T.C. SAĞLIK BİLİMLERİ ÜNİVERSİTESİ, KANUNİ SULTAN SÜLEYMAN SAĞLIK UYGULAMA VE ARAŞTIRMA MERKEZİ

GENEL CERRAHİ KLİNİĞİ

MAKİNE ÖĞRENMESİ VE YAPAY ZEKÂ TABANLI BİLGİSAYAR TOMOGRAFİ ANALİZİ İLE AKUT APANDİSİT TANISININ DEĞERLENDİRİLMESİ

Dr. Osman SIBIÇ

(TIPTA UZMANLIK TEZİ)

İSTANBUL 2023

T.C. SAĞLIK BİLİMLERİ ÜNİVERSİTESİ, KANUNİ SULTAN SÜLEYMAN SAĞLIK UYGULAMA VE ARAŞTIRMA MERKEZİ

GENEL CERRAHİ KLİNİĞİ

MAKİNE ÖĞRENMESİ VE YAPAY ZEKÂ TABANLI BİLGİSAYAR TOMOGRAFİ ANALİZİ İLE AKUT APANDİSİT TANISININ DEĞERLENDİRİLMESİ

Dr. Osman Sıbıç

Tez Danışmanı: Doç. Dr. Erkan Somuncu

Doç. Dr. Serhan Yılmaz

(TIPTA UZMANLIK TEZİ)

İSTANBUL 2023

TEŞEKKÜR

Cerrahi hayatımın ilk adımlarını atmamı sağlayan hocam Prof. Dr. Mustafa Uygar KALAYCI'ya ve cerrahi eğitimim esnasında bilgi ve tecrübelerini paylaşan değerli hocam Prof. Dr. Mehmet Abdussamet BOZKURT'a,

Bilgi ve tecrübesiyle gerek cerrahi anlamda gerekse hayatın her alanında yardımlarını ve deneyimlerini esirgemeden paylaşan tez danışmanım değerli hocam Doç. Dr. Serhan YILMAZ'a,

Cerrahi deneyim ve birikimlerini zaman gözetmeksizin her an tereddütsüz bir şekilde paylaşan ve cerrahi eğitimime ciddi anlamda katkı sağlayan tez danışmanım Doç. Dr. Erkan SOMUNCU'ya,

Hastanemize, kliniğimize ve asistanlık sürecinde vermiş olduğu katkılarından dolayı değerli başhekimimiz Prof. Dr. Ali KOCATAŞ'a,

Tez için fikirleri beyan edip beni yönlendiren, yaptığı her cerrahide eğitimime katkı sağlamak için fedakarlıkta bulunan değerli abim Op. Dr. Emre BOZDAĞ'a,

Asistan hekimlik sürecim boyunca tecrübelerini ve bilgilerini esirgemeyen değerli uzman abilerim ve ablalarıma; geçirdiğim süre boyunca hayatıma dahil olan kıymetli kıdemlilerim ve tüm asistan arkadaşlarıma, beraber çalıştığım servis, poliklinik, ameliyathane ve endoskopi birimlerindeki tüm çalışma arkadaşlarıma teşekkür ederim.

İlk anımdan bugüne kadar karşılaştığım her engelde yılmama müsaade etmeden beni destekleyen babam Muhittin SIBIÇ ve annem Ayşe SIBIÇ'a, eğitimimin her anında bilgi ve tecrübesiyle beni yönlendiren sevgili abim Okan SIBIÇ'a sonsuz teşekkür ederim.

Dr. Osman SIBIÇ

İÇİNDEKİLER

TEŞEKKÜR i
İÇİNDEKİLER ii
TABLOLAR iv
ŞEKİLLER v
SİMGELER VE KISALTMALAR v
ÖZET vii
ABSTRACT ix
1. GİRİŞ VE AMAÇ 1
2. GENEL BİLGİLER 3
2.1. APENDİKS VERMİFORMİS 3
2.1.1 Tarihçe 3
2.1.2 Embriyoloji 4
2.1.3 Anatomi 5
2.1.4 Histoloji 7
2.1.5 Fizyoloji 8
2.2. AKUT APANDİSİT 8
2.2.1. Akut Apandisit Epidemiyolojisi 8
2.2.2. Akut Apandisit Etiyoloji 9
2.2.3. Akut Apandisit Patogenezi 9
2.2.4. Klinik Tablo 10
2.2.4.1. Semptomlar (Anamnez) 10
2.2.4.2. Fizik Muayene 11
2.2.5. Laboratuvar Bulguları 13
2.2.6. Klinik Skorlama Sistemleri 14
2.2.6.1. Apandisit İnflamatuar Yanıt (AIR) Skoru 14
2.2.6.2. Alvarado Skoru 15
2.2.6.3. Raja Isteri Pengrian Anak Saleha Apandisit (RIPASA) Skoru 16
2.2.6.4. Lintula Skoru 17
2.2.6.5. Tzanakis Skoru 18
2.2.7. Görüntüleme Yöntemleri 19
2.2.7.1. ADBG 19
2.2.7.2. Ultrasonografi (USG) 19
2.2.7.3. Bilgisayarlı Tomografi (BT) 20
2.2.7.4. Manyetik Rezonans (MR) 20
2.2.8. Ayırıcı Tanı 21
2.2.9. Tedavi 22
2.2.10. Komplikasyonlar 26
2.3. AKUT APANDİSİT TANISINDA YAPAY ZEKÂ 26
3. GEREÇ VE YÖNTEM 30
3.1. ETİK KURUL İZNİ 30

3.2. ÇALIŞMANIN YÖNTEMİ 30
3.4. İSTATİSTİKSEL ANALİZ 34
4. BULGULAR 37
5. TARTIŞMA 46
6. SONUÇ 51
7. KAYNAKLAR 52

TABLOLAR

Tablo 1: Akut apandisit etkeni olabilecek mikroorganizmalar. 9
Tablo 2: Apandisit İnflamauart Yanıt Skoru 14
Tablo 3: Alvarado Skoru 15
Tablo 4: RIPASA Skoru 16
Tablo 5: Lintula skoru 17
Tablo 6: Tzanakis skoru 18
Tablo 7: Skorlama sistemlerinin tanısal performans değerleri 18
Tablo 8: Hastaların grup dağılımı 31
Tablo 9: BT görüntü kesitlerinin yapay zekâ modellerinde dağılımı 33
Tablo 10: Model Parametre Düzenlemeleri 41
Tablo 11: Model çıktıları hakkında karşılaştırma 41
Tablo 12: MobileNet v2 hata matrisi sonuçları 43
Tablo 13: ResNet v2 hata matrisi sonuçları 43
Tablo 14: EfficientNet b2 hata matrisi sonuçları 44
Tablo 15: Inception v3 hata matrisi sonuçları 44
Tablo 16: Tüm modellerin performans değerleri 45

ŞEKİLLER

Şekil 1: Apendiks Embriyoloji Gelişimi 4
Şekil 2: Apendiks Anatomik Görüntüsü 5
Şekil 3: Apendiks Yerleşim Yerleri 6
Şekil 4: Apendiksin arteriyel beslenmesi 7
Şekil 5: Apendiks Histolojisi 8
Şekil 6: Apandisit patolojisinin evreleri 10
Şekil 7: Psoas Testi 12
Şekil 8: Obturatuar testi 13
Şekil 9: Akut apandisit USG görüntüsü 20
Şekil 10: Apendektomi insizyon çeşitleri 23
Şekil 11: Laparoskopik apendektomi ameliyathane yerleşimi 24
Şekil 12: Laparoskopik apendektomi trokar yerleşimi 25
Şekil 13: Makine öğrenimi ve derin öğrenme şemaları 27
Şekil 14: Nesne tanımlama şeması 28
Şekil 15: Evrişimli sinir ağları mimarisi 29
Şekil 16: Akut apandisit BT kesiti örneği 32
Şekil 17: Sağlıklı hasta BT kesiti örneği 32
Şekil 18: İkili sınıflandırma şematik gösterim 35
Şekil 19: Yaş dağılımı grafiği 37
Şekil 20: Akut apandisit grubu yaş Q-Q grafiği 38
Şekil 21: Sağlıklı grup yaş Q-Q grafiği 38
Şekil 22: Çalışma grubunun cinsiyet dağılımı 39
Şekil 23: Akut apandisit ve sağlıklı grup cinsiyet dağılımı 40
Şekil 24: Modellerin kayıp-doğruluk eğrileri 42

SİMGELER VE KISALTMALAR

AA : Akut Apandisit

AI : Artificial Intelligence - Yapay Zekâ

AIR : Apandisit Inflamatuar Yanıt

ALT : Alanin Transferaz

AST : Aspartat Transferaz

BT : Bilgisayarlı Tomografi

CNN : Convolutional Neural Network – Evrişimli Sinir Ağı

CRP : C-Reaktif Protein

FN : False Negative – Yanlış Negatif

FP : False Positive – Yanlış Pozitif

FPR : False Positive Rate – Yanlış Pozitif Oranı

GALT : Gut-associated Lymphoid Tissue

USG : Ultrasonografi

MR : Manyetik Rezonans

NOTES : Doğal Açıklıktan Transluminal Endoskopik Cerrahi

RIPASA : Raja Isteri Pengrian Anak Saleha Apandisit

SIAS : Spina İliaca Anterior Superior

TN : True Negative – Doğru Negatif

TP : True Positive – Doğru Pozitif

TPR : True Positive Rate – Doğru Pozitif Oranı

WBC : White blood cells – Beyaz kan hücreleri

β-HCG : Human Koryonik Gonadotropini

ÖZET

AMAÇ

Akut apandisit (AA), en sık karşılaşılan cerrahi acillerden biri olup, nüfusun %7-8'inde görülmektedir. Zamanında tanı ve tedavisi yapılmaması halinde ciddi morbidite ve mortalite sonuçları olabilmektedir. Tanı genellikle fizik muayene, laboratuvar, ultrasonografi, bilgisayarlı tomografi (BT) yöntemleri ile konulur. Bu çalışmada AA tanısının erken konulması ve perforasyon, apse gibi komplikasyonların önüne geçilmesi için BT görüntülerinde yapay zekâ kullanımının etkinliğini değerlendirmek amaçlanmıştır.

GEREÇ VE YÖNTEM

Kanuni Sultan Süleyman Sağlık Uygulama ve Araştırma Merkezi Genel Cerrahi kliniğinde 01 Ocak 2019 ile 31 Haziran 2023 tarihleri arasında akut apandisit tanısıyla opere edilen hastaların BT görüntüleri incelendi. 400 hastanın kaydedilen 1200 BT kesit görüntüsü MobileNet, Resnet, EfficientNet ve Inception yapay zekâ modellerinde değerlendirildi. Model sonuçları hata matrisi kullanılarak ve kategorik değişkenler IBM SPSS istatistik paket programı kullanılarak değerlendirildi.

BULGULAR

Çalışma grubunun yaş ortancası 28 (17–88) (IQR: 13) yıl idi ve gruplar arasında yaş parametresi açısından anlamlı fark izlenmedi. Akut apandisit grubunda 266 erkek, 134 kadın hasta ve sağlıklı grupta 269 erkek, 131 kadın hasta mevcuttu. Gruplar arasında cinsiyet parametrei açısından anlamlı fark saptanmadı (p=0,881). Tüm CNN modelleri kıyaslandığında modeller arasında en yüksek doğruluk oranı (0,8) Inception v3, en yüksek kesinlik oranı (0,819515) MobileNet v2 modelinde saptandı. Kesinlik ve duyarlılık arasındaki dengeyi gösteren F-skor değeri en yüksek (0,795745) Inception v3 modelinde saptandı. Sensivite değeri en yüksek (0,7791667) Inception v3 ve spesifite değeri en yüksek (0,8625) EfficientNet b2 modelinde saptandı

SONUÇ

Yapay zekâ ve yapay zekâ ilişkili teknolojiler, bilgisayar bilimleri alanında yaşanan yeni gelişmeler ile günlük hayatta sıklıkla yer almaya devam etmektedir. Çalışmamızda kullanılan modellerde en yüksek sensivite %77 ve en yüksek spesifite %86 olarak saptanmıştır. BT görüntülemesinin yapay zekâ sistemleri ile desteklenmesi halinde AA teşhisi için sensivite, spesifite ve doğruluk değerlerinin artacağını düşünmekteyiz.

ANAHTAR KELİMELER: akut apandisit, yapay zekâ, tanısal görüntüleme, bilgisayarlı tomografi,

ABSTRACT

AIM

Acute appendicitis (AA) is one of the most common surgical emergencies and is seen in 7-8% of the population. If timely diagnosis and treatment are not made, serious morbidity and mortality may occur. Diagnosis is usually made by physical examination, laboratory, ultrasonography and computerized tomography (CT) methods. This study aimed to evaluate the effectiveness of using artificial intelligence in CT images to diagnose AA early and prevent complications such as perforation and abscess.

MATERIALS AND METHODS

CT images of patients who were operated on with the diagnosis of acute appendicitis at the General Surgery Clinic of Kanuni Sultan Süleyman Health Application and Research Center between January 1, 2019 and June 31, 2023 were examined. 1200 CT cross-sectional images recorded from 400 patients were evaluated in MobileNet, Resnet, EfficientNet and Inception artificial intelligence models. Model results were evaluated using confusion matrix and categorical variables were evaluated with IBM SPSS statistical package program.

RESULTS

The median age of the study group was 28 (17–88) (IQR: 13) years and no significant difference was observed between the groups in terms of age parameters. There were 266 male and 134 female patients in the acute appendicitis group and 269 male and 131 female patients in the healthy group. No significant difference was found between the groups in terms of gender parameters (p=0.881). When all CNN models were compared, the highest accuracy rate (0.8) was found in Inception v3, and the highest accuracy rate (0.819515) was found in MobileNet v2 model. The highest F-score value (0.795745), indicating the balance between precision and sensitivity, was detected in the Inception v3 model. The highest sensitivity value (0.7791667) was detected in the Inception v3 model and the highest specificity value (0.8625) was detected in the EfficientNet b2 model.

CONCLUSION

Artificial intelligence and artificial intelligence-related technologies continue to take part frequently in daily life with new developments in the field of computer science. In the models used in our study, the highest sensitivity was found to be 77% and the highest specificity was 86%. We think that if CT imaging is supported by artificial intelligence systems, the sensitivity, specificity and accuracy values for AA diagnosis will increase.

KEY WORDS: acute appendicitis, artificial intelligence, diagnostic imaging, computed tomography

1. GİRİŞ VE AMAÇ

Akut apandisit (AA) akut karın ile başvuran hastalarda sıklıkla karşılaşılan klinik bir tablodur. Bu sıklık çeşitli yaş gruplarında farklılık göstermektedir. Sağlıklı insan popülasyonunda yaşam boyunca akut apandisit gelişme oranının %7-8 arasında olduğu tahmin edilmektedir (1).

Akut apandisit tanısında anamnez, fizik muayene ve laboratuvar bulgularından yararlanılmaktadır. Klinik göstergeler hastalar arasında farklılık gösterebilir. AA'nın klasik bulgularında sağ alt kadran ağrısı, ağrı göçü olarak tanımlanan ağrının göbekten sağ alt kadrana doğru konum değiştirmesi görülmesine rağmen bu bulgular hastaların yalnızca yaklaşık %50'sinde görülmektedir (2).

AA hastalığında oluşabilecek komplikasyonlar hastalarda istenmeyen morbidite ve mortalite sonuçlarına yol açabilmektedir. Akut apandisit olan hastaların teşhisinin zamanında yapılamaması ya da sağlıklı hastalarda akut apandisit tanısı konulması tanısal sürecin gecikmesine yol açmaktadır. Hastalığın erken tanınması ve tedavinin hızlı bir şekilde başlanması için ultrasonografi (USG), bilgisayarlı tomografı (BT) gibi görüntüleme tetkiklerinden yararlanılmaktadır (3). Yine bu amaçla klinik kullanım için Alvarado, Lintula, RIPASA, Tzanakis gibi birçok skorlama sistemi geliştirilmiştir (4–8).

Akut apandisit tanısı konulan hastaların yaklaşık %13-20'sinde perforasyon görülmektedir (9). Perforasyon izlenen hastaların hastaneye geliş süreleri incelendiğinde sıklıkla 24 saat üzerinde olduğu görülse de hastaların %20'sinin ilk 24 saat içerisinde hastane başvurusunun olduğu bilinmektedir (10). AA hastalarının yaklaşık %4'ünde ameliyat öncesi karın içi apse ya da pelvik bölgede apse izlenmektedir (11). Tanı ve tedavi sürecinde oluşabilecek tüm yetersizlikler perforasyon ve apse gibi çeşitli komplikasyonların gelişmesine neden olmaktadır.

Yapay Zekâ (AI), makinelerin, özellikle bilgisayar sistemlerinin, insan zekasını simüle etme ve görevleri insan müdahalesi olmadan tamamlama yeteneği olarak tanımlanır (12). Tahmin modellerinin oluşturulması için makine öğreniminin

kullanılması ile yapay zekanın sağlık hizmetlerinde etkin olarak kullanımı giderek daha fazla kabul görmektedir (13).

Çalışmamızda AA tanısında kullanılan BT görüntülerinde, makine öğrenmesi ile desteklenmiş yapay zekâ sisteminin tanı konulması üzerinde etkinliğini değerlendirme amaçlanmıştır.

2. GENEL BİLGİLER

2.1. APENDİKS VERMİFORMİS

2.1.1 Tarihçe

AA hastalığının tarihsel süreci incelendiğinde ilk bulgular Antik Mısır mumyalarında izlenen adezyonlar ile ilişkili görülmüştür (14). Akut apandisit hastalığı 1544 yılında Jean Fernel tarafından yayınlanan makalede kabul edilmiştir. Mortalite ile sonuçlanan vakanın otopsisinde apendiks lümeninin tıkandığı, nekroz ve perforasyona yol açtığı görülmüştür (14).

Appendektomi cerrahisi tarihte ilk kez Cladius Amyand tarafından 1735 yılında gerçekleştirilmiştir. Cladius Amyand herni kesesi içerisinde çevresinde omentumun görüldüğü perfore apandisiti saptamış ve apendektomi ile omentektomi yaparak operasyonu tamamlamıştır (15).

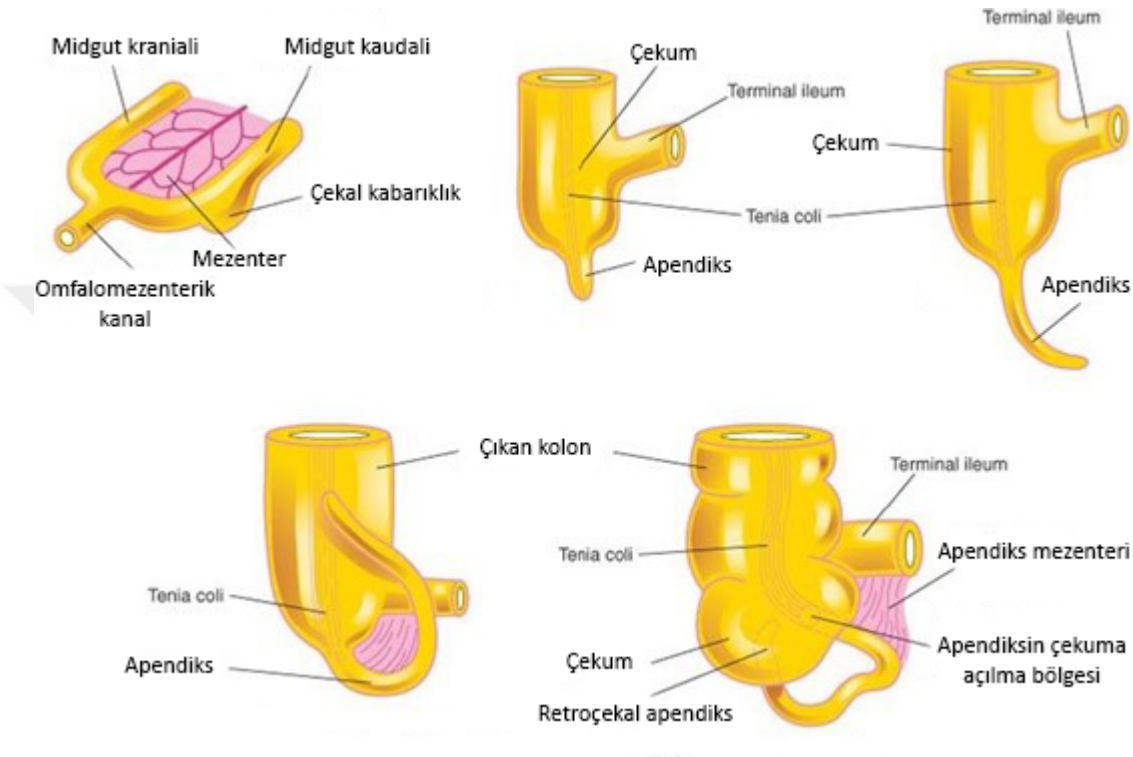
New York Cerrahi Topluluğu üyesi Charles Mcburney, 1889 yılında apendiksin konumunu tanımlamış ve apandisit tedavisi için önemli bir çalışma olarak kabul edilen yazı New York State Medical Journal'da yayınlanmıştır (16).

Bu gelişmeler ile apendektomi sayılarında önemli miktarda artış gerçekleşmiştir. AA ilk zamanlarda medikal yöntemlerle tedavi edilmeye çalışılsa da, klinik tablonun ilerlemesini ve perforasyonu önlemek için erken dönemde apendektomi yapılması kabul görmüştür.

İlk laparoskopik apendektomi 1983 yılında Kurt Semm tarafından gerçekleştirilmiştir (17). Günümüzde kolonoskopik yöntemler ile apendektomiler ve NOTES (Doğal Açıklıktan Transluminal Endoskopik Cerrahi) yöntemi ile apendektomi çalışmalarıda yapılmaktadır (18,19).

2.1.2 Embriyoloji

Embriyolojik gelişimin 6. haftasında midgut kaudal ucunun antimezenterik alanınında çekal divertikülit oluşur. Apendiks 8. haftadan başlayarak dışa doğru cepleşmeye başlar ve yaklaşık 5. ayın sonlarına doğru solucanımsı görüntüsünü alır (Şekil 1)(20).

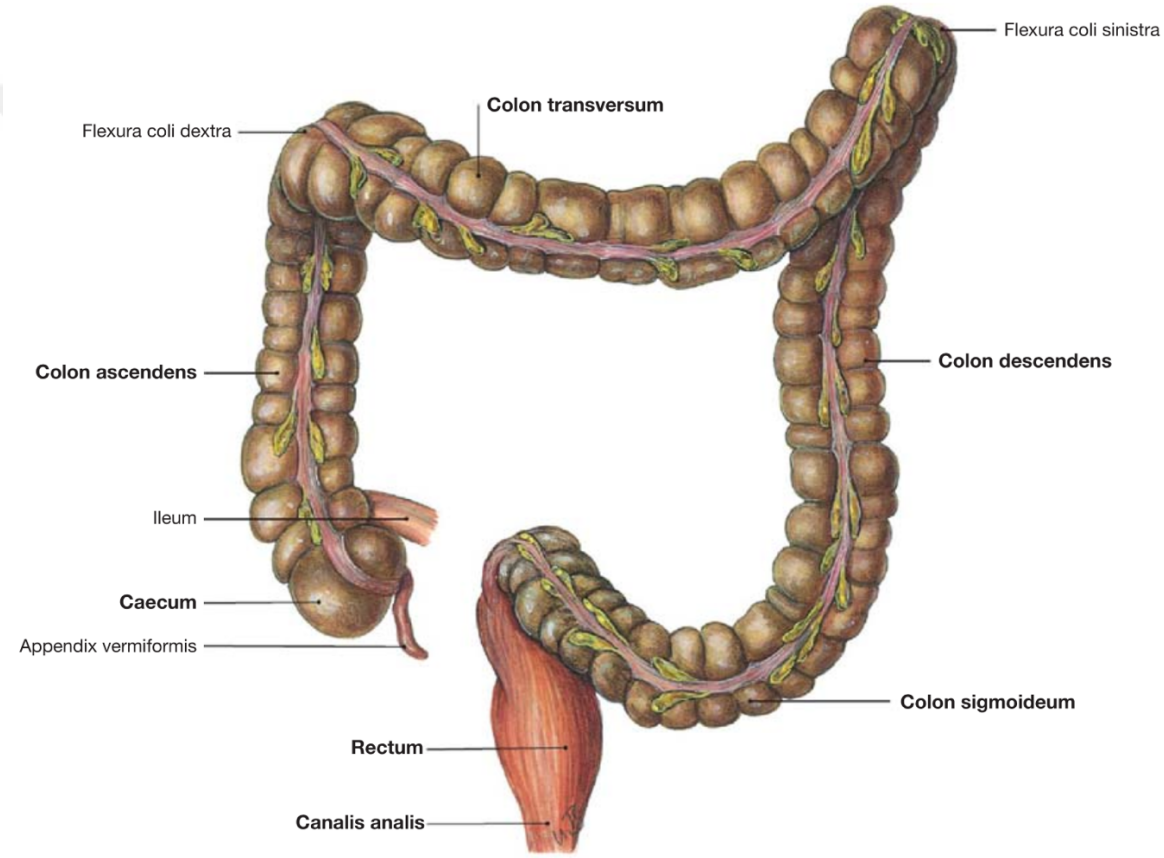


Şekil 1: Apendiks Embriyoloji Gelişimi (21)

2.1.3 Anatomi

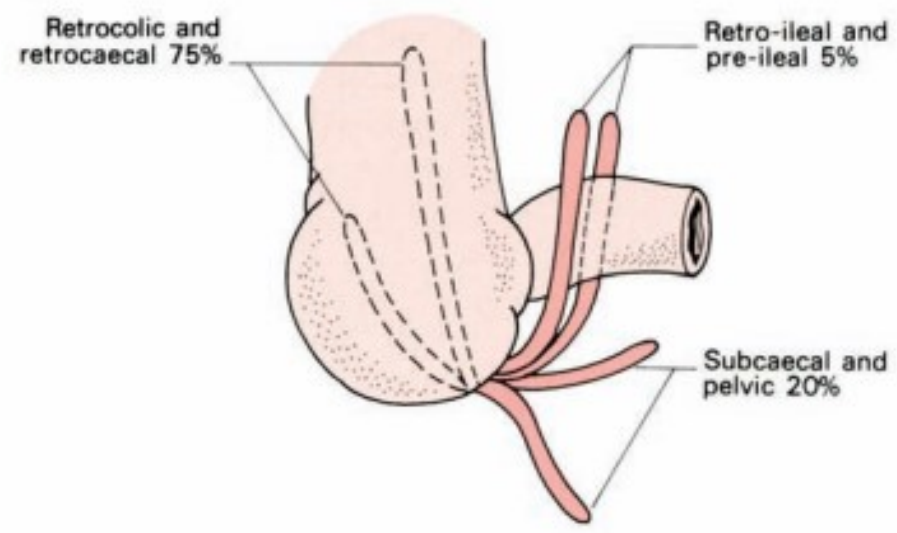
Latince de *apendiks* ¨ek¨, *vermiformis* ¨solucan şeklinde¨ kelimelerinden türeyen apendiks vermiformis çekumun kör sonlanan solucan şeklinde uzantısdır (Şekil 2)(22).

Apendiksin boyutu çeşitlilik göstermekle beraber ortalama uzunluğu yaklaşık 6-9 cm arasındadır. Lümen iç çapı 1-3 mm iken dış çapı 3-8 mm arasında olabilmektedir (23).



Şekil 2: Apendiks Anatomik Görüntüsü (24)

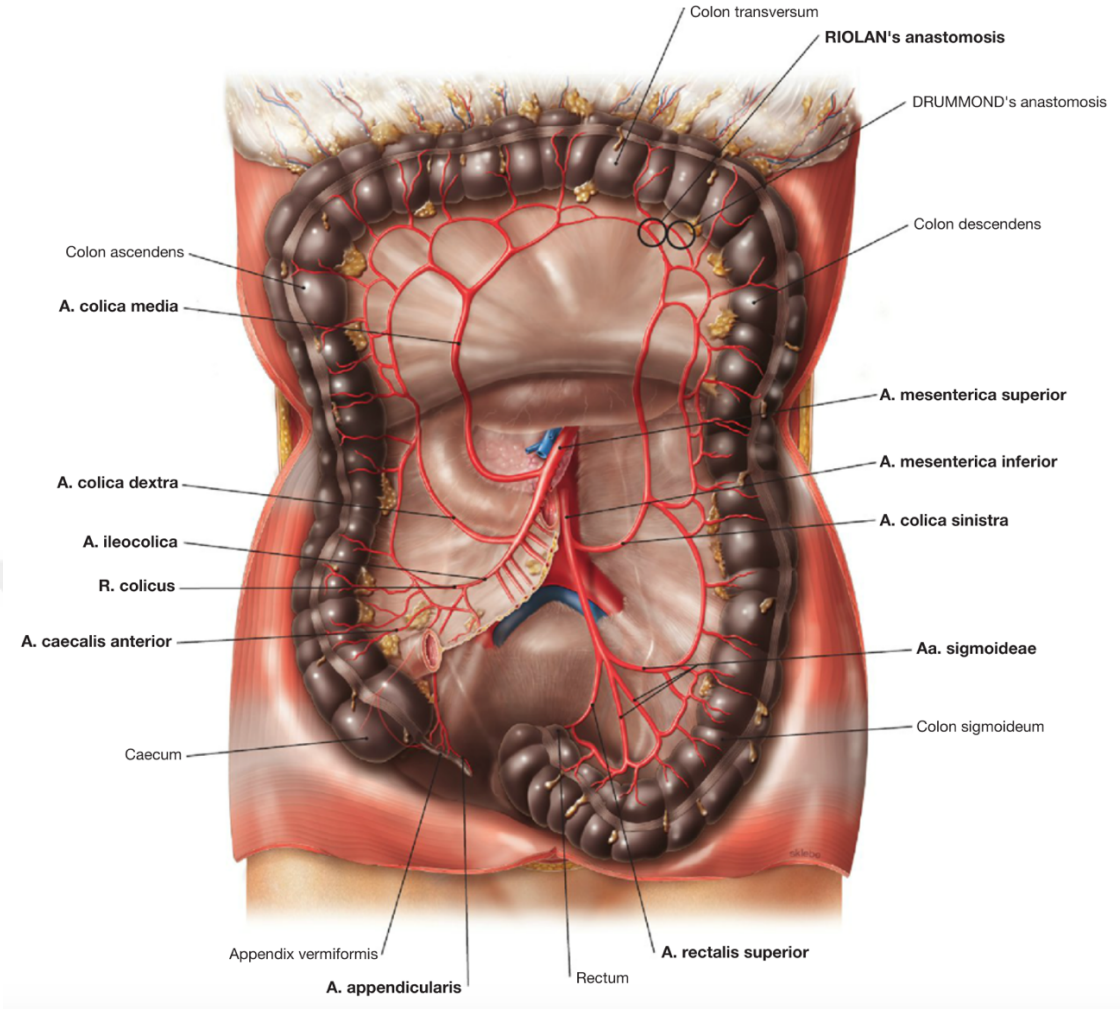
Apendiksin çekuma giriş noktası değişiklik göstermemesine rağmen, serbest olarak izlenen kısmın anatomik yerleşiminde değişiklikler izlenebilir. Paraileal, postileal, promontorik, pelvik, subçekal, parakolik ve en sık oranda retroçekal (%65-75) olarak izlenmektedir (Şekil 3)(25).



Şekil 3: Apendiks Yerleşim Yerleri (26)

Apendiksin beslenmesi ileokolik arterin dalı olan apendiküler arter tarafından sağlanmaktadır (Şekil 4). Apendiküler arterin uç arter olması sebebiyle tromboza bağlı tıkanma ve buna bağlı nekroz sık görülmektedir. Beslenmenin en az olduğu alan antimezenterik yüzün orta kısmıdır ve nekroz en sık bu bölgede izlenmektedir (27).

Apendiksin venöz drenajı, arterleri ile aynı isimde olup v. ileocolica, v. mezenterica superior ile portal vene dökülür (28). Visseral inervasyonu incelendiğinde sempatik aktivite superior mezenterik pleksustan (T10-L1), parasempatik aktivite ise vagal sinirden sağlanmaktadır (24).



Şekil 4: Apendiksin arteriyel beslenmesi (24)

2.1.4 Histoloji

Apendiks histolojik olarak incelendiğinde dıştan içe doğru 4 katmadan oluşur; seroza, muskularis propria, submukoza ve mukoza (Şekil 5). Kolondan en önemli farkı serozası üzerinde tenia coli yapısı ve villusların bulunmamasıdır (25).



Şekil 5: Apendiks Histolojisi (29)

2.1.5 Fizyoloji

Apendiks uzun süre boyunca fonksiyona sahip olmayan bir organ olarak düşünülmüştür. Yapılan çalışmalar sonrasında gut-ilişkili lenfoid doku (GALT) dokusunun gelişmesi ve Immunglobulin-A ile immun sistemin bir parçası haline geldiği düşünülmektedir. Aynı zamanda barsak içeriğinde izlenen yararlı mikrobiyom ortamının korunmasında görevli olduğu düşünülmektedir (23).

2.2. AKUT APANDİSİT

2.2.1. Akut Apandisit Epidemiyolojisi

AA dünya çapında akut batının en sık nedenlerinden biridir. Dünya toplumunda yılda her 1000 kişiden birinde görülmektedir (30). Yaşam boyu AA görülme insidansı kadınlarda %6,7 iken erkeklerde %8,6 oranında görülmektedir. Hastalığın morbidite ve mortalite oranları değişkenlik göstermekte ve özellikle 50 yaş üzerinde bu oranlarda artış görülmektedir (23).

2.2.2. Akut Apandisit Etiyoloji

AA etiyolojisinde çok sayıda faktör bulunmaktadır. Bunlardan önemli olan esas etiyolojik faktör lümen tıkanıklığı yani obstrüksiyondur. Yetişkin popülasyonda bu obstrüksiyon nedeni fekalit, fibrozis, yabancı cisim, çekirdekli bitkisel gıda alımı, malign lezyonlar (Adenokarsinom, karsinoid tümörler, lenfoma, kaposi sarkomu) olabilmektedir. Hatta bazı bakteriler (Salmonella, Shigella), parazitler (Taenie Saginata, Ascaris Lumbricoides vb.) gibi mikroorganizmalar patolojiye neden olabilmektedir (Tablo 1). Pediyatrik grupta ise neden sıklıkla foliküler hiperplazi olarak karşımıza çıkmaktadır (23,31).

Tablo 1: Akut apandisit etkeni olabilecek mikroorganizmalar (32) .

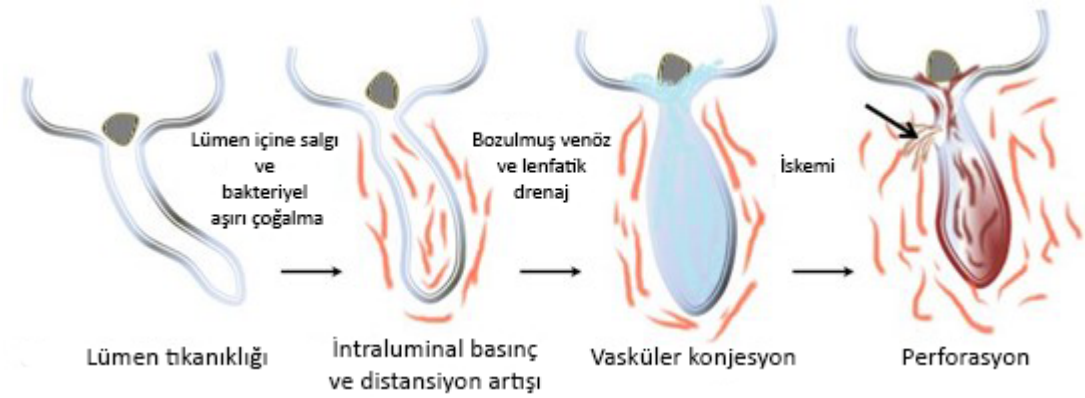
Viral	Bakteriyel	Fungal	Paraziter
Kızamık Adenovirus Sitomegalovirus Epstein-Barr Virus	Salmonella Shigella Y. enterocolica Campylobacter Clostridium Mycobacteria Ricketsia ricettsi Actinomyces	Mucormycosis Histoplasmosis	Enterobius vermicularis Schistosomes Entamoeba histolytica Balantidium coli Strongyloides stercolaris Toxoplasma Cryptosporidium Echinococcus Trichuris Ascaris

2.2.3. Akut Apandisit Patogenezi

Akut apandisit tablosu, apendiks lümeninin obstrüksiyonu ile başlamaktadır. Tıkanma sonucu normalde kolonun çekum kısmına drene olması gereken sekresyonlar lümende birikmesi ve tıkanmaya bağlı oluşan bakteriyel aşırı çoğalma,

intralüminal basınç artışına sebep olmaktadır. Oluşan basınç artışı serozal gerginlik, lenfatik akımda bozulma ve sonrasında ise venöz akımda tıkanma yaratmaktadır.

Ödematöz ve iskemik süreçte gerçekleşen bakteriyel translokasyon antimezenterik apendiks bölgesinde arteriyel iskemiye ve bunun sonucunda gangren ve perforasyona sebep olmaktadır (Şekil 6) (23).



Şekil 6: Apandisit patolojisinin evreleri (33)

2.2.4. Klinik Tablo

2.2.4.1. Semptomlar (Anamnez)

Akut apandisit tanısında iki önemli faktör bulunmaktadır. Bunlar anamnez ve fizik muayene olarak tanımlanabilir.

AA anamnezinde esas olarak görülen semptom karın ağrısıdır. Ağrı hastalığın ilk safhasında sıklıkla göbek çevresinde, visseral periton uyarılmasına bağlı olarak görülmektedir. Sonrasında gerçekleşen parietal periton irritasyonu ile sıklıkla sağ alt kadranda lokalize olmaktadır. Sağ alt kadran ağrısı akut apandisit en spesifik bulgusu olarak kabul edilmektedir (23).

Her ne kadar AA kliniğinde sağ alt kadran spesifik bulgu olsa da apendiksin yerleşiminin varyasyonları nedeniyle ağrı lokalizasyonu değişiklik gösterebilir. Sağ lomber bölgede, pelvik bölgede, suprapubik bölgede ve sol alt kadranda da ağrı izlenebilmektedir (23).

AA hastalarında iştahsızlık, bulantı, kusma gibi atipik semptomlarda izlenmektedir. Semptomlar sıklıkla ağrıdan hemen sonra görülmektedir. Ağrı oluşmadan benzer semptomların görülmesi ayırıcı tanıda özellikle gastroenterit açısından şüphe uyandırmalıdır (23).

2.2.4.2. Fizik Muayene

AA'da fizik muayene bulguları apendiksin anatomik yerleşimi, perforasyon varlığı, başvuru zamanı ve ek hastalıklar gibi nedenlere bağlı olarak değişiklik göstermektedir (23).

Hastalığın erken döneminde klinik bulgular tam olarak ortaya çıkmamakta ve nadir görülmektedir. Bazı vakalarda ateş yüksekliği ve taşikardi görülebilmektedir. Vital bulgularda ki ciddi değişimler komplike vakaları veya diğer akut karın tablolarını akla getirmelidir (23).

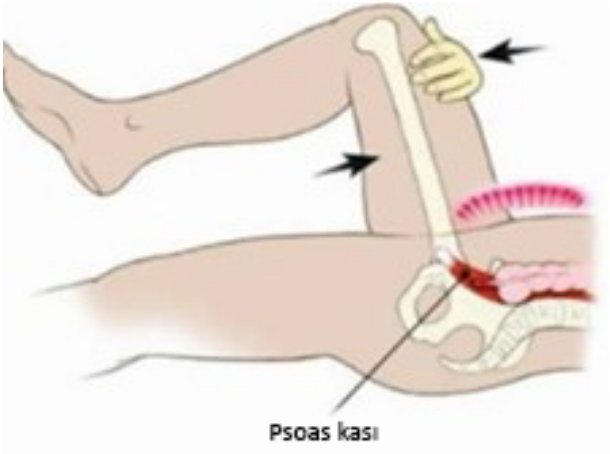
Batın muayenesinde temel muayene uygulamalarından inspeksiyon, oskültasyon ve perküsyon tanı koymada avantaj sağlamamaktadır. AA tanısında en önemli muayene bulgusu palpasyonda ağrı olmasıdır (23).

Akut apandisit tanısında kullanılan fizik muayene yöntemleri aşağıda sıralanmıştır:

a. **Sağ alt kadranda hassasiyet (Mc Burney noktası**): Spina iliaca anterior superior (SİAS) ile umblikus arasında çizilen hayali çizginin lateral 1/3'ü olarak Mc Burney noktası tanımlanmıştır (16). Muayenede bu bölgede gerçekleştirilen palpasyonda ağrı olması olarak tanımlanmaktadır.
b. **Muskuler defans:** Gerçekleştirilen palpasyonda hastanın ağrıdan kaçınmak amacıyla karın kaslarının kasılarak gerilmesi durumudur. İstemli veya istemsiz olarak görülmektedir. İstemsiz defans yaygın peritonitte önemli bulgu olarak görülmektedir (34).
c. **Rebound bulgusu:** Hassasiyetin çok görüldüğü alanda yapılan palpasyonu, elin hızlıca geri çekilmesi ile sonlandırmak ve sonrasıda aynı

kadranda ya da karnın herhangi bir bölgesinde ağrının şiddetlenmesidir (35).

d. **Rovsing bulgusu:** Hastanın sol alt kadrandan gerçekleştirilen palpasyonda kolon gazları sol kolondan çekuma doğru itilir ve artan gaz hacmi ile birlikte sağ alt kadranda oluşmaktadır (36).
e. **Psoas bulgusu:** Sağ uylukta yapılan hiperekstansiyon ileopsoas kasının gerilmesine sebep olmaktadır. Sıklıkla retroçekal vakalarda ileopsoas kasına komşu AA vakalarında sağ alt kadranda ağrı oluşmaktadır (Şekil 7)(34).



Şekil 7: Psoas Testi (37)

f. **Obturatuar bulgusu:** Kalça eklemine (sağ taraf) ilk olarak fleksiyon ve sonrasında iç rotasyon yapılmasıyla sağ alt kadranda ağrı oluşmasıdır. Pelvik yerleşimli AA veya apse varlığında izlenmesi mümkündür (Şekil 8)(34).



Şekil 8: Obturatuar testi (37)

g. **Dunphy bulgusu:** Karın içi basıncı arttırmak için ıkınma, öksürme hareketleri yaptırılır. Basın içi artış nedeniyle karın ağrısı oluşur ve hastalar bu durumda cenin pozisyonu alarak yavaş ve dikkatli nefes alışverişi yapar (34).
h. **Aaron bulgusu:** McBurney noktasına yapılan palpasyonda epigastrik bölgede ağrı oluşmasıdır (38).
i. **Ten-Horn bulgusu:** Sağ testisin çekilmesi ile sağ alt kadranda ağrı hissedilmesidir (38).
j. **Topuk testi:** Hasta ayak parmak uçlarında yükselmesi ve sonrasında kendini hızlı bir şekilde serbest bırakmasıyla oluşan karın ağrısı bulgusudur (39).

2.2.5. Laboratuvar Bulguları

AA tanısı çoğunlukla klinik anamnez ve fizik muayene bulgularına dayanmaktadır. Laboratuvar bulguları tanıyı desteklemektedir fakat tanıyı koydurabilecek nitelikte spesifik bir parametre bulunmamaktadır (23,34).

AA tanısından şüphelenilen hastalarda ilk başvuruda beyaz küre sayısı (WBC), C-reaktif Protein (CRP) düzeyi, Aspartat transaminaz (AST) ve Alanin transaminaz (ALT) değerleri çalışılabilir (23,40).

Kadın hastalarda gebelik dışlanması için Human Koryonik Gonadotropini (β HCG) ve üriner sistem yolu enfeksiyonunu dışlamak amacıyla tam idrar tetkiki yapılabilir (23).

CRP, WBC yükseklikleri tek başına akut apandisit tanısı için yeterli sensivite ve spesifitiye sahip olmasa da klinik ile testlerin kombine bir şekilde değerlendirilmesinin tanıda başarı oranını arttırdığına dair çalışmalar bulunmaktadır (41).

2.2.6. Klinik Skorlama Sistemleri

2.2.6.1. Apandisit İnflamatuar Yanıt (AIR) Skoru

Akut apandisit tanısının konulması ve somut bir tanı sistemi oluşturmak amacıyla bazı skorlama sistemleri geliştirilmiştir. 2008 yılında oluşturulan AIR Skorlama sisteminin parameterleri Tablo 2'de gösterilmektedir (42).

Tablo 2: Apandisit İnflamauart Yanıt Skoru (42)

Kriter	**Puan**
Kusma	1
Sağ alt kadran ağrısı	1
Rebound ve muskuler defans	1 (Hafif), 2 (Orta), 3 (Şiddetli)
Ateş (>38,5 °C)	1
Nötrofilik sol kayma	1 (%70-84), 2 (≥%85)
Lökositoz (10^3/μL)	1 (10-14,999), 2 (≥15)
CRP (mg/dL)	1 (10-49), 2 (≥50)
0-4: Düşük risk **5-8:** Orta risk **9-12:** Yüksek risk	

2.2.6.2. Alvarado Skoru

AA tanısında en çok kullanılan skorlama sistemi olarak bilinmektedir. İlk olarak 1984 yılında tanımlanmış, ilerleyen teknoloji ve tetkikler ile zamanla revizyona gidilmiştir (43). Güncel olarak kullanılan Alvarado skorlama sistemi Tablo 3'te gösterilmektedir.

Tablo 3: Alvarado Skoru (43)

Kriter	**Puan**
Ağrının sağ alt kadrana göçü	1
İştahsızlık	1
Bulantı-Kusma	1
Sağ alt kadranda hassasiyet	2
Rebound varlığı	1
Ateş	1
Lökositoz	2
Nötrofilik sola kayma	1
1-4: Olası değil **5-6:** Düşük risk **7-8:** Orta risk **9-10:** Yüksek Risk	

2.2.6.3. RIPASA (Raja Isteri Pengrian Anak Saleha Apandisit) Skoru

Parametre sayısı diğer iki skorlama sisteminden fazla olan yakın zamanda geliştirimiş bir skorlama sistemidir. Asya kökenli hasta popülasyonunda duyarlılığının daha fazla olduğuna dair çalışmalar mevcuttur (7). Parametreler Tablo 4'te gösterilmiştir.

Tablo 4: RIPASA Skoru (7)

Kriter	**Puan**
Cinsiyet	1 (Erkek), 0,5 (Kadın)
Yaş	1 (<40), 0,5 (≥40)
Sağ alt kadran ağrısı	0,5
Sağ alt kadrana ağrı göçü	0,5
İştahsızlık	1
Bulantı-Kusma	1
Semptom süresi	1 (<48 saat), 2 (≥48 saat)
Sağ alt kadranda hassasiyet	1
Defans	2
Rebound	1
Rovsing bulgusu	2
Ateş (37-39 °C)	1
Lökositoz	1
Negatif idrar tahlili	1
Asya uyruklu hasta	1
0-4: Olası değil **5-7:** Düşük risk **7,5-11,5:** Yüksek risk **>12:** Kesin akut apandisit	

2.2.6.4. Lintula Skoru

Lintula skoru, özellikle pediyatrik yaş grubunda kullanılan bir skorlama sistemidir. 2005 yılında çocuk ve erişkin arasında yapılan karşılaştırma sonucunda çocuk yaş grubunda yararlı olduğu düşünülen bu skorlama sistemi oluşturulmuştur (6). Parametreler Tablo 5'teki gibidir.

Tablo 5: Lintula skoru (6)

Kriter	**Puan**
Cinsiyet	0 (Kadın), 2 (Erkek)
Karın ağrısı şiddeti	0 (Hafif-Orta), 2 (Şiddetli)
Ağrının yeniden konumlandırılması	0 (Hayır), 4 (Evet)
Kusma	0 (Hayır), 2 (Evet)
Sağ alt kadranda ağrı	0 (Hayır), 4 (Evet)
Ateş	0 (Hayır), 3 (Evet)
Defans	0 (Hayır), 4 (Evet)
Barsak peristaltizm sesleri	0 (Normal), 4 (Anormal ya da yok)
Rebound	0 (Hayır), 7 (Evet)
<15: Yüksek ihtimal akut apandisit değil **15-21:** Hasta takip edilmeli **>21:** Yüksek ihtimal akut apandisit	

2.2.6.5. Tzanakis Skoru

Bu skorlama sistemi Nicolaos E. Tzanakis tarafından 2005 yılında tanımlanmıştır. Toplam 15 puan alınabilen bu skorlama sistemindeki parametreler Tablo 6'da gösterilmiştir (44).

Tablo 6: Tzanakis skoru (44)

Kriter	**Puan**
Sağ alt kadranda hassasiyet	4
Rebound	3
Lökositoz (>12 x 10^3/µL)	2
Pozitif USG bulguları	6
<8: Düşük ihtimal (Akut apandisit değil) **≥8:** Yüksek ihtimal (Akut apandisit)	

Her bir skorlama sisteminin birbirine karşı avantajları ve dezavantajları olmasına rağmen temel amaç akut apandisit tanısı için en yüksek hassasiyeti sağlamak ve negatif apendektomi oranlarını azaltmak olarak belirlenmiştir. Tablo 7'de skorlama sistemlerinin tanısal değerleri gösterilmiştir.

Tablo 7: Skorlama sistemlerinin tanısal performans değerleri (7,8,42,45)

	Sensivite	**Spesifite**	**PPD**	**NPD**	**NAR**
AIR	96	73	64	97	*
Alvarado	81,91	66,66	74	29	12
RIPASA	88	67	93	53	9,4
Lintula	60,8	60	79,5	37,5	9,8
Tzanakis	91,48	66,66	81	40	20-45
PPD: Pozitif prediktif değer, NPD: Negatif prediktif değer, NAR: Negatif apendektomi oranı **Sayısal değerler yüzde (%) olarak verilmiştir.					

2.2.7. Görüntüleme Yöntemleri

2.2.7.1. Ayakta Direkt Batın Grafisi

Akut karın tanısı ile klinik başvurusu olan hastalarda değerlendirme aşamasında ilk istenilen tetkiktir. Akut apandisit tanısında nadiren faydalı olmaktadır (23). AA dışı patolojilerin dışlanmasında rol oynamaktadır.

Direkt karın grafisinde apendiks lokalizasyonu üzerinde apendikolitler görülebilir. Yine barsak perforasyonlarında görülen lümen dışında serbest hava görüntüsü perfore akut apandisiti akla getirmelidir (46). Sağ alt kadranda serbest sıvı varlığı akut apandisite bağlı gelişebilecek apseyi akla getirmelidir (23).

2.2.7.2. Ultrasonografi

Ultrasonografi, çocuk yaş grubunda, genç ve beden kitle endeksi düşük hastalarda ve gebe hastalarda kullanılan temel görüntüleme yöntemlerinden biridir. Radyoaktif ajan maruziyetinin olmaması ve maliyet açısından uygunluğunun yüksek olması tanı yönteminin kullanılmasının avantajları arasındadır.

USG ile yapılan incelemede prob basısı ile kompresyon olmaması, apendiks çapının >6 mm olması, çevre yağlı mezenter dokularda inflamasyona bağlı ekojenitede artış izlenmesi, apendikolit varlığı gibi bulgular tanı konulmasında yardımcı olmaktadır (Şekil 9) (46).

USG'nin akut apandisitte duyarlılığı %85 iken, özgüllğü %90 oranına olduğu bilinmektedir (23). Bu tanı yönteminin işlemi yapan radyoloji hekiminin subjektif değerlendirmesine bağlı olması dezavantajları arasındadır.



Şekil 9: Akut apandisit USG görüntüsü (47)

2.2.7.3. Bilgisayarlı Tomografi

Bilgisayarlı tomografi, USG kullanımının tanı koymada yeterli olmadığı, beden kitle endeksi yüksek ve perforasyondan şüphelenilen hastalarda tanıyı desteklemek amacıyla ile kullanılabilecek bir tetkiktir. Maliyet yüksekliği, radyoaktif ışın maruziyeti ve çoğunlukla kontrast kullanılması gerekliliği dezavantajları arasındadır.

BT'de akut apandisit açısından anlamlı bulguar arasında, apendiks çapının >6 mm'den büyük olması, çift duvar görüntüsü, çevre yağlı dokularda hiperdens görüntü yani kirlilik izlenmesi ve apendikolit sayılabilir. BT incelemesinin sensivite ve spesifitesi %95 oranında seyretmektedir (23).

2.2.7.4. Manyetik Rezonans (MR)

Akut apandisit tanısında özel durumlarda gereklilik halinde kullanılan görüntüleme yöntemidir. Özellikle gebe hastalarda USG ile apendiksin

görüntülenemediği vakalarda tanıyı desteklemek amacıyla radyasyon maruziyeti bulunmayan görüntüleme tetkikidir.

Maliyetinin yüksek olması ve görüntülerin değerlendirilmesi için genellikle ikinci görüş ihtiyacı dezavantajlarındandır. Sensivitesi ve spesifitesi ortalama %95 civarındadır (23).

2.2.8. Ayırıcı Tanı

Akut karın patolojileri yaş grupları arasından tanısal olarak farklılık göstermektedir. AA ayırıcı tanısı yaş, cinsiyet, ağrı lokalizasyonu ve derecesi değerlendirilerek yapılmalıdır. Ayırıcı tanıda çeşitli hastalıklar bulunmaktadır. Bunlardan bazı hastalıklar aşağıda sıralanmıştır (48).

a. **Çekal Divertikülit:** Genç yetişkinlerde sık görülür. Akut apandisit benzeri tablo sergiler.
b. **Meckel divertiküliti:** Omfalomezenterik duktusun konjenital kalıntısının inflamasyonudur.
c. **Akut ileit:** Sıklıkla akut bakteriyel nedenlerden kaynaklanır. Diyare benzeri şikayetler ile seyredebilir.
d. **Crohn hastalığı:** Terminal ileum tutulumu ile seyreden hastalıkta akut apandisit benzeri tablo eşlik edebilir.
e. **Pelvik inflamatuvar hastalık:** Öksürme ile artan ağrı ve ateş ile seyreder. Yaygın alt kadran ağrısı izlenir.
f. **Tuba-ovaryen apse:** Genellikle üst genital yol enfeksiyonu olan kadın hasta grubunda izlenir. Pelvik inflamatuar hastalığın komplikasyonu olarak karşılaşılabilir.
g. **Ovaryen kist rüptürü:** Genellikle sağ taraflı patolojilerde, fiziksel aktivite ile tetiklenen ağrı ile izlenebilir. Vajinal kanama şikâyeti görülebilir.
h. **Ektopik gebelik:** Akut pelvik ağrının olduğu ve gebelik testinin pozitif olduğu hastalarda akla gelmelidir.

i. **Endometriyozis:** Endometriyum dokusunun pelvise implante şekilde lokalize olmasından kaynaklanır. Pelvik ağrı, dismenore, anormal vajinal kanamalar eşlik eder.
j. **Renal kolik:** Şiddetli ağrı ile başvuru izlenir. Ağrı şiddetinin seyrinde dalgalanmalar görülebilir.
k. **Testis torsiyonu:** Sıklıkla yenidoğanlarda ve pubertede olmak üzere erkek cinsiyette izlenen ürolojik acil tablodur.
l. **Epididimit:** İleri adölesan dönemde izlenir. Skrotal ağrının sık nedenidir. Fiziksel ya da seksüel aktivite ile sağ alt kadranda ağrı izlenebilir.

2.2.9. Tedavi

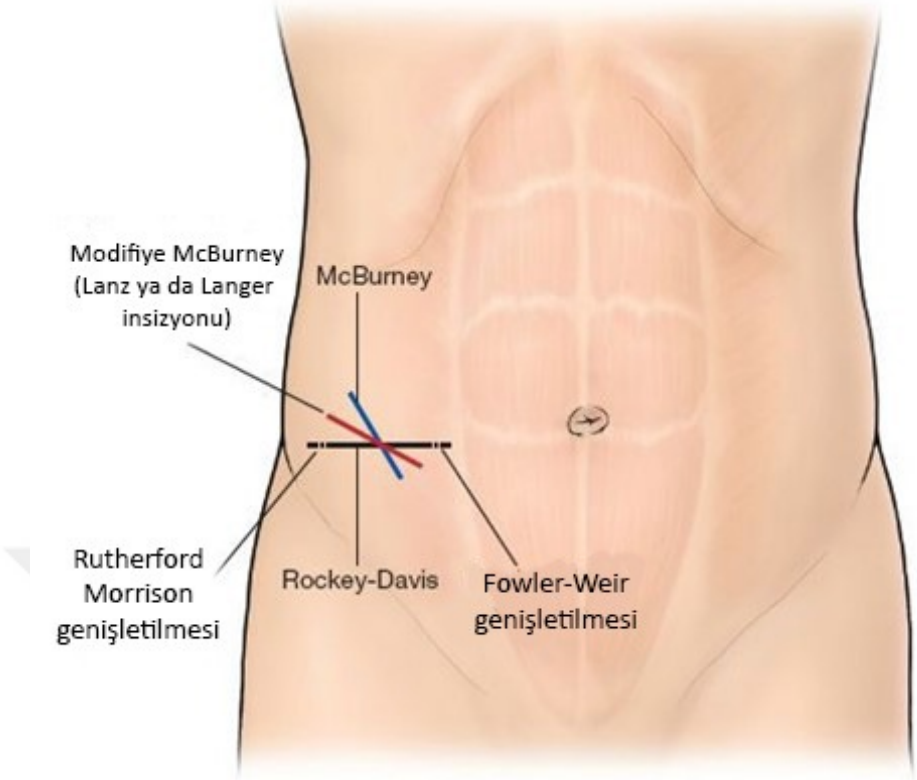
Akut apandisit hastalığının tedavisinde en iyi ve etkili tedavi şekli cerrahi olarak tanımlanmıştır. Cerrahi tedavinin erişilemediği hallerde ya da hastanın klinik tablosunun cerrahi için uygun olmadığı durumlarda antibiyotik tedavisinin etkili olduğunu bildiren çalışmalar mevcuttur (23).

Komplike olmayan akut apandisit vakalarında medikal tedavi kullanılarak takip edilen vakalara ait çalışmalar mevcuttur. Son yapılan bazı çalışmalar ışığında bu seçilmiş vaka grubundan antibiyoterapi ile takibin yeterli olduğu gösteren kanıtlar mevcuttur (49).

Günümüzde halen akut apandisitte komplike olsun ya da olmasın standart tedavi apendektomi olarak kabul edilmektedir. Klinik, radyolojik ve laboratuvar bulgular eşliğinde tanı konulmasının ardından hastalara sıvı desteği ve etiyolojide belirtilen nedenlere uygun antibakteriyel ajan kullanımı önerilmiştir.

Açık cerrahi, laparoskopik cerrahi, robotik cerrahi ve NOTES gibi teknikler kullanılarak apendektomi yapılabilmektedir.

Açık cerrahi: Çoğunlukla genel anestezi altında ve supin pozisyounda yapılır. McBurney, transvers Rocky-Davis, Lanz, paramedian ya da median insizyonlar ile batına giriş gerçekleştirilir (Şekil 10)(50).



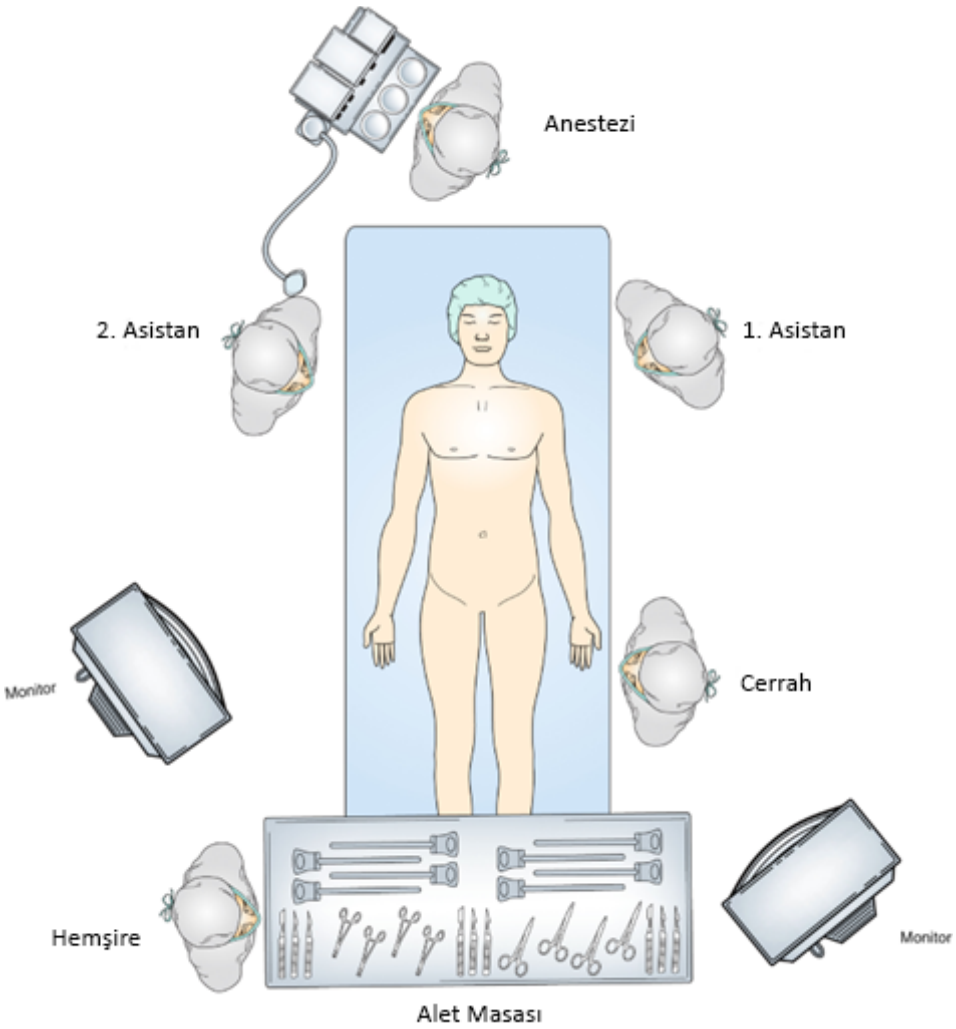
Şekil 10: Apendektomi insizyon çeşitleri (51)

Uygun insizyon tercihi yapıldıktan sonra cilt kesisi yapılır. Ardından cilt altında camper ve scarpa fasyaları diseke edilerek superficial fasya açılır. Ardından eksternal oblik kasın aponevrozu, internal oblik kas ve transversus abdominis kası diseke edilir. Fasya transversalis ve periton, klemp yardımıyla havaya kaldırılır. Keskin diseksiyon ile açılarak batına girilir. Tenia kolinin çekum üzerinden takip edilmesiyle apendiks köküne ulaşılır.

Apendiks bulunduktan sonra ilk olarak mezoapendiks diseke edilerek apendiks iskeletize edilir. Mezoapendiks kökünden bağlanarak apendiküler arter ligate edilir. Ardından apendiks radiksinden klips, sütur veya stapler adı verilen kapatıcılar kullanılarak transekte edilir ve apendektomi tamamlanır.

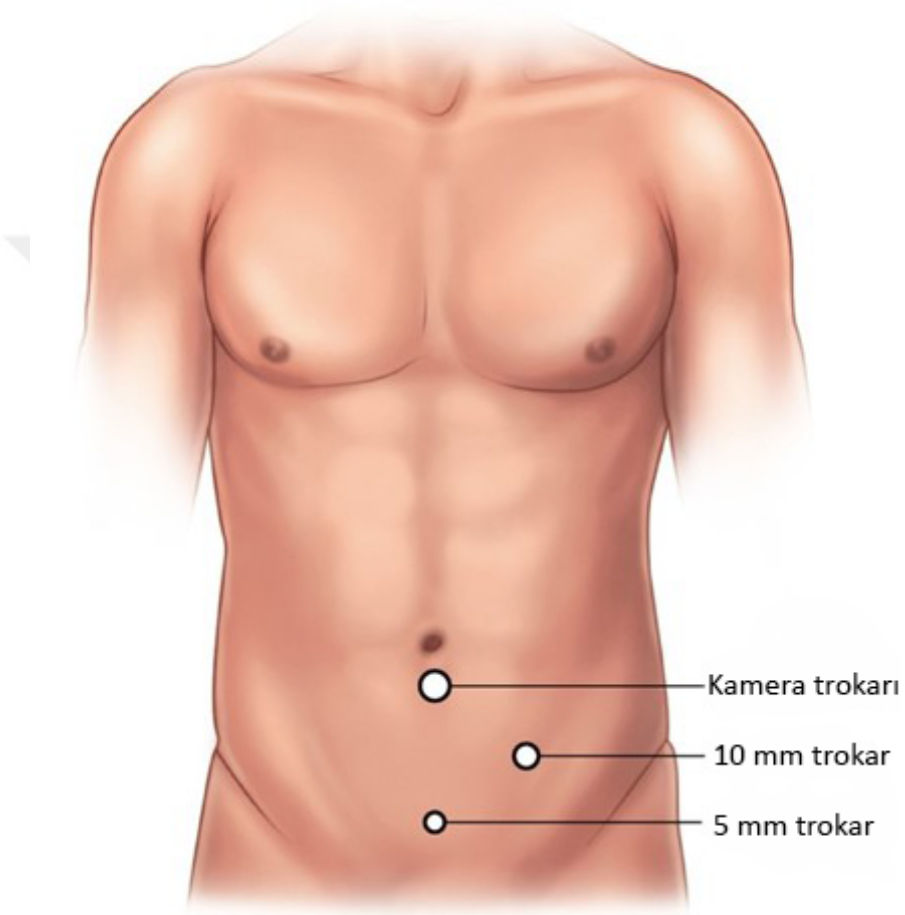
Batın içi apseler gereklilik halinde drene edilebilir. Pürülan mayi varlığında batın içi yayılımı önlemek amacıyla batın irrigasyonu genellikle önerilmez. Operasyon lojuna cerrahi dren yerleştirilebilir (23,50).

Laparoskopik cerrahi: İkinci bir teknik olarak laparoskopik apendektomi tanımlanmıştır. Genel anestezi altında gerçekleştirilir. Üriner kataterizasyon yapılarak mesane boşaltılır. Hasta supin pozisyonda sol kol ameliyat masasına bitişik şekilde pozisyon verilir. Primer cerrah ve 1. asistan hastanın sol tarafında yerleşir. Laparoskopik görüntü ekranı hastanın sağ ayak tarafında yerleştirilir (Şekil 11).



Şekil 11: Laparoskopik apendektomi ameliyathane yerleşimi (52)

Pozisyon ve yerleşimin ardından umblikus yaklaşık 1 cm altından yapılan kesi ile kamera trokarı yerleştirilir. Laparoskopi görüşü ile batın eksplore edilir. Akut apandisit tanısı kesinleştirilir. Ardından görüş altında sol alt kadrandan ve suprapubik alandan birer adet çalışma trokarları girilir (Şekil 12).



Şekil 12: Laparoskopik apendektomi trokar yerleşimi (53)

Hasta trendenleburg pozisyonuna alınarak operasyona başlanır. Açık apendektomide izlenen adımlar benzer şekilde uygulanarak laparoskopik apendektomi tamamlanır. Apendiks bir torba yardımıyla 10 mm lik trokar girişinden batın dışına alınır. Batın içi pürülan mayi varlığında sıvı aspire edilir.

Komplike apandisit, vakaların sıklıkla geç başvuruda bulunmasından kaynaklanması ile gerçekleşir. Hastaların yalnızca %20'sinin ağrının olduğu gün klinik başvurusu olduğu görülmüştür. Olgularda apendikste gangrenöz görünüm, perforasyon, apse bulguları izlenebilir. Bu bulgulara bağlı hastalarda septik görüntü izlenebilir (23).

Akut apandisit hastalarının yaklaşık %4'ünde preoperatif karın içi apse ya da pelvik apse izlenmektedir. Palpasyonda kitle varlığı apse lehine anlamlıdır (11).

Perfore apandisit tanısı almış hastalar ameliyat öncesinde destek tedavisinin tamamlanmasının ardından geciktirilmeden opere edilmelidir. Vakalarda açık ya da laparoskopik yöntemlerinin her ikisi de uygulanabilir. Teknik olarak birbirlerine net üstünlükleri bulunmamaktadır. Ameliyat sonrasında yara bakımı ve antibiyotik tedavisi alması önerilmektedir (23,50).

2.2.10. Komplikasyonlar

Apendektomi sonrası gelişen genel komplikasyon oranı yüzde % 8,2-31,4, ameliyat insizyonunda izlenen yara yeri enfeksiyonu oranı %3,3-10,3 ve pelvik apse görülme oranı %10,4 olarak görülmektedir (54).

Yara yeri enfeksiyonu ve pelvik apse genellikle perfore apandisit vakalarında görülür. Komplike olmayan vakalarda izlenmesi beklenmez. Ameliyat sonrası enfeksiyon gelişimini önlemek amacıyla geniş spektrumlu antibiyotik tedavisi ve yara yeri irrigasyonları önerilmektedir (55).

Açık ve laparoskopik cerrahi komplikasyon riskleri açısından incelendiğinde, laparoskopik cerrahinin yara yeri enfeksiyonu riskini azalttığı görülmüştür. Fakat batın içi ya da pelvik apse açısından anlamlı fark saptanmamıştır (56).

2.3. AKUT APANDİSİT TANISINDA YAPAY ZEKÂ

Sağlık biliminde verilerin istatistiksel analizinin gelişmesi ile birlikte bilgisayarlı karar destek sistemleri gelişme göstermektedir (57). Karar destek sistemleri, cerrahların acil vakaların tanısal değerlendirmelerini ve hastalık

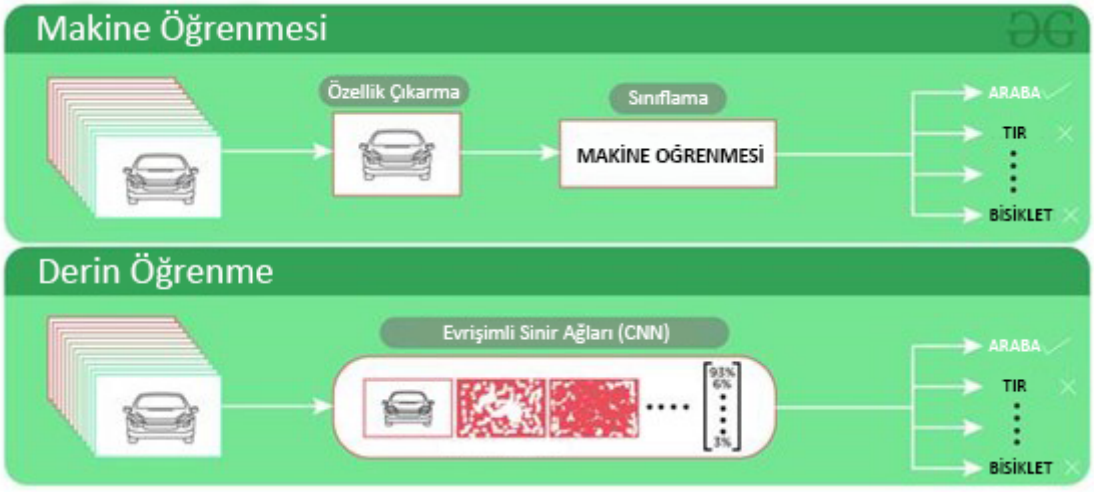
prognozunu kontrol etmesine, ayrıca komplike vakaların değerlendirilmesi için yapay zekanın kullanılmasına olanak sağlar (58).

Sağ alt kadran ağrısı olan akut apandisit hastalarında yapılan bir çalışmada yapay sinir ağlarının duyarlılığı %100, özgüllüğü %97,2, pozitif prediktif değeri %96, negatif prediktif değeri %100 olarak belirtilmiştir (59).

Başka bir çalışmada ise akut sağ alt kadran ağrısı olan hastaların akut apandisit için bilgisayarlı tomografi değerlendirilmesinde, yapay sinir ağlarının BT'ye dayalı tanısal duyarlılığının %90'nın üzerinde olduğu görülmüştür (60).

2.3.1. Derin Öğrenmeyi Kullanarak Nesne Tanıma

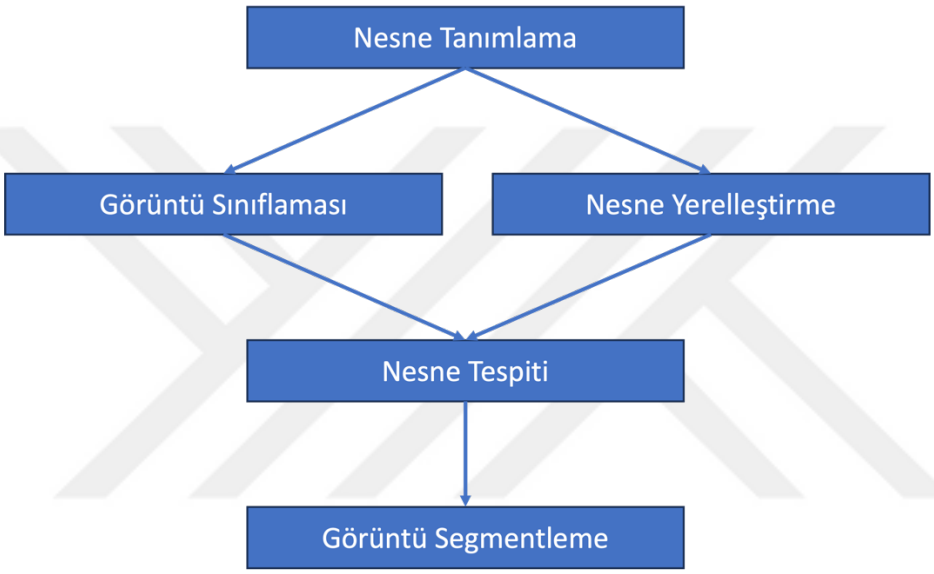
Evrişimli Sinir Ağı (Convolutional Neural Networks) (CNN), nesne tanıma uygulamasının popüler yöntemlerinden biridir. Yaygın olarak kullanılan ve en ileri teknolojiye sahip sinir ağları, görüntü sınıflandırma gibi nesne tanıma ile ilgili görevler için kullanır. CNN ağı girdi olarak bir görüntüyü alır ve farklı sınıfların olasılığını çıktı olarak verir. Eğer aranmak istenen nesne görüntüde mevcutsa, çıktı olasılığı yüksektir. Derin öğrenmenin makine öğrenimine göre avantajı incelendiğinde verilerden özellik çıkarma işleminin otomatik olarak yapılmasıdır (Şekil 13) (61).



Şekil 13: Makine öğrenimi ve derin öğrenme şemaları (61)

2.3.2. Görüntü Sınıflandırması:

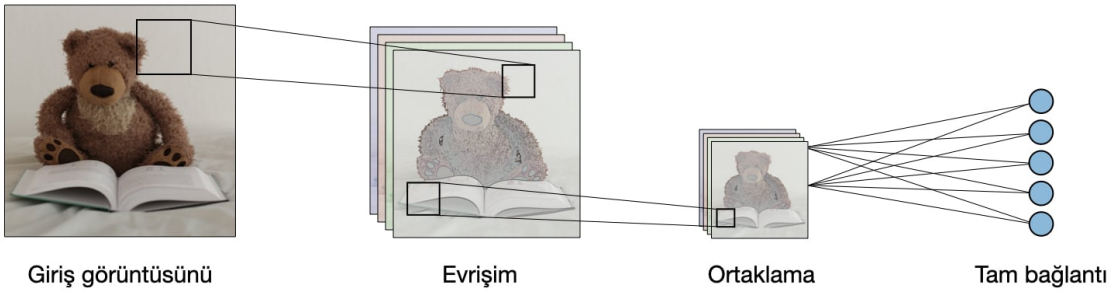
Görüntü sınıflandırmada, bir görüntüyü girdi olarak alır ve bu görüntünün sınıflandırma etiketini bazı ölçümlerle (olasılık, kayıp, doğruluk vb.) çıktı olarak verir. Örneğin: Bir kedi görüntüsü, belirli bir olasılıkla "kedi" sınıf etiketi olarak sınıflandırılabilir veya köpek görüntüsü, "köpek" sınıf etiketi olarak sınıflandırılabilir (Şekil 14)(61).



Şekil 14: Nesne tanımlama şeması (61)

2.3.3. Evrişimli Sinir Ağları:

Evrişimli sinir ağları, LeCun ve arkadaşları tarafından 1989 yılında ileri beslemeli bir yapay sinir ağı ve derin öğrenme mimarisidir (62). İnsanlar ve makineler arasında bulunan algılama farkını gidermek amacıyla canlıların görsel algı mekanizmalarından ilham alınarak CNN tasarlanmıştır. CNN'in temel amacı, görüntüler içinde bilgiyi anlamak, derin öğrenme teknikleri ile yeni görüntüler oluşturmak, görüntüler içindeki karmaşık özellikleri anlamaktır. CNN, bir görüntü üzerine çalışabilecek, görüntüdeki nesneleri algılayacak ve birbirini ayırt edebilecek şekilde tasarlanmış olan bir sistemdir (Şekil 15)(63).



Şekil 15: Evrişimli sinir ağları mimarisi (64)

Görüntü özelliklerinin çıkarılması aşamasında CNN mimarileri kullanılmıştır. Kullanılan bazı CNN mimarileri aşağıda sıralanmıştır.

- VGG16
- VGG19
- ResNet
- ResNet v2
- Inception v3
- InceptionResNet v2
- Xception
- EfficientNet
- MobileNet'dir.

3. GEREÇ VE YÖNTEM

3.1. ETİK KURUL İZNİ

Tez çalışmamız, İstanbul Kanuni Sultan Süleyman Sağlık Uygulama ve Araştırma Merkezi yerel etik kurulundan 27.09.2023 tarihli 2023.09.105 sayı numaralı karar ile onaylanmıştır. Helsinki bildirisine uyumlu şekilde gerçekleştirilmiştir. Çalışmamızın etik kurul onayı ekler bölümünde Ek 1 olarak verildi.

3.2. ÇALIŞMANIN YÖNTEMİ

01.01.2019 – 31.06.2023 tarihleri arasında akut apandisit tanısı alan ve tanı sürecinde bilgisayarlı tomografi çekilmiş hastalar incelendi. AA tanısıyla opere edilen, radyoloji ve patoloji raporunda akut apandisit tanısı değişmeyen tüm hastalar çalışma kapsamına alındı.

Dahil olma kriterleri:

- 18 yaş üzerinde olmak

- Akut apandisit tanısı almış olmak

- 01 Ocak 2019 ile 31 Haziran 2023 tarihleri arasında Kanuni Sultan Süleyman Sağlık Uygulama ve Araştırma Merkezi Genel Cerrahi kliniğinde ameliyat edilmiş olmak

Hariç tutma kriterleri:

- 18 yaş altı hastalar

- Patoloji sonucu akut apandisit olarak değerlendirilmemiş hastalar

- Gebe hastalar

- Malignite tanısı olan hastalar

- Eşlik eden ek acil patolojisi bulunan hastalar

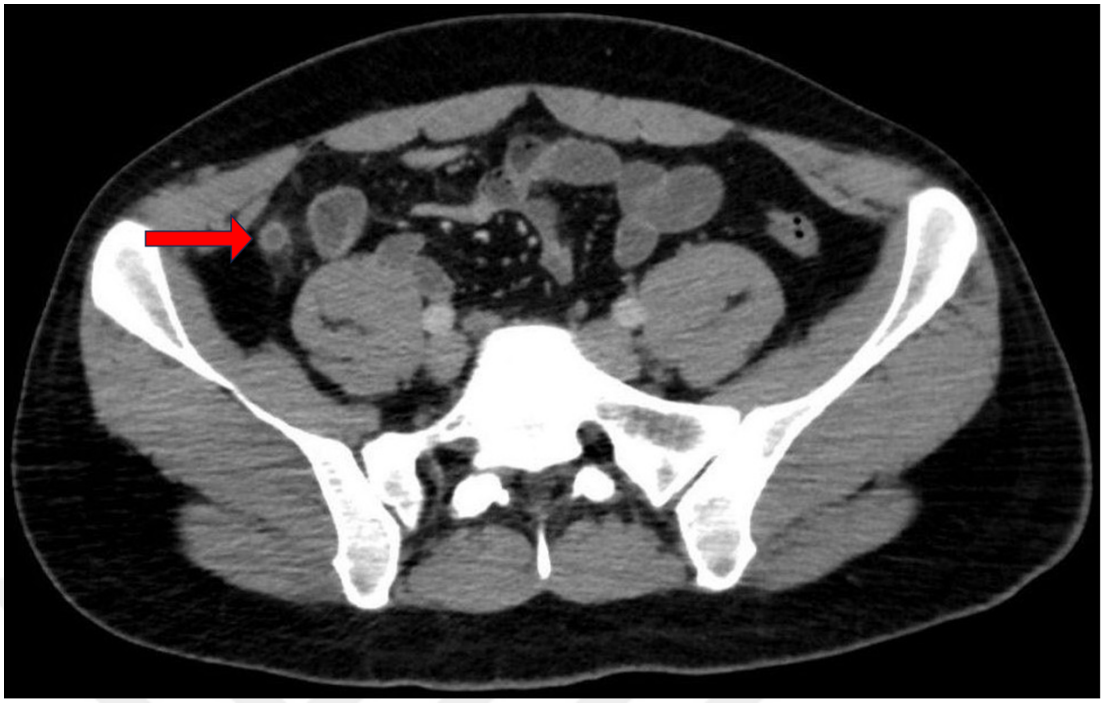
Kapsamda belirtilen tarih aralığında klinisyen (Genel Cerrahi Uzman Hekim) tarafından radyolojik görüntülerin incelenmesi ile akut apandisit tanısı doğrulanan hastalar çalışmaya dahil edildi. Tarama sonucunda hastaların yaş, cinsiyet gibi demografik verileri kaydedildi. Yine aynı tarihler arasında genel cerrahi kliniğinde akut apandisit dışı acil olmayan patolojiler nedeniyle yatışı gerçekleştirilmiş ve BT görüntüsü olan hastalar sağlıklı grubu oluşturmak üzere kaydedildi.

Yapay zeka tarafından eğitim ve test için modellerde kullanılacak veri sayısı, minimum 100 olarak belirlendi (65). Oluşturulan veri modellerinden ¨Image Classification¨ yani görüntü sınıflandırma özelliği içeren 4 model tespit edilerek çalışmada kullanılma kararı alındı. Dört model için 400 hastanın (Her iki grup için ayrı ayrı) verisi değerlendirildi.

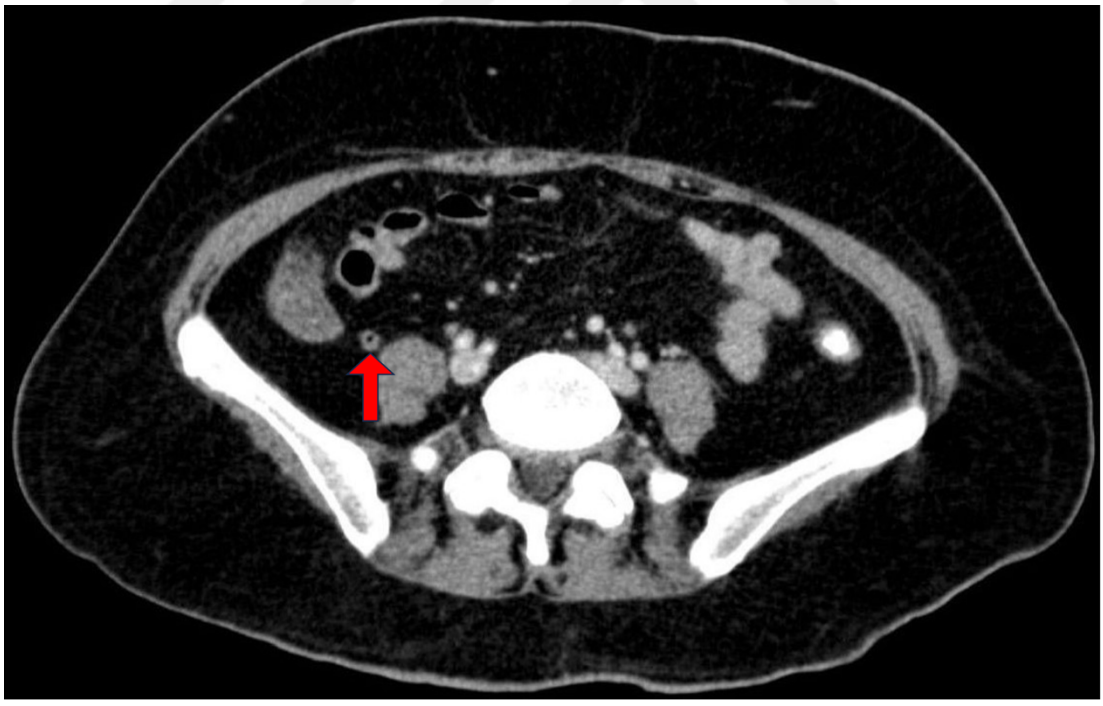
Bu kapsamda akut apandisit ve sağlıklı hastaların tarama sonucunda elde edilen BT görüntülerinden, akut apandisit hastalarının her birinden hastalığının eşlik ettiği 3 farklı kesit ve sağlıklı grupta olan hastaların her birinden hastalık bulguları olmayan 3 farklı kesit randomize olarak dahil edildi. Yaklaşık 1200 adet akut apandisit hastalığını içeren kesit (Şekil 16) ve 1200 adet sağlıklı apendiks kesiti (Şekil 17) (Toplam 2400 kesit) Joint Photographic Experts Group (Birleşik Fotoğraf Uzmanları Grubu) (*.jpeg) formatında 1164x734 piksel boyutlarında resim olarak kaydedildi (Tablo 8).

Tablo 8: Hastaların grup dağılımı

<table>
<tr><td colspan="3">Akut apandisit</td></tr>
<tr><td>1. kesit</td><td rowspan="3">400 hasta</td><td rowspan="3">1200 kesit görüntü</td></tr>
<tr><td>2. kesit</td></tr>
<tr><td>3. kesit</td></tr>
<tr><td colspan="3">Sağlıklı grup</td></tr>
<tr><td>1. kesit</td><td rowspan="3">400 hasta</td><td rowspan="3">1200 kesit görüntü</td></tr>
<tr><td>2. kesit</td></tr>
<tr><td>3. kesit</td></tr>
</table>



Şekil 16: Akut apandisit BT kesiti örneği (Kırmızı ok: İnflame apendiks) (Kanuni Sultan Süleyman SUAM Radyoloji Kliniği Arşivi – BT Görüntüleme)



Şekil 17: Sağlıklı hasta BT kesiti örneği (Kırmızı ok: Apendiks) (Kanuni Sultan Süleyman SUAM Radyoloji Kliniği Arşivi – BT Görüntüleme)

Görüntülerin %80'i yapay zekâ modellerinin eğitimi için (1920 kesit) kullanıldı. Kalan %20'lik görüntü karıştırılıp rastgele bir şekilde yapay zekâ modellerine akut apandisit tanısı doğrulaması amacıyla gösterildi (Tablo 9).

Tablo 9: BT görüntü kesitlerinin yapay zekâ modellerinde dağılımı

n=2400	Akut apandisit	Sağlıklı
Eğitim (%80)	960	960
Test (%20)	240	240

Tez çalışmamızda; MobileNet v2, ResNet v2, EfficientNet b2 ve Inception v3 isimli yapay zekâ modellerinde veriler işlendi.

MobileNet v2: Bu model, mobil ve gömülü görme uygulamaları için tanıtılmış olup derinlik açısından ayrılabilir evrişimlere dayanmaktadır. MobileNet, diğer birçok popüler modelden çok daha küçük boyutta ve performans açısından daha hızlı olan, basit bir derin CNN modelidir. Derinlik açısından ayrılabilir evrişimlerde her bir girdi kanalına tek bir filtre uygulanır. MobileNet, derinlikli ve noktasal evrişimler haricinde 28 katmana sahiptir. MobileNet mimarisi derinlemesine ayrılabilir evrişim işleminden faydalanarak parametre sayısını, işlem hacmini ve model karmaşıklığını düşürmüş, bu sayede donanımsal olarak kısıtları olan mobil ve gömülü cihazlarda kullanılabilir hale getirilmiştir (66).

ResNet V2: ResNet getirdiği yenilikle CNN'ler arasında ciddi bir konumda yer almıştır. ResNet'e kadar geliştirilen mimarilerde esas yaklaşım katman sayısını arttırarak derinliği arttırmak yönündedir. Fakat ağ derinliğini arttırmak gradyan yok olmasına sebep olduğu için modelin etkinliğini azaltmaktadır. Birçok çalışmada modelin derinliğini çok fazla artırmanın başarı oranını azalttığı gösterilmiştir (67). Resnet V2, ResNet'e benzer mimaride ve daha gelişmiş versiyonudur.

Inception v3: Inception mimarisiyle ResNet mimarisinin birleşiminden oluşan InceptionResNet v2 mimarisine göre doğruluk oranı düşük fakat maliyet oranıda düşük olan CNN mimarisidir.

Inception v3 mimarisi InceptionResNet mimarisine göre daha yüzeyel bir derin öğrenme mimarisidir (68).

EfficentNet b2: EfficientNet evrişimsel sinir ağı mimarisi 2019 yılında geliştirilmiştir. Model ölçeklendirilmesi sistematik olarak ele alınmıştır. EfficientNet bileşik ölçekleme yöntemi kullanılarak ağ derinliği, genişliği ve çözünürlüğü eşit olarak ölçeklenmiş ve bunun sonunda dengeli ve daha iyi performans elde edilmiştir. EfficientNet ağı 5,3 milyon parametreden oluşmaktadır ve mobil/gömülü cihazlarda kullanımı uygundur. (69).

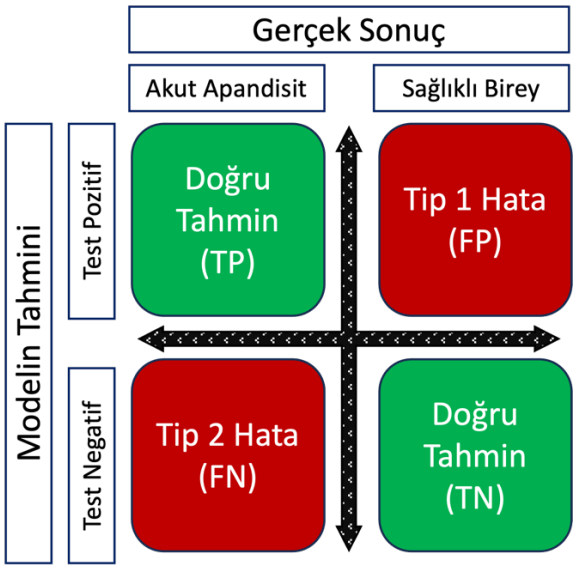
3.4. İSTATİSTİKSEL ANALİZ

a. Kategorik Değişken Analizi: Kategorik değişkenler için frekans ve yüzde, sürekli değişkenler için ortalama ve standart sapma, ortanca (minimum-maksimum), IQR (Interquartile Range) değerleri verildi. Sürekli değişkenlerin normalliği Shapiro-Wilk testi ile kontrol edildi. Normal dağılım göstermeyen sürekli değişkenler için Mann Whitney U test kullanıldı. Kategorik değişkenlerin karşılaştırılmasında Ki-Kare testi kullanıldı. Tüm analizler, Windows için Sosyal Bilimler İstatistik Paketi 22.0 (SPSS Inc., Chicago, Illinois, ABD) ile yapıldı ve $p < 0.05$ düzeyi olan sonuçlar anlamlı kabul edildi.

b. İkili Sınıflandırma: Modeller üzerinde bir girdi verisi için iki çıktıdan birini üreten ikili sınıflandırma (Binary Classification) yöntemi kullanıldı. İkili sınıflandırma pozitif ve negatif sınıflama olarak ikiye ayrıldı. Test sonuçlarına göre bir hastanın akut apandisit olup olmadığını belirleyen bir model oluşturuldu. Test sonucu negatifse hastanın sağlıklı olduğu, test sonucu pozitifse hastanın akut apandisit olduğu kabul edildi. Pozitif sınıf doğru pozitif (true-positive [TP]) (akut apandisit hasta) ve negatif sınıf ise doğru negatif (true-negative [TN]) (sağlıklı birey) olarak kabul edildi.

Yapay zekâ modelinde her zaman doğru sonuçlar oluşmayacağı ve modelin mükemmel çalışmayacağı düşünüldü. Sağlıklı bireyin test sonucunun pozitif olarak yani akut apandisit teşhisi olarak verilmesi yanlış-pozitif (false-positive [FP]) olarak tanımlandı. Akut apandisit olan hastanın test sonucunun negatif yani sağlıklı bir birey

olarak verilmesi ise yanlış-negatif (false-negative [FN]) olarak tanımlandı. Bu hatalar çok ciddi sorunlara yol açabilir. Yanlış-pozitif Tip 1 Hata (Type 1 Error) olarak, yanlış-negatif ise Tip 2 Hata (Type 2 Error) olarak tanımlandı (Şekil 18).



Şekil 18: İkili sınıflandırma şematik gösterim

c. Hata Matrisi (Confusion Matrix): Hata matrisi bir modelinin tahminlerinin ne kadar başarılı olduğunu özetleyen bir NxN tablosudur. Bir ekseni tahmin edilen sonuçları, diğer ekseni ise gerçek sonuçları gösterir (70). Hata matrisi, duyarlılık (recall), kesinlik (precision), doğruluk (accuracy) ve ROC (Receiver Operating Characteristic) eğrisini ölçmek için son derece yararlıdır.

Doğruluk (Accuracy), doğru tahmin edilen örneklerin sayısının (TP ve TN) toplam tahmin edilen örnek sayısına bölünmesiyle elde edilir.

$$Doğruluk = \frac{TP + TN}{TP + TN + FP + FN}$$

Kesinlik (Precision), pozitif olarak tahmin edilen örneklerin kaç tanesinin gerçekten pozitif olduğunu ölçer. Amaç, yanlış-pozitiflerin (FP) sayısını sınırlamak olduğunda, kesinlik (precision) bir performans ölçütü olarak kullanılır. Modelin çok sayıda yanlış pozitif üretmemesi yani yüksek bir hassasiyete sahip olması önemlidir. Precision, FP'nin FN'den daha yüksek olduğu durumlarda kullanışlı bir ölçümdür.

$$Kesinlik = \frac{TP}{TP + FP}$$

Duyarlılık (Recall), tüm pozitif sınıflardan ne kadar doğru tahmin ettiğimizi ölçer.

$$Duyarlılık = \frac{TP}{TP + FN}$$

F-skoru (F-score), kesinlik ile duyarlılık arasında bir denge vardır. Kesinlik ve duyarlılık çok önemli metrikler olsa da bunlardan sadece birine bakarak iki modeli karşılaştırmak zordur. Bunları karşılaştırılabilir hale getirmenin bir yolu, kesinlik ile duyarlılık değerinin harmonik ortalaması olan f-skorudur. Aynı anda kesinlik ve duyarlılığı ölçmeye yardımcı olur.

$$F1 - Skoru = 2\,\frac{Kesinlik\ x\ Duyarlılık}{Kesinlik + Duyarlılık}$$

Hastalarda aynı zamanda sensivite, spesifite, TPR ve FPR değerleri hesaplanarak kaydedildi.

$$Sensivite = \frac{TP}{TP + FN}$$

$$Spesifite = \frac{TN}{TN + FP}$$

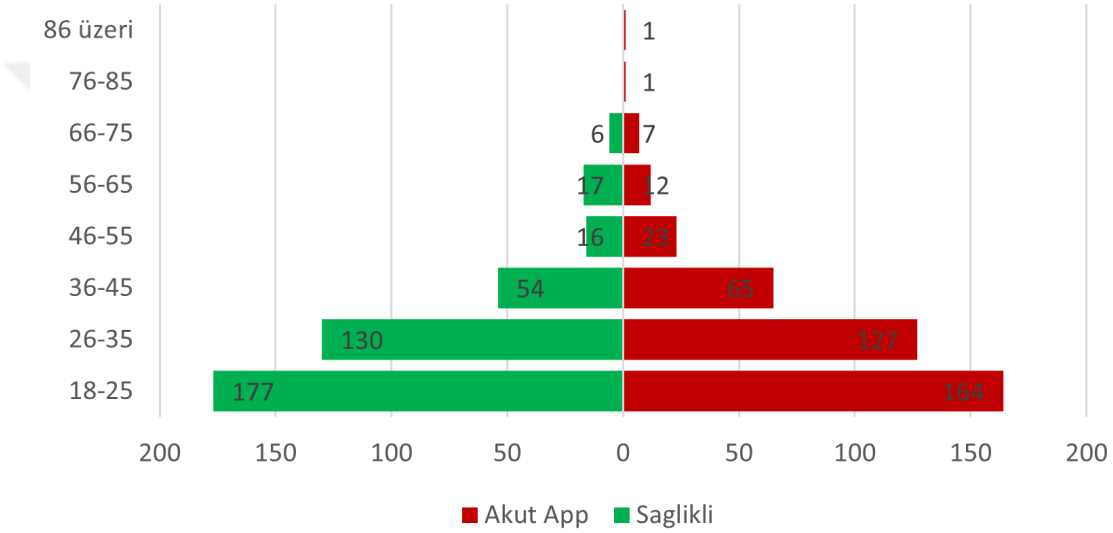
$$TPR = \frac{TP}{TP + FN}$$

$$FPR = 1 - Spesifite = \frac{FP}{TN + FP}$$

4. BULGULAR

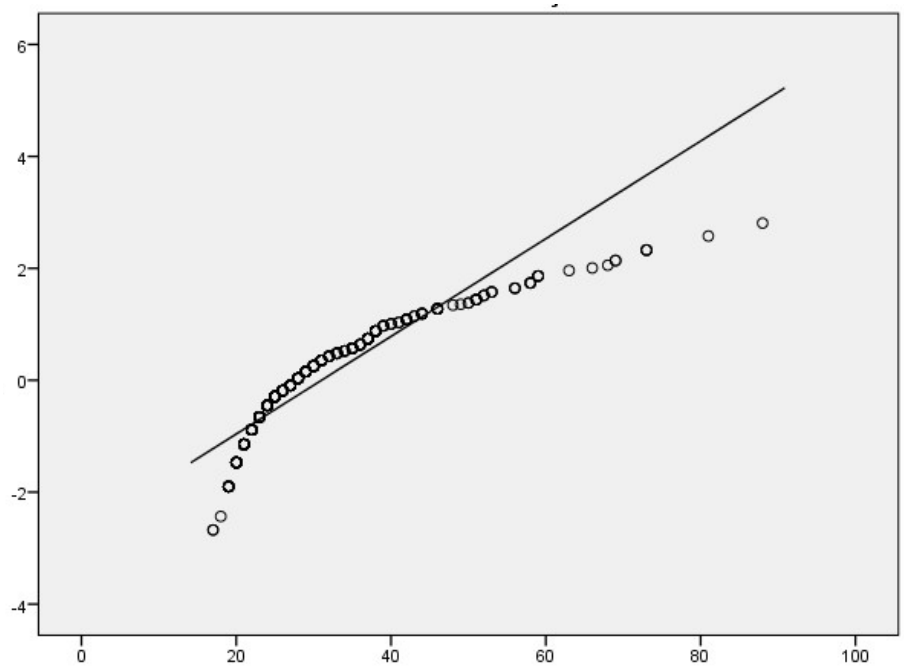
Çalışmaya 01 Ocak 2019 ve 31 Haziran 2023 tarihleri arasında akut apandisit nedeniyle opere edilmiş, tanı konulma aşamasında bilgisayarlı tomografi görüntüsü bulunan 800 hasta çalışmaya dahil edildi.

Çalışmada yaş değişkeni normal dağılım göstermiyordu (p <0,001). Çalışma grubunun yaş ortancası 28 (17–88) yıl, IQR:13, yaş ortalaması 30,48 ± 11,04 yıl idi. Yaş dağılım grafiği Şekil 19'da gösterildi.

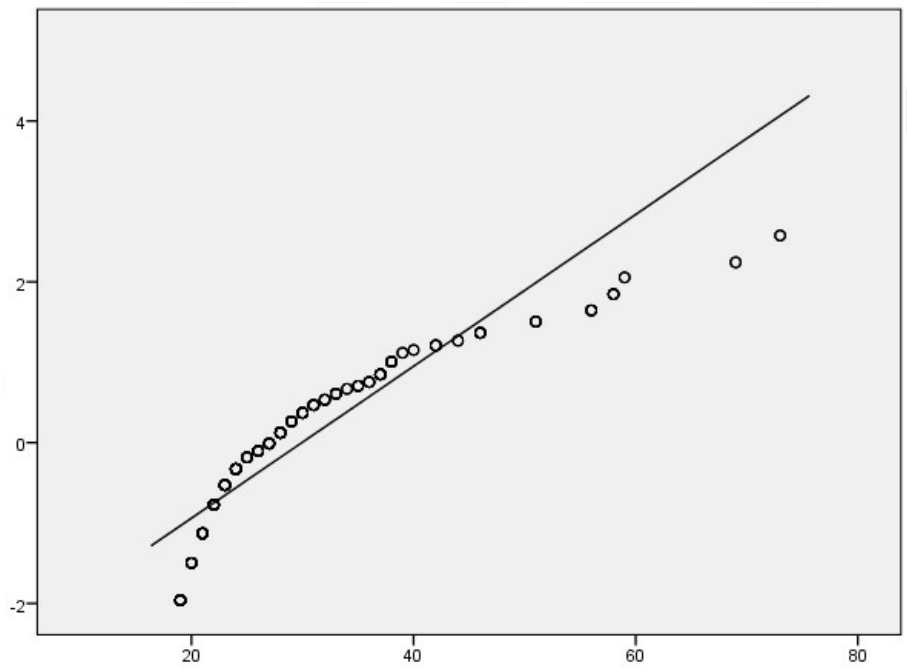


Şekil 19: Yaş dağılımı grafiği

Akut apandisit grubunda yaş ortancası 28 (17-88) yıl, IQR: 13,75, yaş ortalaması 31,01 ± 11,46 yıl iken sağlıklı grupta yaş ortancası 27 (19-73) yıl, IQR: 12, yaş ortlaması 29,95 ± 10,59 yıl idi. Gruplar arasında yaş parametresi açısından istatistiksel olarak anlamlı fark saptanmadı (p=0,168). Yaş gruplarının normal dağılımını içeren Q-Q grafikleri Şekil 20 ve Şekil 21'de gösterildi.

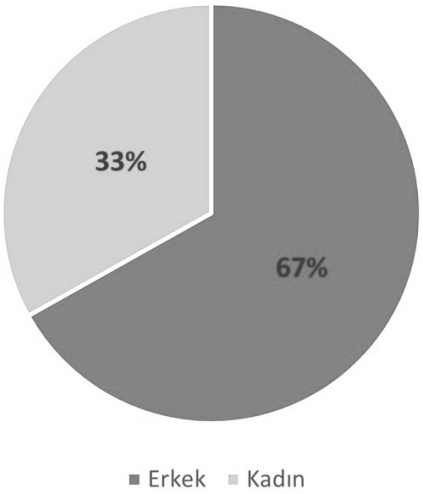


Şekil 20: Akut apandisit grubu yaş Q-Q grafiği



Şekil 21: Sağlıklı grup yaş Q-Q grafiği

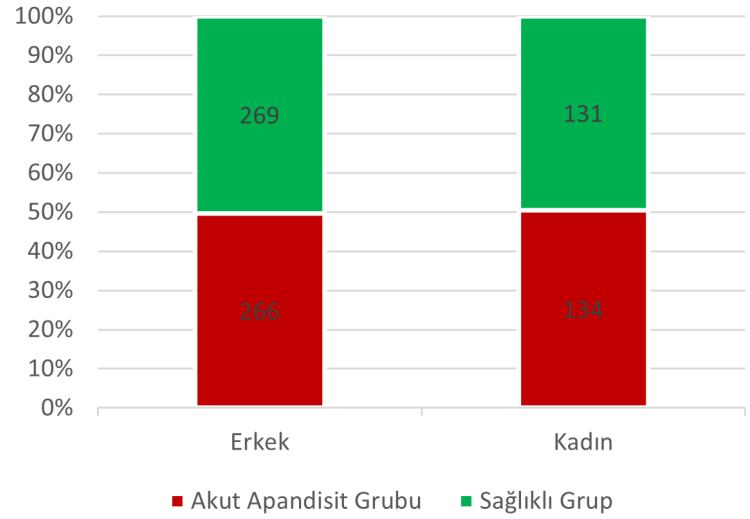
Akut apandisit grubunda 400 (%50) ve sağlıklı grupta 400 (%50) hasta mevcuttu. Çalışma grubunda 535 (%66,88) erkek ve 265 (%33,13) kadın hasta mevcuttu (Şekil 22).



	n	%
Erkek	535	66,88
Kadın	265	33,12

Şekil 22: Çalışma grubunun cinsiyet dağılımı

Akut apandisit grubunda 266 (%66,5) erkek, 134 (%33,5) kadın hasta ve sağlıklı grupta 269 (%67,25) erkek, 131 (%32,75) kadın hasta mevcuttu (Şekil 24). Gruplar arasında cinsiyet parametresi açısından istatistiksel olarak anlamlı fark saptanmadı (p=0,881).



		n	%
Akut Apandisit	**Erkek**	266	66,5
	Kadın	134	33,5
Sağlıklı	**Erkek**	269	67,25
	Kadın	131	32,75

Şekil 23: Akut apandisit ve sağlıklı grup cinsiyet dağılımı

Yapay zekâ modelinin eğitilmesi için tüm veri setinin kaç kere tekrar edilmesi gerektiğini gösteren eğitim turu sayısı (no of epochs) değeri 20 olarak ayarlandı. Her eğitim turunda (epoch) veri setinin kaçarlık kümelere ayrıldığını gösteren veri boyutu (batch size) değeri 32 olarak ayarlandı ve veriler 32'şerli kümeler haline getirilerek eğitimde kullanıldı.

Model eğitim süreci boyunca parametrelerin güncellemesi için düzenleyici (optimizer) olarak ¨Adam¨ kullanıldı. Her eğitim turunda (epoch) parametreler güncellenirken ne kadar büyüklükte adımlar atılmasını belirleyen parametre olan öğrenme oranı (learning rate) değeri 0,001 olarak ayarlandı (Tablo 10).

Tablo 10: Model Parametre Düzenlemeleri

Parametre	**Değer**
Öğrenme Oranı (Learning Rate)	0,001
Veri Boyutu (Batch Size)	32
Eğitim Turu Sayısı (No of Epochs)	20

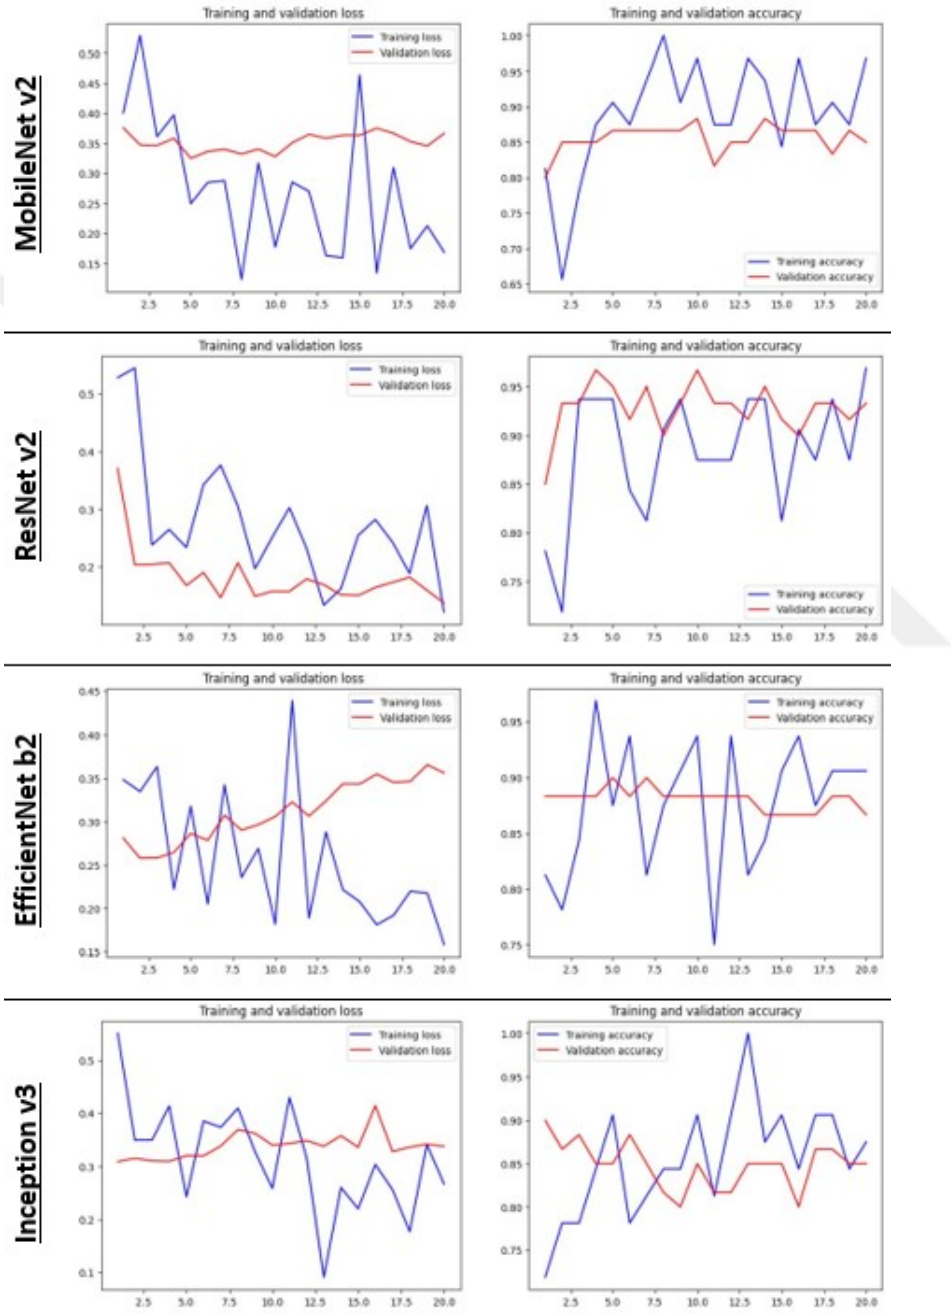
Yapay zekâ modellerinde giriş görüntü boyutları, MobileNet v2 için 224 x 224 x 3; ResNet v2 için 224 x 224 x 3; EfficientNet b2 için 260 x 260 x 3; Inception v3 modeli için 299 x 299 x 3 piksel olarak başlatıldı.

Modellerdeki toplam parametre sayısı, MobileNet v2 için 2,260,546; ResNet v2 için 58,335,746; EfficientNet b2 için 7,771,380 ve Inception v3 için 21,806,882 olarak hesaplandı (Tablo 11).

Tablo 11: Model çıktıları hakkında karşılaştırma

Model Adı	**Görüntü Giriş Boyutu**	**Toplam Parametre Sayısı**
MobileNet v2	224 x 224 x 3	2,260,546
ResNet v2	224 x 224 x 3	58,335,746
EfficientNet b2	260 x 260 x 3	7,771,380
Inception v3	299 x 299 x 3	21,806,882

Yapay zekâ modellerinin genelleme (veri setlerini algılama) düzeyini anlamak ve fazla/yetersiz uyumluluğu tespit etmek amacıyla eğitim ve test dönemlerinde doğruluk ve kayıp eğrileri hesaplanmıştır. Modeller arasında en iyi trendin (Kayıp değeri azalan, doğruluk değeri artan) ResNet v2 modelinde olduğu görüşmüştür (Şekil 24).



Şekil 24: Modellerin kayıp-doğruluk eğrileri

MobileNet v2 modelinde, doğru pozitif 168 hasta, yanlış pozitif 37 hasta, yanlış negatif 72 hasta ve doğru negatif 203 hasta olarak kaydedildi (Tablo 12). Modelin sensivitesi 0,7 ve spesifitesi 0,845833 olarak belirlendi.

Hata matrisi sonucunda model performasnları incelendiğinde, doğruluk değeri 0,772917, kesinlik değeri 0,819512, duyarlılık değeri 0,7 ve F-Skor değeri 0,755056 olarak sonuçlandı.

Tablo 12: MobileNet v2 hata matrisi sonuçları

		Model Tahmin Sonuçları	
	n=480	Akut Apandisit	Sağlıklı
Gerçek Sonuçlar	**Akut Apandisit**	168	72
	Sağlıklı	37	203

Modelin doğru pozitif oranı (TPR) 0,7 ve yanlış pozitif oranı (FPR) 0,154167 olarak sonuçlandı.

ResNet v2 modelinde, doğru pozitif 179 hasta, yanlış pozitif 50 hasta, yanlış negatif 61 hasta ve doğru negatif 190 hasta olarak kaydedildi (Tablo 13). Modelin sensivitesi 0,7458333 ve spesifitesi 0,7916667 olarak belirlendi.

Hata matrisi sonucunda model performasnları incelendiğinde, doğruluk değeri 0,76875, kesinlilik değeri 0,7816594, duyarlılık değeri 0,7458333 ve F-Skor değeri 0,7633262 olarak sonuçlandı.

Tablo 13: ResNet v2 hata matrisi sonuçları

		Model Tahmin Sonuçları	
	n=480	Akut Apandisit	Sağlıklı
Gerçek Sonuçlar	**Akut Apandisit**	179	61
	Sağlıklı	50	190

Modelin doğru pozitif oranı (TPR) 0,7458333 ve yanlış pozitif oranı (FPR) 0,2083333 olarak sonuçlandı.

EfficientNet b2 modelinde, doğru pozitif 149 hasta, yanlış pozitif 33 hasta, yanlış negatif 91 hasta ve doğru pozitif 207 hasta olarak kaydedildi (Tablo 14). Modelin sensivitesi 0,620833 ve spesifitesi 0,8625 olarak belirlendi.

Hata matrisi sonucunda model performasnları incelendiğinde, doğruluk değeri 0,741667, kesinlik değeri 0,818681, duyarlılık değeri 0,620833 ve F-Skor değeri 0,706161 olarak sonuçlandı.

Tablo 14: EfficientNet b2 hata matrisi sonuçları

		Model Tahmin Sonuçları	
	n=480	Akut Apandisit	Sağlıklı
Gerçek Sonuçlar	**Akut Apandisit**	149	91
	Sağlıklı	33	207

Modelin doğru pozitif oranı (TPR) 0,620833 ve yanlış pozitif oranı (FPR) 0,1375 olarak sonuçlandı.

Inception v3 modelinde, doğru pozitif 187 hasta, yanlış pozitif 43 hasta, yanlış negatif 53 hasta ve doğru pozitif 197 hasta olarak kaydedildi (Tablo 15). Modelin sensivitesi 0,779167 ve spesifitesi 0,820833 olarak belirlendi.

Hata matrisi sonucunda model performasnları incelendiğinde, doğruluk değeri 0,8, kesinlik değeri 0,813043, duyarlılık değeri 0,779167 ve F-Skor değeri 0,795745 olarak sonuçlandı.

Tablo 15: Inception v3 hata matrisi sonuçları

		Model Tahmin Sonuçları	
	n=480	Akut Apandisit	Sağlıklı
Gerçek Sonuçlar	**Akut Apandisit**	187	53
	Sağlıklı	43	197

Modelin doğru pozitif oranı (TPR) 0,779167 ve yanlış pozitif oranı (FPR) 0,179167 olarak sonuçlandı.

Tüm CNN modelleri kıyaslandığında modellerimiz arasında en başarılı doğruluk oranına sahip olan model Inception v3, kesinlik oranı en yüksek olan model MobileNet v2 idi. Modeller arasında kesinlik ve duyarlılık arasındaki dengeyi gösteren F-score değeri en yüksek Inception v3 modelinde saptandı. Sensivite değeri incelendiğinde en yüksek model Inception v3 iken spesifite değeri en yüksek olan model EfficientNet b2 olarak saptandı (Tablo 16).

Tablo 16: Tüm modellerin performans değerleri

Model Adı	**Doğruluk**	**Kesinlik**	**Duyarlılık**	**F-Skoru**
MobileNet v2	0,772917	0,819512	0,7	0,755056
ResNet v2	0,76875	0,7816594	0,7458333	0,7633262
EfficientNet b2	0,741667	0,818681	0,620833	0,706161
Inception v3	0,8	0,813043	0,7791667	0,795745
	Sensivite	**Spesifite**	**TPR**	**FPR**
MobileNet v2	0,7	0,845833	0,7	0,154167
ResNet v2	0,7458333	0,7916667	0,7458333	0,2083333
EfficientNet b2	0,620833	0,8625	0,620833	0,1375
Inception v3	0,7791667	0,820833	0,7791667	0,179167

5. TARTIŞMA

Akut apandisit, acil serviste akut karın ile karşılaşılan hastalıklar arasında en sık görülen klinik tablodur (1). Klinik bulguların her hasta için farklı sonuçlar içermesi, görüntüleme yöntemlerinin tanı koymadaki etkilerinin eksikliği ve geliştirilen klinik skorlama sistemlerine rağmen halen AA tanısı kolaylıkla koyulamamaktadır (3–8). Tanı gecikmesi sonucu ortaya çıkabilecek kompilkasyonlardan perforasyon %13-20 arasında, pelvik ya da karın içi apse ise %4 oranında görülmektedir. (9,11). Tüm bu veriler AA tanısının erken konulmasını destekler niteliktedir.

Körner H ve arkadaşlarının 1997 yılında yaptığı epidemiyoloji çalışmasında %53 (794 hasta) erkek ve %47 (692 hasta) kadın olarak bulundu. Yaş ortalaması 35,16 yıl olarak izlendi (71). Ayrıca Golz R ve arkadaşları tarafından yapılan 5 yılllık verinin incelendiği retrospektif bir çalışmada 35830 AA hasta değerlendirilmiş, %46,4 (16574) hasta kadın, %53,6 (19156) hasta erkek olarak saptanmıştır. Ortanca yaş 29 yıl olarak saptanmıştır (72). Çalışmamızda yaş değişkeninin tüm hasta grubunda, AA hasta grubunda ve sağlıklı grupta fark göstermediği görüldü ve literatürde gözlenen diğer çalışmalara benzer olarak ortalama 30,48 ± 11,04 yıl olarak bulundu. Cinsiyet değişkeni açısından değerlendirildiğinde de AA grubu ve sağlıklı grup arasında anlamlı fark görülmediği saptandı. Bizim çalışmamızda da literatürle uyumlu olarak erkek cinsiyette daha fazla AA tanısı görüldü. Sonuç olarak literatüre benzer oranlarda ve homojen dağılım gösteren hasta gruplarımız mevcuttu.

Akbulut S ve arkadaşları tarafından yapılan 1465 akut apandisit ve 332 AA olmayan hasta içeren çalışmasında hastaların laboratuvar verileri yapay zekâ modeline yüklenerek tanı konulmaya çalışılmıştır. Kullanılan CatBoost modelinin sensivitesi %84,2, spesifitesi %93,2, doğruluk değeri %88,2 ve F-skoru %88,7 olarak saptanmıştır (73). Elde edilen model sonuçlarının çalışmamıza göre yüksek olmasını hasta dağılımının akut apandisit lehine fazla olmasıyla ilişkili olduğunu düşünmekteyiz.

Akgül ve arkadaşları tarafından 2019 yılında yürütülen çalışmada AA ile ilişkili laboratuvar markerları ve USG bulguları yapay zekâ tekniği ile kombine edilmiştir. Çalışma sonucunda yapay zekâ ile desteklenen tüm veriler incelendiğinde sensivite %89,2 ve spesifite %81,2 olarak saptanmıştır (74). Elde edilen verilerin çoğunlukla subjektif veriler olması yapay zekâ modellerinin daha fazla anlamlı sonuç vermesine sebep olmuş olabilir. Çalışmamızda BT görüntüleri USG'ye kıyasla daha objektif olması nedeniyle tercih edilmiş ve ek müdahele gerektirmeden derin öğrenme yöntemiyle görüntü özellikleri çıkartılmıştır.

Ghareeb WM ve arkadaşlarının 319 apendektomi yapılan hasta ile yaptığı çalışmada, hastaların klinik, fizik muayene ve laboratuvar bulguları ile alvarado skoru hesaplanmış, USG bulguları kaydedilmiştir. Çalışmada yapay zeka modeli, alvarado skoru, USG ve her iki değerlendirme kombine edilerek karşılaştırılmıştır. Yapay zeka modelinin sensivite değeri %100, spesifite değeri %80 ve doğruluk değeri %97,9 olarak saptanmıştır (75). Hsieh CH ve arkadaşlarının 180 hasta ile yaptığı çalışmada ise alvardo skoru için gerekli klinik bulgular ve laboratuvar değerleri yapay zekâ modelinde değerlendirilmiştir. Modelin sensivite değeri %94, spesifite %85 ve doğruluk %91 olarak bulunmuştur (76). Bu çalışmalarda farklı olarak çalışmamızda akut apandisit nedeniyle ameliyat yapılan gruba ilave olarak apendiksi sağlıklı olanlardaa eklenerek yapay zekanın BT görüntüleri ile tanı sonuçları değerlendirilmiştir.

Gudelis M ve arkadaşlarının sağ alt kadran ağrısını değerlendirmek için yaptığı çalışmada "The CHAID" modeli ve yapay nöral ağlar kullanılmıştır. Modellerde klinik bulgular, laboratuvar bulguları ve semptom süresi değerlendirilmiştir. AA için yapay nöral ağlarda doğruluk oranı %93,5 ve CHAID için %81,7 olarak saptanmıştır (77). Park SY ve arkadaşlarının 801 hasta dahil edilerek 2015 yılında yaptığı çalışmada, hastaların klinik bulguları 3 yapay zeka ağı kullanılarak değerlendirilmiştir. Değerlendirme sonucunda tüm yapay zeka sistemlerinde sensivite ve spesifite değerlerinin %90 üzerinde olduğu saptanmıştır (78). Prabhudesai SG ve arkadaşlarının çalışmasında ise 60 hasta anamnez ve fizik muayene bulguları ile değerlendirilmiş, değerlendirme sonucunda yapay zeka ağlarının sensivite değeri %100 ve spesifite

değeri %97,2 olarak tespit edilmiştir (79). Yoldas O ve arkadaşlarının yaptığı çalışmada 156 hasta retrosepktif olarak çalışmaya dahil edilmiş, klinik ve laboratuvar bulguları ile oluşturulan yapay zeka modelinde sensivite oranı %97 ve spesifite oranı %100 olarak saptanmıştır (59). Yukarıdaki çalışmalarda yapay zekâ modelleri tarafından değerlendirilen parametreler subjektif verileri içermekte idi. Bizim çalışmamızda ise objektif değerlendirme yöntemlerinden biri olan BT görüntüleri kullanılmıştır.

Kim KB ve arkadaşlarının USG görüntülerini Fuzzy C-means isimli yapay zekâ modeli ile değerlendirdiği çalışmada, 85 akut apandisit hastasının görüntüleri incelenmiştir. Modelin doğruluk oranı %96,47 olarak saptanmıştır (80). Bizim çalışmamızdan farklı olarak Kim KB ve arkadaşlarının çalışmasında AA tanılı hastalar kullanılmış olması ve kontrol grubunun olmaması başarı oranın yüksek olmasının nedeni olabilir.

Lee GP ve arkadaşlarının 2 boyutlu BT görüntüleri ile yaptığı çalışmada AA ve divertikülit tanıları değerlendirilmiştir. Çalışmaya dahil edilen 500 hastadan 2782 BT görüntü kesiti AA için ve 823 BT görüntü kesiti divertikülit için kaydedilmiştir. EfficientNet modeli kullanılan çalışmada EfficientNet b2 için doğruluk değeri %90,47 ve kesinlik değeri %92,78 olarak saptanmıştır (81). Çalışmada akut apandisit ve divertikülit grubu kıyaslanmış ve tüm hastalarda eşlik eden patolojiler mevcut idi. Bizim çalışmamızda ise değerlendirilen gruplardan birinde apendiks görüntüsü sağlıklı hastalar mevcut idi.

Dai Su ve arkadaşlarının 8 yıllık veri toplama süreci sonrasında 2022 yılında yayınladıkları çalışmada acil servis başvurularında karın ağrısı tespit edilen 28657 hasta incelenmiş 655 hasta akut apandisit olarak çalışmaya dahil edilmiştir. LR ve RF yapay zeka modellerinde semptomatik değerlendirme yapılmış ve modellerin eğitim süreci sonrasında LR modeli için sensivite %69-73, spesifite %67-70, doğruluk %93-96 ve RF modeli için sensivite %65-68, spesifite %63-71, doğruluk %96-97 olarak saptanmıştır (82). Eylül 2023'te yayınlanan Lam A. ve arkadaşları tarafından yayınlanan sistematik derlemede, akut apandisitte yapay zekâ kullanımı ile ilgili 10

makale değerlendirilmiştir. Çeşitli yapay zeka modellerini içeren bu derleme soncunda sensivite değerleri %87,2-95, spesifite değerleri %33-81,2 ve doğruluk değerleri %51-94,69 arasında değişmekte olduğu izlenmiştir (83). Hasta sayısı yüksek olan bu çalışmalarda da subjektif klinik bulguların değerlendiriliyor olması çalışmamızdan farklılık göstermekte idi.

Park SH. ve arkadaşlarının yayınlanan çalışmasında EfficientNet modeline BT görüntüleri tanıtılarak 246 akut apandisit hastası ve 215 akut apandisit olmayan sağlıklı grup incelenmiştir. Çalışma sonucunda modelin AA için sensivitesi %85,6, spesifitesi %86,5 ve doğruluk değeri %86,07 olarak izlenmiştir (84). Rajpurkar P. ve arkadaşları tarafından AppendiXNet isimli model geliştirilerek yapılan çalışmada 646 hastanın BT görüntüleri üç boyutlu şekilde incelenerek akut apandisit tanısı değerlendirilmiştir. Çalışma sonucunda AA tespit oranı %81, normal apendiks tespit edilme oranı %43-58 olarak saptanmıştır (85). Park JJ. ve arkadaşlarının yaptığı çalışmada 215 akut apandisit ve 452 sağlıklı hastadan elde edilen BT görüntüleri üç boyutlu olarak incelenmiştir. Görüntüler üç boyutlu inceleme için tasarlanmış CNN modellerinde incelenmiştir. Modellerin sensivite değeri %90,2, spesifite değeri %92 olarak tespit edilmiştir (60). Bizim çalışmamızda ise AI tahmin modellerimizde; MobileNet v2 için sensivite 0,7, spesifite 0,845833, doğruluk 0,772917; ResNet v2 için sensivite 0,745833, spesifite 0,7916667, doğruluk 0,76875; EfficientNet b2 için sensivite 0,620833, spesifite 0,8625, doğruluk 0,741667; Inception v3 için sensivite 0,779167, spesifite 0,820833, doğruluk 0,8 olarak bulundu. Çalışmamızda sensivite ve spesifite değerlerinin literatürdeki diğer iki boyutla yapılan çalışmalarla kıyaslandığında benzer sonuçlar içerdiği gözlenmiştir. Üç boyutlu incelemelerde görüntünün farklı açılardan değerlendirilmesinin modelin başarı oranını arttırdığı öngörülebilir.

Çalışmamızın bazı kıstılıkları mevcuttu. Çalışmaya klinik değerlendirme sonrası yalnız akut apandisit nedeniyle opere edilen hastalar dahil edildi. Ek gastrointestinal sistem bulguları olan hastalar çalışma dışında bırakıldı. Bu durumda, modelin AA hastalarına spesifik değerlendirilmesine ve modelin gerçek performas değerini göstermemesine yol açacaktır. Retrospektif tasarımlı çalışma yerine

yapılabilecek prospektif randomize bir çalışma sonuçlarının güvenilirliğini arttıracaktır.

6. SONUÇ

Yapay zekâ ve yapay zekaya bağlı teknolojiler günlük hayatta sıklıkla yer almaya başlamaktadır. İyi huylu ve kötü huylu hastalıkların tanınmasında başarıları katlanarak artış göstermektedir. Tanısal amaçla kullanılan yapay zekâ modeli kesin olarak belirtilmese de pratikte birçok model kullanılmaktadır.

Çalışmamızda AA teşhisi için kullandığımız 4 adet farklı CNN mimarisi modelinde en yüksek sensivite oranı %77 ve en yüksek spesifite oranı %86 olarak gözlemlenmiştir. Ayrıca kullanılan modellerin sonuçlarının literatürde gözlenen diğer tanısal sonuçlarla uyumluluk göstermesi tanısal inceleme açısından bize güven vermektedir.

Akut apandisit tanısında kullanılan BT görüntülemesinin yapay zekâ sistemleri ile desteklenmesi halinde AA teşhisinde sensivite, spesifite ve doğruluk değerlerinin artacağını düşünmekteyiz.

7. KAYNAKLAR

1. Addiss DG, Shaffer N, Fowler BS, Tauxe RV. The epidemiology of appendicitis and appendectomy in the United States. Am J Epidemiol. 1990;132(5):910-25. doi:10.1093/oxfordjournals.aje.a115734

2. Prystowsky JB, Pugh CM, Nagle AP. Current problems in surgery. Appendicitis. Curr Probl Surg. 2005;42(10):688-742. doi:10.1067/j.cpsurg.2005.07.005

3. Noureldin K, Hatim Ali AA, Issa M, Shah H, Ayantunde B, Ayantunde A. Negative Appendicectomy Rate: Incidence and Predictors. Cureus. 2022;14(1):e21489. Published 2022 Jan 22. doi:10.7759/cureus.21489

4. Van Way CW 3rd, Murphy JR, Dunn EL, Elerding SC. A feasibility study of computer aided diagnosis in appendicitis. Surg Gynecol Obstet. 1982;155(5):685-88.

5. Pouget-Baudry Y, Mucci S, Eyssartier E, et al. The use of the Alvarado score in the management of right lower quadrant abdominal pain in the adult. J Visc Surg. 2010;147(2):40-4. doi:10.1016/j.jviscsurg.2010.05.002

6. Lintula H, Pesonen E, Kokki H, Vanamo K, Eskelinen M. A diagnostic score for children with suspected appendicitis. Langenbecks Arch Surg. 2005;390(2):164-170. doi:10.1007/s00423-005-0545-8

7. Chong CF, Adi MI, Thien A, et al. Development of the RIPASA score: a new appendicitis scoring system for the diagnosis of acute appendicitis. Singapore Med J. 2010;51(3):220-5.

8. Sigdel GS, Lakhey PJ, Mishra PR. Tzanakis score vs. Alvarado score in acute appendicitis. JNMA J Nepal Med Assoc. 2010;49(178):96-9.

9. Andersson RE, Hugander A, Thulin AJ. Diagnostic accuracy and perforation rate in appendicitis: association with age and sex of the patient and with appendicectomy rate. Eur J Surg. 1992;158(1):37-41.

10. Temple CL, Huchcroft SA, Temple WJ. The natural history of appendicitis in adults. A prospective study. Ann Surg. 1995;221(3):278-81. doi:10.1097/00000658-199503000-00010

11. Livingston EH, Woodward WA, Sarosi GA, Haley RW. Disconnect between incidence of nonperforated and perforated appendicitis: implications for pathophysiology and management. Ann Surg. 2007;245(6):886-92. doi:10.1097/01.sla.0000256391.05233.aa

12. Deo RC. Machine Learning in Medicine. Circulation. 2015;132(20):1920-1930. doi:10.1161/CIRCULATIONAHA.115.001593

13. A. Callahan, N.H. Shah, Machine learning in healthcare, in: A. Sheikh, D. Bates, A. Wright, K. Cresswell (Eds.), Key Advances in Clinical Informatics: Transforming Health Care through Health Information Technology, Elsevier Scinece & Technology, Stanford, CA, 2017, pp. 279-91.

14. Young P. La apendicitis y su historia [Appendicitis and its history]. Rev Med Chil. 2014;142(5):667-672. doi:10.4067/S0034-98872014000500018

15. Seal A. Appendicitis: a historical review. Can J Surg. 1981;24(4):427-33.

16. McBurney CM. Experience with early operative interference in cases of disease of the vermiform appendix. NY State Med J 1889;50:676–84.

17. Semm K. Endoscopic appendectomy. Endoscopy. 1983;15(2):59-64. doi:10.1055/s-2007-1021466

18. Silberhumer GR, Birsan T, Noda W, et al. Design and instrumentation of new devices for performing appendectomy at colonoscopy (with video). Gastrointest Endosc. 2008;68(1):139-45. doi:10.1016/j.gie.2008.02.024

19. Bernhardt J, Steffen H, Schneider-Koriath S, Ludwig K. Clinical NOTES appendectomy study: comparison of transvaginal NOTES appendectomy in hybrid technique with laparoscopic appendectomy. Int J Colorectal Dis. 2015;30(2):259-67. doi:10.1007/s00384-014-2081-x

20. T.W. Sadler Chapter 15: Digestive System in Langmans Medical Embryology 14th Edition, Philadelphia, Wolters Kluver Health, 2019, pp 247-8

21. Keith L. Moore, T.V.N. Persaud, Mark G. Torchia Chapter 11: Alimentary System in The Developing Human. Clinically Oriented Embryology 10th Edition, Philadelphia, 2016, p.226

22. Constantin M, Petrescu L, Mătanie C, et al. The Vermiform Appendix and Its Pathologies. Cancers (Basel). 2023;15(15):3872. Published 2023 Jul 29. doi:10.3390/cancers15153872

23. Fadi S. Dahdaleh, David Heidt, and Kiran K. Turaga, Chapter 30: The Appendix in Brunicardi FC, Andersen DK, Billiar TR, Dunn DL, Hunter JG, Kao LS et al. Schwartz 11th Edition, McGraw-Hill Education , 2019, pp. 1331-43

24. Paulsen F, Waschke J. Organs of the Abdominal Cavity in Sobotta Anatomy 16th Edition, Elsevier GmbH, Munich, Germany, 2018, p.142

25. Deshmukh S, Verde F, Johnson PT, Fishman EK, Macura KJ. Anatomical variants and pathologies of the vermix. Emerg Radiol. 2014;21(5):543-52. doi:10.1007/s10140-014-1206-4

26. Harold Ellis Part 2: The Abdomen and Pelvis in Clinical Anatomy 11th Edition, Blackwell Publishing, United Kingdom, 2006, p.80

27. Nirmaladevi M, Seshayyan S. Cadaveric study on the origin of the appendicular artery. Int J Anat Res 2016, Vol 4(1):1769-71. doi: dx.doi.org/10.16965/ijar.2015.329

28. Kahai P, Mandiga P, Wehrle CJ, et al. Anatomy, Abdomen and Pelvis: Large Intestine. [Updated 2023 Aug 7]. In: StatPearls [Internet]. Treasure Island (FL): StatPearls Publishing; 2023 Jan-. Available from: https://www.ncbi.nlm.nih.gov/books/NBK470577/

29. Bertalan Dudás M.D., Ph.D. Habil Digestive System II: Lower Alimentary Tract in Bertalan Dudás Human Histology, Elsevier Science Direct, 2023, p.155

30. Téoule P, Laffolie J, Rolle U, Reissfelder C. Acute Appendicitis in Childhood and Adulthood. Dtsch Arztebl Int. 2020;117(45):764-74. doi:10.3238/arztebl.2020.0764

31. Jones MW, Lopez RA, Deppen JG. Appendicitis. [Updated 2023 Apr 24]. In: StatPearls [Internet]. Treasure Island (FL): StatPearls Publishing; 2023 Jan-. Available from: https://www.ncbi.nlm.nih.gov/books/NBK493193/

32. Lamps LW. Infectious causes of appendicitis. Infect Dis Clin North Am. 2010;24(4):995-x. doi:10.1016/j.idc.2010.07.012

33. Parepalli VK. Appendix, Appendicitis and Appendicectomy [Internet] in Epomedicine; 2020 Feb 8. Available from: https://epomedicine.com/medical-students/appendix-appendicitis-and-appendicectomy/.

34. Humes DJ, Simpson J. Acute appendicitis. BMJ. 2006;333(7567):530-4. doi:10.1136/bmj.38940.664363.AE

35. Alshehri MY, Ibrahim A, Abuaisha N, et al. Value of rebound tenderness in acute appendicitis. East Afr Med J. 1995;72(8):504-6.

36. Prosenz J, Hirtler L. Rovsing sign revisited-effects of an erroneous translation on medical teaching and research. J Surg Educ. 2014;71(5):738-42. doi:10.1016/j.jsurg.2014.03.002

37. Health Jade Team Obturator sign and psoas sign [Internet]. Health Jade. 2020 [Date 25 October 2023]. Available from: https://healthjade.net/obturator-sign/

38. Rastogi V, Singh D, Tekiner H, Ye F, Mazza JJ, Yale SH. Abdominal Physical Signs and Medical Eponyms: Part II. Physical Examination of Palpation, 1907-1926. Clin Med Res. 2019;17(1-2):47-54. doi:10.3121/cmr.2018.1426

39. Markle GB 4th. A simple test for intraperitoneal inflammation. Am J Surg. 1973;125(6):721-2. doi:10.1016/0002-9610(73)90171-2

40. Sandy Craig Appendicitis: Practice Essentials, Background, Anatomy [Internet] in Medscape 09 November 2022; Available from: https://emedicine.medscape.com/article/773895-overview

41. Huckins DS, Copeland K. Diagnostic accuracy of combined WBC, ANC and CRP in adult emergency department patients suspected of acute appendicitis. Am J Emerg Med. 2021;44:401-6. doi:10.1016/j.ajem.2020.04.086

42. Andersson M, Andersson RE. The appendicitis inflammatory response score: a tool for the diagnosis of acute appendicitis that outperforms the Alvarado score [published correction appears in World J Surg. 2012 Sep;36(9):2269-70]. World J Surg. 2008;32(8):1843-9. doi:10.1007/s00268-008-9649-y

43. Alvarado A. A practical score for the early diagnosis of acute appendicitis. Ann Emerg Med. 1986;15(5):557-64. doi:10.1016/s0196-0644(86)80993-3

44. Tzanakis NE, Efstathiou SP, Danulidis K, et al. A new approach to accurate diagnosis of acute appendicitis. World J Surg. 2005;29(9):1151-7. doi:10.1007/s00268-005-7853-6

45. Ojuka D, Sangoro M. Ann Afr Surg. 2017;14(1): 22-28. doi: http://dx.doi.org/10.4314/aas.v14i1.5

46. Federle MP, Jeffrey RB, Woodward PJ, Borhani AA. Apandisit in Diagnosting Imaging – Abdomen, Lipincott Williams & Wlkins, 2013, pp. 26-30

47. Kouamé N, N'goan-Domoua AM, N'dri KJ, et al. The diagnostic value of indirect ultrasound signs during acute adult appendicitis. Diagn Interv Imaging. 2012;93(3):24-8. doi:10.1016/j.diii.2011.12.008

48. Martin RF. Acute appendicitis in adults: Clinical manifestations and differential diagnosis [Internet] UpToDate [Apr 20, 2022]. Available from: https://www.uptodate.com/contents/acute-appendicitis-in-adults-clinical-manifestations-and-differential-diagnosis

49. Bass GA, Mohseni S, Ryan ÉJ, et al. Clinical practice selectively follows acute appendicitis guidelines. Eur J Trauma Emerg Surg. 2023;49(1):45-56. doi:10.1007/s00068-022-02208-2

50. Richmond B. Chapter 50: The Appendix in Townsend CM, Beauchamp RD, Evers BM, Mattox KL. Sabiston Textbook of Surgery: The Biological Basis of Modern Surgical Practice, Elsevier, Canada, 2021, pp 1301-19

51. Hejazi RE, Aljedaani RM, Alshehri MA. Laparoscopic versus Open Appendectomy in Adults. The Egyptian Journal of Hospital Medicine. The Egyptian Journal of Hospital Medicine. 2018: n. pag. doi: 10.12816/EJHM.2018.15117

52. Zelhart M, Kaiser AM. Appendectomy (Open, Laparoscopic) in: Scott-Conner CEH, Kaiser AM, Nguyen NT, Sarpel U, Sugg SL, editors. Chassin's Operative Strategy in General Surgery: An Expositive Atlas [Internet], Springer International Publishing; 2022 pp. 337-47.

53. Rosales A, Montorfano L, Rosenthal RJ. Laparoscopic Appendectomy in: Rosenthal RJ, Rosales A, Lo Menzo E, Dip FD, editors. Mental Conditioning to Perform Common Operations in General Surgery Training: A Systematic Approach to Expediting Skill Acquisition and Maintaining Dexterity in Performance [Internet], Springer International Publishing; 2020, pp. 147-51.

54. Bhangu A, Søreide K, Di Saverio S, Assarsson JH, Drake FT. Acute appendicitis: modern understanding of pathogenesis, diagnosis, and management [published correction appears in Lancet. 2017 Oct 14;390(10104):1736]. Lancet. 2015;386(10000):1278-87. doi:10.1016/S0140-6736(15)00275-5

55. Smink D, Soybel DI. Appendectomy [Internet] UpToDate [Jun 30, 2022]. Available from: https://www.uptodate.com/contents/appendectomy

56. Jaschinski T, Mosch C, Eikermann M, Neugebauer EA. Laparoscopic versus open appendectomy in patients with suspected appendicitis: a systematic review of meta-analyses of randomised controlled trials. BMC Gastroenterol. 2015;15:48. Published 2015 Apr 15. doi:10.1186/s12876-015-0277-3

57. Hamet P, Tremblay J. Artificial intelligence in medicine. Metabolism. 2017;69S:S36-S40. doi:10.1016/j.metabol.2017.01.011

58. 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

59. Yoldaş Ö, Tez M, Karaca T. Artificial neural networks in the diagnosis of acute appendicitis. Am J Emerg Med. 2012;30(7):1245-1247. doi:10.1016/j.ajem.2011.06.019

60. Park, J.J., Kim, K.A., Nam, Y. et al. Convolutional-neural-network-based diagnosis of appendicitis via CT scans in patients with acute abdominal pain presenting in the emergency department. Sci Rep 10, 9556 (2020). doi: doi.org/10.1038/s41598-020-66674-7

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

62. 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

63. Güven, F. (2019). Using Text Representation and Deep Learning Methods ForTurkish Text Classification, Yüksek Lisans Tezi, Çukurova Üniversitesi Fen Bilimleri Enstitüsü, Adana, 23-24.

64. 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-convolutional-neural-networks

65. Training Requirements in Media Server Administration Guide in IDOL 12.0 - Documentation [Internet] Micro Focus [May 2018]. Available from: https://www.microfocus.com/documentation/idol/IDOL_12_0/

66. Howard AG, Zhu M, Chen B, Kalenichenko D, Wang W, Weyand T et al. MobileNets: Efficient Convolutional Neural Networks for Mobile Vision Applications. arXiv:1704.04861. doi: doi: doi.org/10.48550/arXiv.1704.04861

67. He K, Zhang X, Ren S, Sun J. Deep Residual Learning for Image Recognition. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, arXiv:1512.03385, 2016;770-8 doi: doi: doi.org/10.48550/arXiv.1512.03385

68. Szegedy C, Ioffe S, Vanhoucke V, Alemi A. Inception-v4, Inception-ResNet and the Impact of Residual Connections on Learning. Proceedings of the AAAI Conference on Artificial Intelligence, 2017; 31(1). doi: doi.org/10.1609/aaai.v31i1.11231

69. Tan M, Le QV. EfficientNet: Rethinking Model Scaling for Convolutional Neural Networks. Machine Learning on Computer Vision and Pattern Recognition, arXiv:1905.11946, 2020, doi: doi: doi.org/10.48550/arXiv.1905.11946

70. Bhandari A. Understanding & Interpreting Confusion Matrix in Machine Learning [Internet] Analytics Vidyha [Nov 2, 2023], Available from: https://www.analyticsvidhya.com/blog/2020/04/confusion-matrix-machine-learning/

71. Körner H, Söndenaa K, Söreide JA, et al. Incidence of acute nonperforated and perforated appendicitis: age-specific and sex-specific analysis. World J Surg. 1997;21(3):313-7. doi:10.1007/s002689900235

72. Golz RA, Flum DR, Sanchez SE, Liu X, Donovan C, Drake FT. Geographic Association Between Incidence of Acute Appendicitis and Socioeconomic Status. JAMA Surg. 2020;155(4):330-8. doi:10.1001/jamasurg.2019.6030

73. Akbulut S, Yagin FH, Cicek IB, Koc C, Colak C, Yilmaz S. Prediction of Perforated and Nonperforated Acute Appendicitis Using Machine Learning-Based Explainable Artificial Intelligence. Diagnostics (Basel). 2023;13(6):1173. Published 2023 Mar 19. doi:10.3390/diagnostics13061173

74. Akgül F, Er A, Ulusoy E, et al. Integration of Physical Examination, Old and New Biomarkers, and Ultrasonography by Using Neural Networks for Pediatric Appendicitis. Pediatr Emerg Care. 2021;37(12):1075-81. doi:10.1097/PEC.0000000000001904

75. Ghareeb WM, Emile SH, Elshobaky A. Artificial Intelligence Compared to Alvarado Scoring System Alone or Combined with Ultrasound Criteria in the Diagnosis of Acute Appendicitis. J Gastrointest Surg. 2022;26(3):655-8. doi:10.1007/s11605-021-05147-2

76. Hsieh CH, Lu RH, Lee NH, Chiu WT, Hsu MH, Li YC. Novel solutions for an old disease: diagnosis of acute appendicitis with random forest, support vector machines, and artificial neural networks. Surgery. 2011;149(1):87-93. doi:10.1016/j.surg.2010.03.023

77. Gudelis M, Lacasta Garcia JD, Trujillano Cabello JJ. Diagnosis of pain in the right iliac fossa. A new diagnostic score based on Decision-Tree and Artificial Neural Network Methods. Dolor agudo en fosa ilíaca derecha. Un nuevo algoritmo de diagnóstico basado en árboles de clasificación y red neuronal artificial. Cir Esp (Engl Ed). 2019;97(6):329-35. doi:10.1016/j.ciresp.2019.02.006

78. Park SY, Kim SM. Acute appendicitis diagnosis using artificial neural networks. Technol Health Care. 2015;23 Suppl 2:pp. 559-65. doi:10.3233/THC-150994

79. Prabhudesai SG, Gould S, Rekhraj S, Tekkis PP, Glazer G, Ziprin P. Artificial neural networks: useful aid in diagnosing acute appendicitis. World J Surg. 2008;32(2):305-11. doi:10.1007/s00268-007-9298-6

80. Kim KB, Park HJ, Song DH. Semi-dynamic Control of FCM Initialization for Automatic Extraction of Inflamed Appendix from Ultrasonography. Curr Med Imaging Rev. 2019;15(8):810-16. doi:10.2174/1573405614666180719142536

81. Lee GP, Park SH, Kim YJ, Chung JW, Kim KG. Enhancing Disease Classification in Abdominal CT Scans through RGB Superposition Methods and 2D Convolutional Neural Networks: A Study of Appendicitis and Diverticulitis. Comput Math Methods Med. 2023;2023:7714483. Published 2023 May 29. doi:10.1155/2023/7714483

82. Su D, Li Q, Zhang T, et al. Prediction of acute appendicitis among patients with undifferentiated abdominal pain at emergency department. BMC Med Res Methodol. 2022;22(1):18. Published 2022 Jan 14. doi:10.1186/s12874-021-01490-9

83. Lam A, Squires E, Tan S, et al. Artificial intelligence for predicting acute appendicitis: a systematic review. ANZ J Surg. 2023;93(9):2070-78. doi:10.1111/ans.18610

84. Park SH, Kim YJ, Kim KG, et al. Comparison between single and serial computed tomography images in classification of acute appendicitis, acute right-sided diverticulitis, and normal appendix using EfficientNet [published correction appears in PLoS One. 2023 Nov 17;18(11):e0294794]. PLoS One. 2023;18(5):e0281498. Published 2023 May 24. doi:10.1371/journal.pone.0281498

85. Rajpurkar, P., Park, A., Irvin, J. et al. AppendiXNet: Deep Learning for Diagnosis of Appendicitis from A Small Dataset of CT Exams Using Video Pretraining. Sci Rep 10, 3958 (2020). doi: doi.org/10.1038/s41598-020-6105