.; Venugopalan, S.; Widner, K.; Madams, T.; Cuadros, J.; et al. Development and Validation of a Deep Learning Algorithm for Detection of Diabetic Retinopathy in Retinal Fundus Photographs. JAMA 2016, 316, 2402–2410.

45) Gao, Y.; Zeng, S.; Xu, X.; Li, H.; Yao, S.; Song, K.; Li, X.; Chen, L.; Tang, J.; Xing, H.; et al. Deep learning-enabled pelvic ultrasound images for accurate diagnosis of ovarian cancer in China: A retrospective, multicentre, diagnostic study. Lancet Digit. Health 2022, 4, e179–e187.

46) Object Detection vs Object Recognition vs Image Segmentation [Internet]. GeeksforGeeks. 2020 Available from: https://www.geeksforgeeks.org/object-detection-vs-object-recognition-vsimage-segmentation/

47) LeCun Y, Boser BE, Denker JS, Henderson D, Howard RE, Hubbard WE et al. Backpropagation Applied to Handwritten Zip Code Recognition. Neural Computation, 1, 1989, 541-51. doi: doi: doi.org/10.1162/neco.1989.1.4.541

48) Amidi A, Amidi S. CS 230 - Convolutional Neural Networks cheatsheet [Internet], Stanford Edu, Available from: https://stanford.edu/~shervine/l/tr/teaching/cs-230/cheatsheet-convolutionalneural-networks

49) Khan, Z. A., Waqar, M., Khan, H. U., Chaudhary, N. I., Khan, A. T. M., Ishtiaq, I., Khan, F. A., & Raja, M. A. Z. (2025). Fine-tuned deep transfer learning: an effective strategy for the accurate chronic kidney disease classification. *PeerJ Computer Science*, *11*, e2800. https://doi.org/10.7717/peerj-cs.2800

50) Zhang, J., Yu, X., Lei, X., & Wu, C. (2022). A novel CapsNet neural network based on MobileNetV2 structure for robot image classification. *Frontiers in Neurorobotics*, *16*, 1007939. https://doi.org/10.3389/fnbot.2022.1007939

51) Hariri, M., Aydın, A., Sıbıç, O., Somuncu, E., Yılmaz, S., Sönmez, S., & Avşar, E. (2025). LesionScanNet: dual-path convolutional neural network for acute appendicitis diagnosis. *Health Information Science and Systems*, *13*(1), 3. https://doi.org/10.1007/s13755-024-00321-7

52) Sadeghi MH, Sina S, Omidi H, Farshchitabrizi AH, Alavi M. Deep learning in ovarian cancer diagnosis: a comprehensive review of various imaging modalities. Pol J Radiol. 2024;89:e30-e48. doi: 10.5114/pjr.2024.134817.

53) Wang R, Cai Y, Lee IK, Hu R, Purkayastha S, Pan I, et al**.** Evaluation of a convolutional neural network for ovarian tumor differentiation based on magnetic

resonance imaging. Eur Radiol. 2020;30(11):6201-6209. doi:10.1007/s00330-020-07266-x.

54) Liu X, Wang T, Zhang G, Hua K, Jiang H, Duan S, et al. Two-dimensional and three-dimensional T2 weighted imaging-based radiomic signatures for the preoperative discrimination of ovarian borderline tumors and malignant tumors. J Ovarian Res. 2022;15:22. doi:10.1186/s13048-022-00943-z.

55) Saida T, Mori K, Hoshiai S, Sakai M, Urushibara A, Ishiguro T, et al. Diagnosing Ovarian Cancer on MRI: A Preliminary Study Comparing Deep Learning and Radiologist Assessments. Cancers. 2022;14(4):987. doi:10.3390/cancers14040987.

56) Li Y, Jian J, Pickhardt PJ, Ma F, Xia W, Li H, et al. MRI-Based Machine Learning for Differentiating Borderline From Malignant Epithelial Ovarian Tumors: A Multicenter Study. J Magn Reson Imaging. 2020;52(3):897-904. doi:10.1002/jmri.27084.

57) Barcroft JF, Linton-Reid K, Landolfo C, Al-Memar M, Parker N, Kyriacou C, et al. Machine learning and radiomics for segmentation and classification of adnexal masses on ultrasound. npj Digit Med. 2024;7:152. doi:10.1038/s41698-024-00527-8.

58) Sibic O, Somuncu E, Yilmaz S, Avsar E, Bozdag E, Ozcan A, et al. Diagnosis of Acute Appendicitis with Machine Learning-Based Computer Tomography: Diagnostic Reliability and Role in Clinical Management. J Laparoendosc Adv Surg Tech A. 2025;35(4):1. doi:10.1089/lap.2024.0374.

9. EKLER