



İSTANBUL MEDENİYET ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ
BİYOLOJİK VERİ BİLİMİ ANABİLİM DALI

Çocuklarda Abdomen Radyografilerinden
Gastrointestinal Obstrüksiyon Tanısı İçin
Evrşimsel Sinir Ağı Kullanımı

Yüksek Lisans Tezi

Ercan Ayaz

Mayıs 2023



İSTANBUL MEDENİYET ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ
BİYOLOJİK VERİ BİLİMİ ANABİLİM DALI

Çocuklarda Abdomen Radyografilerinden
Gastrointestinal Obstrüksiyon Tanısı İçin
Evrışimsel Sinir Ağı Kullanımı

Yüksek Lisans Tezi

Ercan Ayaz

Danışman

Prof. Dr. Hasan Güçlü

Eş Danışman

Doç. Dr. Ayşe Betül Oktay

Mayıs 2023

TEZ JÜRİSİ ONAYI

Ercan Ayaz tarafından hazırlanan "Çocuklarda Abdomen Radyografilerinden Gastrointestinal Obstrüksiyon Tanısı İçin Evrişimsel Sinir Ağı Kullanımı" başlıklı bu Yüksek Lisans Tezi, Biyolojik Veri Bilimi Anabilim Dalı'nda hazırlanmış ve jürimiz tarafından kabul edilmiştir.

JÜRİ ÜYELERİ

İMZA

Tez Danışmanı:

Prof. Dr. Hasan Güçlü
İstanbul Medeniyet Üniversitesi

Üyeler:

Doç. Dr. Başak Atalay
İstanbul Medeniyet Üniversitesi

Prof. Dr. İbrahim Adaletli
İstanbul Üniversitesi - Cerrahpaşa

Tez Savunma Tarihi: 23/ 05 / 2023

BEYANLAR

Yazım ve Kaynak Gösterme Kılavuzu Beyanı

Danışmanlığımda yazılan bu tezin APA yazım ve kaynak gösterme kılavuzunda belirtilen kurallara uygun olarak yapılandırıldığı ve bu kılavuzun metin içi kaynak gösterme standartlarının bu tezde tutarlı olarak uygulandığı tarafımdan incelenerek teyit edilmiştir.



İmza

Prof. Dr. Hasan Güçlü

Etik İkelere Sadakat Beyanı

Hazırladığım bu tezin tamamen kendi çalışmam olduğunu, akademik ve etik kuralları gözeterek çalıştığımı ve her alıntıya kaynak gösterdiğimi beyan ederim. Çalışmadaki verilerin toplanması ile ilgili etik kurul onayı alınmış olup Ek 1'de sunulmuştur.

İmza

Ercan Ayaz

ÖZET

Çocuklarda Abdomen Radyografilerinden Gastrointestinal Obstrüksiyon Tanısı İçin Evrışimsel Sinir Ağı Kullanımı

Ayaz, Ercan

Yüksek Lisans Tezi, Biyolojik Veri Bilimi Anabilim Dalı

Danışmanlar: Prof. Dr. Hasan Güçlü, Doç. Dr. Ayşe Betül Oktay

Mayıs 2023

Radyografilerde izlenen bağırsak dilatasyonları, kusma, karın ağrısı, kronik kabızlık veya ishal gibi şikâyetlerle başvuran hastalarda sık görülen bir bulgudur. En sık nedenleri bağırsak enfeksiyonları, inflamatuvar hastalıklar ve obstrüksiyonlardır. Bu hastalarda cerrahi gerektiren obstrüksiyon olup olmadığının ayırımının zamanında ve doğru yapılması, ölüme kadar gidebilecek olan nekroz, perforasyon gibi komplikasyonların önlenmesi için çok önemlidir. Bu tezde, ilk olarak abdomen radyografilerinde normal bağırsak gaz dağılımı olan sağlıklı çocuklarla, bağırsak dilatasyonu veya obstrüksiyon bulgusu olan anormal hastaların evrışimsel sinir ağı (ESA) modelleriyle ikili sınıflama kullanılarak ayırımının yapılması amaçlandı. Daha sonra da hasta grubunda cerrahi gerektiren obstrüksiyon hastaları ile diğer bağırsak dilatasyonu veya ileusu bulunan inflamatuvar/enfeksiyöz nedenli hastaların sınıflandırılması hedeflendi. Bu amaçla çocukluk çağındaki hastalarda çekilen 1152 abdomen radyografisi (540 normal, 298 cerrahi tanıli dilatasyon, 314 inflamatuvar/enfeksiyöz dilatasyon) veri kümesi olarak kullanıldı. Bu veri kümesine gerekli ön işlemler yapıldıktan sonra görüntü analizinde başarısı kanıtlanmış olan 5 ESA modeliyle (ResNet50, InceptionResNetV2, Xception, EfficientNetV2L, ConvNeXtXLarge) transfer öğrenme metodu kullanılarak eğitim, validasyon işlemlerinden sonra test edildi. Sonuç olarak normal ile anormal ayırımında en yüksek doğruluk oranı ResNet50 (0,938) ile elde edildi. Daha sonra otomatik kırpılma ön işleme metoduyla verilerin tanısız değeri olmayan kısımları çıkarıldıktan sonra yapılan analizde en yüksek doğruluk oranları EfficientNetV2L (0,962), ConvNeXtXLarge (0,956) ve InceptionResNetV2(0,950) ile elde edildi. Cerrahi obstrüksiyonlar ile diğer hastaların ayırımında ise en yüksek doğruluk oranı EfficientNetV2L(0,972) ile elde edildi. Sonuç olarak, ESA modelleri, gastrointestinal obstrüksiyon olgularında dijital radyografiye entegre edilerek karar destek sistemi olarak yüksek doğruluk ile kullanılabilir. Anormal radyografiler konusunda hekimi uyararak tanı ve tedavi sürecinin hızlanmasına katkıda bulunabilir.

Anahtar Kelimeler: GIS obstrüksiyonu, Abdomen radyografisi, Pediatrik Radyoloji, Gastroenterit, Evrışimsel Sinir Ağları

ABSTRACT

Convolutional Neural Network Usage on Abdominal Radiographs for the Diagnosis of Gastrointestinal Obstruction in Children

Ayaz, Ercan

Master's Thesis, Department of Biological Data Science

Supervisors: Prof. Dr. Hasan Güçlü, Doç. Dr. Ayşe Betül Oktay

May 2023

Intestinal dilatations in radiographs are a common finding in patients presenting with symptoms such as vomiting, pain, constipation, or diarrhea. The most common causes are intestinal infections, inflammatory diseases, and obstructions. Timely and accurate differentiation of whether there is an obstruction requiring surgery in these patients is crucial to prevent complications such as necrosis and perforation, which can lead to death. In this thesis, the first aim was to differentiate healthy children with normal intestinal gas distribution in abdominal radiographs from intestinal dilatation or obstruction using convolutional neural network (CNN) models. Then, the classification of patients with surgical obstruction and those with other intestinal dilatation or ileus was aimed. For this purpose, a dataset of 1152 abdominal radiographs taken in childhood (540 normal, 298 surgically diagnosed dilatation, 314 inflammatory/infectious dilatation) was used. After preprocessing of this dataset, five CNN models with proven success in image analysis (ResNet50, InceptionResNetV2, Xception, EfficientNetV2L, ConvNeXtXLarge) were trained, validated, and tested using transfer learning method. Consequently, the highest accuracy in the differentiation between normal and abnormal was achieved with ResNet50 (0.938). Then, after removing the non-diagnostic parts of the data using an automated cropping preprocessing, the highest accuracy rates were achieved with EfficientNetV2L (0.962), ConvNeXtXLarge (0.956), and InceptionResNetV2 (0.950). The highest accuracy in the differentiation between surgical obstructions and others was achieved with EfficientNetV2L (0.972). In conclusion, CNN models can be integrated into radiographs as a decision support system with high accuracy rates in pediatric gastrointestinal obstructions by alerting the physician about abnormal radiographs.

Keywords: GIS obstruction, Abdominal radiograph, Ileus, Pediatric Radiology, Convolutional Neural Networks

TEŞEKKÜR

Tez danışmanlarım ve değerli hocalarım sayın Prof. Dr. Hasan Güçlü ve Doç. Dr. Ayşe Betül Oktay'a tezin hazırlanması boyunca katkıları ve destekleri için çok teşekkür ederim. Biyolojik Veri Bilimi yüksek lisansındaki derslerinden faydalandığım sayın Prof. Dr. Handan Ankaralı, Prof. Dr. Işıl Maral, Prof. Dr. Mahmut Gümüş, Dr. Rüya Şen, Dr. Mahmut Alpertunga Kara, Dr. Arafat Salih Aydın'ere teşekkür ederim. Yüksek lisans eğitimim boyunca mesai konusunda esneklik sağlayan, Diyarbakır Çocuk Hastanesi Ultrason bölümü radyolog ve personellerine şükranlarımı sunarım. Son olarak her anlamda bana destek olan ailemesevgilerimi sunarım.

Dr. Ercan AYZ

İÇİNDEKİLER

İÇ KAPAK.....	i
ONAY.....	ii
BEYANLAR.....	iii
ÖZET.....	iv
ABSTRACT.....	v
TEŞEKKÜR.....	vi
İÇİNDEKİLER.....	vii
TABLO LİSTESİ.....	x
GRAFİK LİSTESİ.....	xi
ŞEKİL LİSTESİ.....	xii
KISALTMALAR.....	xiv
BÖLÜM I – GİRİŞ.....	1
BÖLÜM II – LİTERATÜR ÖZETİ.....	6
2.1 ÇOCUKLARDA GİS OBSTRÜKSİYONUNA NEDEN OLAN HASTALIKLAR.....	6
2.1.1 Hipertrofik Pilor Stenozu.....	6
2.1.2 Duodenal Atrezi / Stenoz.....	7
2.1.3 İntestinal Malrotasyon / Midgut Volvulus.....	8
2.1.4 İnvajinasyon.....	9
2.1.5 Akut / Komplike Appandisit.....	10
2.1.6 Mekonyum İleusu / Mekonyum Tıkaç Sendromu.....	11
2.1.7 Hirschsprung Hastalığı.....	12
2.1.8 İnguinal Herni.....	13
2.1.9 Diğer Hastalıklar.....	14
2.2. GEÇMİŞTE YAPILAN BENZER ÇALIŞMALAR.....	15
2.2.1 GİS Hastalıklarının Radyografiden Tanısında Derin Öğrenme Uygulamaları.....	16
2.2.2 Abdomen Görüntülemesi ile İlgili Yapılan Çalışmalar.....	18

2.2.3 Akciğer Radyografileri ile İlgili Çalışmalar	20
2.2.4 COVID-19 Pandemisi Sürecinde Yapılan Çalışmalar	23
BÖLÜM III – KURAMSAL TEMELLER.....	28
3.1 YAPAY ZEKA	28
3.2 MAKİNE ÖĞRENMESİ VE YAPAY SİNİR AĞLARI.....	28
3.3 DERİN ÖĞRENME	29
3.4 EVRİŞİMSEL SİNİR AĞLARI	31
3.4.1 Giriş Katmanı.....	32
3.4.2 Evrişim (Konvolüsyon) Katmanı	33
3.4.2.1 Aktivasyon fonksiyonları.....	34
3.4.3 Havuzlama Katmanı.....	36
3.4.4 Tam Bağlantılı Katman	37
3.5 ESA MODELİNİN OLUŞTURULMASI VE EĞİTİLMESİ	37
3.5.1 Regülasyon (Düzenleme) Yöntemleri	38
3.5.1.1 Veri artırma (data augmentation)	38
3.5.1.2 L1/L2 düzenleme (L1/L2 normalization).....	38
3.5.1.3 Bırakma (dropout regularization)	38
3.5.1.4 Erken durdurma (early stopping)	39
3.5.2 Optimizasyon Yöntemleri.....	39
3.5.2.1 Stokastik gradyan azalma	39
3.5.2.2 Momentumlu gradyan azalma (gradient descentwith momentum).....	40
3.5.2.3 RMS-Prop (root mean square propagation) AdaGrad (adaptive gradient)	40
3.5.2.4 Adam (adaptive moment estimation)	41
3.5.3 Transfer Öğrenme	41
3.6 PERFORMANS ÖLÇÜTLERİ	41
3.7 ESA MODELLEMESİNDE KULLANILAN YAZILIMLAR.....	42

3.7.1 Python	43
3.7.2 Tensorflow	43
3.7.3 Keras	44
BÖLÜM IV – KULLANILAN VERİ KÜMELERİ VE YÖNTEMLER	45
4.1 VERİ KÜMESİ	45
4.2 ÇALIŞMADA KULLANILAN ESA MODELLERİ	50
4.2.1 ResNet50	50
4.2.2 Inception	51
4.2.3 Xception	54
4.2.4 EfficientNet	54
4.2.5 ConvNeXt	55
4.2.6 Deneyde Modellere Yapılan Eklemeler ve İnce Ayar (Fine Tuning)	57
BÖLÜM V – BULGULAR	59
5.1 VERİ KÜMESİNİN ÖN İŞLEMESİ	59
5.1.1 Veri Artırma	59
5.1.2 Kırpma	59
5.2 ESA MODELLERİ İLE SINIFLANDIRMA SONUÇLARI	61
BÖLÜM VI – TARTIŞMA VE SONUÇ	68
6.1 ÇALIŞMANIN KISITLILIKLARI VE GELECEK ÇALIŞMA ÖNERİLERİ	70
KAYNAKÇA	72
EKLER	82
EK-1 ETİK KURUL ONAYI	82
EK-2 ÇALIŞMADA KULLANILAN KODLAR	84
ÖZGEÇMİŞ	88

TABLO LİSTESİ

Tablo 2.1 Literatürde GİS hastalıklarının tanısı için yapılan ESA çalışmalarındaki performans ölçüt sonuçları	18
Tablo 2.2 Literatürde COVID-19 pnömonisinin tanısı için akciğer radyografilerinde yapılan ESA çalışmalarındaki performans ölçüt sonuçları	27
Tablo 3.1 Karmaşıklık matrisi	42
Tablo 4.1 Veri kümesindeki vakaların gruplara göre yaş ve cinsiyet özellikleri	46
Tablo 4.2 Cerrahi gerektiren bağırsak obstrüksiyonu olan vakaların tanılara göre sayı, yaş ve cinsiyet özellikleri.....	48
Tablo 4.3 Inception v3 model mimarisi.....	53
Tablo 4.4 EfficientNet-B0 model mimarisi (Tan; 2019)	56
Tablo 5.1 ResNet50 modeliyle yapılan sınıflandırmaların karmaşıklık matrisleri...	62
Tablo 5.2 InceptionResNetV2 modeliyle yapılan sınıflandırmaların karmaşıklık matrisleri	62
Tablo 5.3 Xception modeliyle yapılan sınıflandırmaların karmaşıklık matrisleri.....	63
Tablo 5.4 EfficientNetV2L modeliyle yapılan sınıflandırmaların karmaşıklık matrisleri	63
Tablo 5.5 ConvNeXtXLarge modeliyle yapılan sınıflandırmaların karmaşıklık matrisleri	63
Tablo 5.6 Deneyde kullanılan ESA modeli ve veri kümesine göre performans ölçütleri	64

GRAFİK LİSTESİ

Grafik 3.1 Sigmoid fonksiyon ve türevi	35
Grafik 3.2 Tanh fonksiyonu ve türevi.....	35
Grafik 3.3 ReLU	35
Grafik 3.4 Leaky ReLU	35
Grafik 3.5 ELU	35
Grafik 3.6 Softmax fonksiyonu.....	36



ŞEKİL LİSTESİ

Şekil 2.1 Hipertrofik pilor stenozu.....	7
Şekil 2.2 Down Sendromlu hastada duodenal stenoz	8
Şekil 2.3 İntestinal malrotasyon.....	9
Şekil 2.4 İnvajinasyon.....	10
Şekil 2.5 Komplike akut apandisit	11
Şekil 2.6 Mekonyum ileusu... ..	12
Şekil 2.7 Hirschsprung hastalığı	13
Şekil 2.8 İnkarsere inguinal herni	14
Şekil 2.9 Nekrotizan enterokolit	15
Şekil 3.1 Örnek tek katmanlı perseptron (yapay nöron) modeli	29
Şekil 3.2 Yapay Zeka-Makine Öğrenmesi-Derin Öğrenme Arasındaki Hiyerarşi	30
Şekil 3.3 Evrişimsel sinir ağı (ESA) Mimari Modeli.....	32
Şekil 3.4 Üç kanallı 5x5'ten büyük bir girdinin sol üst kenarından başlanarak 3x3 boyutlu filtreye uygulanan evrişim işleminin ilk adımı	34
Şekil 3.5 2x2 filtre ve (2,2) adım kayması yapılan maksimum havuzlama işlemi	36
Şekil 3.6 4 sınıflı bir sonuç veren ESA modelinin tam bağlantılı katmanı	37
Şekil 3.7 Erken durdurma işleminin grafik olarak gösterimi.....	39
Şekil 4.1 Veri kümesindeki patolojik grupların yaş dağılımı	46
Şekil 4.2 Cerrahi gerektiren bağırsak dilatasyonu olan gruptaki etyolojilere göre hastaların yaşlarının dağılımı	49
Şekil 4.3 Cerrahi olmayan bağırsak dilatasyonu olan grupta etken bulunamayan hastalar ile rotavirüs olgularının yaşlarının karşılaştırılması.....	50
Şekil 4.4 ResNet50 model mimarisi.....	51

Şekil 4.5 ESA mimarisi içinde oluşturulan temel Inception katmanı	52
Şekil 4.6 Inception v3 modelindeki Inception katmanlarının mimarisi	54
Şekil 4.7 Xception model mimarisi.....	55
Şekil 4.8 ConvNeXt model mimarisi	57
Şekil 4.9 Tezimizdeki veri kümesinin ResNet50 modelinde eğitim ve ince ayar epoklarının eğitim ve validasyon hata grafiği	58
Şekil 5.1 Çalışmada kullanılan veri artımı yöntemlerinden yatay yansıma ve döndürme örnekleri	60
Şekil 5.2 Veri kümemiz içerisindeki ham görüntü örneği ile bu görüntüye otomatik kırılma işlemi yapıldıktan sonraki hali.....	61
Şekil 5.3 Veri kümemiz içerisindeki görüntü örneğinde sol alt taraftaki etiket yazıları nedeniyle alttan ve soldan kırılma işlemi istenildiği gibi olmayan kırılmış görüntü örneği.....	61
Şekil 5.4 Duodenal atrezi, midgut volvulus, mekonyum ileus, perforo apandisit tanılı cerrahi endikasyonlu GIS dilatasyonu olan hastaların görüntülerinin Grad-CAM ağırlık haritası.....	65
Şekil 5.5 Normalde sağlıklı olduğu halde ConvNeXtXL ile test edildiğinde anormal olarak sınıflandırılan (yanlış pozitif) olgulara örnekler.....	66
Şekil 5.6 Normalde cerrahi obstrüksiyonu olduğu halde ConvNeXtXL ile test edildiğinde normal olarak sınıflandırılan (yanlış negatif) olguların cerrahi tanısı, yaşı ve cinsiyeti ile radyografileri.....	67

KISALTMALAR

AE: Oto Kodlayıcı (İng. Auto Encoder)

BT: Bilgisayarlı tomografi

CPU: Central processing unit (merkezi işlem birimi)

DA: Duodenal atrezi

DBN: Deep Belief Network

EAA: Eğri altındaki alan

ELU: Üstel Lineer Birim (İng. Exponential Linear Unit)

ESA (İng. CNN): Evrişimli Sinir Ağları (İng. Convolutional Neural Network)

GELU: Gaussian hata doğrusal birim

GIS: Gastrointestinal sistem

GPU: Graphic processing unit (grafik işlem birimlerinin)

HPS: Hipertrofik pilor stenozu

LSTM: Long Short-Term Memory

MRG: Manyetik rezonans görüntüleme

RBM: Restricted Boltzmann Machine

ReLU: Düzeltilmiş Doğrusal Birim (İng. Rectified Linear Unit)

RNN: Recurrent Neural Networks

PACS: Picture Archiving and Communication Systems

TPU: Tensor processing unit (tensör işlem birimi)

BÖLÜM I – GİRİŞ

Gastrointestinal sistem (GİS) ağızdan başlayarak anüse kadar uzanan, birbiri ile ilişkili ve devamlılık gösteren organlardan oluşan, birçok fonksiyonu olan bir sistemdir. Anatomik olarak GİS tübüler yapısı ağızdan başlar ve sırasıyla özofagus (yemek borusu), mide, ince bağırsaklar (duodenum, jejunum ve ileum), kalın bağırsak (çekum, kolon ve rektum) olarak devam eder ve anüste sonlanır. GİS'in temel fonksiyonları; sindirim, emilim, alınan besinlerin zararlı etkilerinden korumak ve atılımı olarak sayılabilir. En temel fonksiyonlar olan sindirim ve emilimin gerçekleştiği başlıca organlar mide ve ince bağırsaklardır (Cheng ve diğerleri, 2010). Bu fonksiyonlar yerine getirilirken peristalsis olarak adlandırılan ve otonom sinir sistemi tarafından yürütülen ritmik kasılma hareketleri ile alınan besinler ilerler ve sindirilir. Ayrıca pankreas enzimleri, safra, mide ve ince bağırsağın kendi lümeninden salgılanan çeşitli enzimler de sindirim ve emilimi sağlar. Mide ve ince bağırsakta tamamlanan sindirim ve emilimin ardından kalan kısım ise kalın bağırsağageçtikten sonra burada sıvı kısmı emilerek daha katı ve kompakt görünüme sahip olan dışkıya dönüşür (Cheng ve diğerleri, 2010).

GİS'i etkileyen birçok farklı grupta hastalık vardır. Bunlar diğer sistemlerde olduğu gibi kalıtsal (konjenital), gelişimsel, inflamatuvar (iltihabi), enfeksiyöz ve neoplastik (kanser) hastalıklar olarak sınıflandırılabilir. Çocuklarda hastalıkların tipleri ve sıklığı erişkinlere göre farklıdır. Örneğin neoplastik hastalıklar erişkinlere göre çok daha nadir görülürken, kalıtsal ve gelişimsel hastalıklar daha sık görülür. Benzer şekilde 0-18 yaş arasında, yaş gruplarına göre hastalık tiplerinin görülme sıklığı farklı olup bazı yaş gruplarına özgü hastalıklar mevcuttur. Örneğin, hipertrofik pilor stenozu en sık doğumdan sonra 2-8 hafta arası bebeklerde görülürken, 3 aydan sonra görülmez (Kandasamy ve diğerleri, 2019).

GİS ile ilgili hastalık geçiren çocukların şikayetleri çok değişken ve non-spesifik olup etkilenen bölgenin ve sebebin hastanın şikayetleri ve klinik muayene ile belirlenebilmesi erişkin hastalara göre oldukça zordur. Bu nedenle hastalığın tanısına ulaşmak için radyolojik görüntüleme çok önemlidir. Akut (ani gelişen, kısa süreli) şikayetleri olan hastalarda radyologların ve klinisyenlerin ilk hedefi obstrüksiyon

(tıkanıklık) olup olmadığını belirlemektir çünkü akut obstrüksiyon acil tedavi edilmelidir ve genellikle de cerrahi müdahale gerektirir (Hryhorczuk ve Lee, 2012). Akut obstrüksiyon olup olmadığı belirlendikten sonra ise hastalığın lokalizasyonu, nedeni ve etkilenen organların saptanması amacıyla görüntüleme bulguları değerlendirilmelidir.

Gastrointestinal şikâyetleri olan hastalarda ilk tercih edilen ve en sık kullanılan görüntüleme yöntemleri abdomen radyografisi ve ultrasondur (Bucher ve diğerleri, 2011). Ultrason, iyonize radyasyon içermemesi, kolay ulaşılabilir, tekrar uygulanabilir olması ve gerçek zamanlı olarak değerlendirme imkânı sunması nedeniyle karın ağrısı olan çocuklarda en sık tercih edilen görüntüleme yöntemidir. Ultrason, akut apandisit, hipertrofik pilor stenozu, invajinasyon gibi hastalıklarda çocuklarda tanı için tek başına yeterli olabilir (Bucher ve diğerleri, 2011). Ancak ultrason ile iletilen ses dalgası bağırsak gazları tarafından tam yansıtıldığı için bağırsak gazlarının arkasından görüntü bilgisi elde edilemez. Bu nedenle lümen içerisinde yoğun gaz içeren mide ve bağırsağı değerlendirmede yetersiz kalır. Ayrıca, ultrason işlemini gerçekleştiren operatörün deneyimine ve becerisine bağımlı olması da bu görüntüleme yönteminin diğer önemli kısıtlılığıdır (Kandasamy ve diğerleri, 2019).

Abdomen radyografisi, ucuz ve yaygın olması, özellikle dijital radyografiyle birlikte hızlı uygulanıp yorumlanabilmesi, bağırsak gaz dağılımını bütüncül olarak göstermesi gibi nedenlerle GİS hastalıklarında genellikle ilk tercih edilen yöntemdir. Radyografi, özellikle gastrointestinal obstrüksiyon olgularının tanısında ultrasondan üstündür (Rothrock ve diğerleri, 1992). Yenidoğan ve bebeklik dönemlerinde görülen nekrotizan enterokolit, duodenal atrezi gibi hastalıklarda tipik görüntüleme bulguları vardır. Ayrıca akut şiddetli klinik bulguları olan ve bağırsak perforasyonu (yırılması) düşünülen hastalarda batın içi serbest havayı gösterebilir. Ancak, genel olarak bakıldığında karın ağrısı olan çocuklarda abdomen radyografilerinin duyarlılığı oldukça düşük olup patolojik bulgu görülme oranı %2 ile %20 arasında bildirilmiştir (Mirvis ve diğerleri, 1986, Rothrock ve diğerleri, 1992). Yenidoğan ve küçük çocuklarda abdomen radyografisi genellikle hasta yatarken çekilir. Büyük çocuklarda ise ayakta direk abdomen (batın) radyografisi, özellikle peristalsisin bozulduğu hastalıklarda görülen hava-sıvı seviyelerini ve bağırsak anslarındaki

distansiyonu daha iyi gösterebilir. Hava-sıvı seviyelerini, batın içi serbest sıvıyı veya havayı göstermek için bazı hastalarda hasta yan döndürülerek lateral dekübit radyografiler çekilmektedir. Abdomen radyografilerinde bağırsak obstrüksiyonunu düşündüren bulgular;

- Farklı bağırsak segmentlerinde üç veya daha fazla hava-sıvı seviyelenmesi
- İnce bağırsak için $> 2,5$ cm, kalın bağırsak için $> 4,5$ cm çapa ulaşan dilate bağırsak segmentinde görülen hava sıvı seviyelenmesi
- Lokalize bir alanda birbirinden en az 5 mm uzaklıkta izlenen iki veya daha fazla hava-sıvı seviyelenmesi

Ultrason veya abdomen radyografisi ile tanısı netleştirilemeyen hastalarda kullanılan görüntüleme yöntemleri kontrastlı floroskopik incelemeler, bilgisayarlı tomografi (BT), manyetik rezonans görüntüleme (MRG) ve nükleer sintigrafidir. Kontrast madde ağızdan veya rektal yolla verildikten sonra uygulanan floroskopik tetkikler özellikle çocuklarda çok değerli olup trakeoözofageal fistül, Hirschsprung hastalığı, mekonyum ileusu, malrotasyon/volvulus gibi daha sık bebeklerde görülen hastalıklarda tanı koydurucudur (Smith ve diğerleri, 2021). BT, yüksek iyonize radyasyon yükü nedeniyle çocuklarda erişkinlere oranla daha az tercih edilmelidir. Ayrıca çekim sırasında intravenöz kontrast madde ve bazı durumlarda oral kontrast madde gerekliliği damar yolu olmayan küçük çocuklarda diğer dezavantajdır. Ancak neoplastik hastalıklarda, ultrason veya radyografinin yetersiz kaldığı hastalarda, komplike hastalarda, ameliyat öncesi hastalığın lokalizasyonu ve yayılımını net olarak gösterebilmek için kullanılmaktadır. MRG ile yapılan MR enterografi, bağırsak hastalıklarında iyonize radyasyon yükünden kurtulmak için kullanılmaktadır. Özellikle Crohn hastalığı, ülseratif kolit gibi kronik inflamatuvar bağırsak hastalıkları ve tekrarlayan çekim gerektiren olgularda MR enterografi sıklıkla kullanılmaktadır (Mollard ve diğerleri, 2014). Nükleer sintigrafi, Meckel divertikülü gibi bazı spesifik hastalıklarda tanı koydurucu olsa da yüksek iyonize radyasyon dozu nedeniyle nadiren tercih edilmektedir (Farrell ve Zimmermann, 2020).

Tıp alanında tanı destek modelleri olarak yapay zekânın özellikle radyoloji ve patoloji gibi görüntü temelli bilim dallarına entegrasyonu ile ilgili her yıl giderek artan sayıda çalışmalar sunulmaktadır. Yapay zekânın alt dallarından olan yapay sinir

ağları, son dönemde görüntü sınıflandırmada en çok tercih edilen, doğruluk oranı en yüksek modeller oldu (Atlan ve Pençe, 2021).

Yapay sinir ağı modellerinden olan evrimsel sinir ağı (ESA), görüntülerden belirli nitelikler çıkarıp bunları benzeştirerek, görüntüleri ayırt edebilme ve sınıflandırma yeteneğine sahiptir. ESA'nın en büyük kısıtlılığı eğitim için büyük veri kümelerine ihtiyaç duymasıdır. Ancak daha önce büyük veri kümesinde eğitilmiş bir ESA'nın kapasitesi benzer bir görüntü ayırt etmek için transfer edilebilir (Yosinski ve diğerleri, 2014). Dijital radyografi ve PACS (Picture Archiving and Communication Systems) sistemlerinin yayılması ile radyografi verilerini elde etmek konusunda son yıllarda büyük aşama kaydedildi. Radyografi tek kesit ve iki boyutlu görüntüleme iken BT ve MRG çok kesitli ve üç boyutlu görüntülemelerdir. Bu nedenle radyografiler daha basit mimarideki derin öğrenme modelleriyle işlenebilmektedir.

Günlük pratikte çocuklara acilde ve poliklinikte çok sayıda abdomen radyografisi çekilmekte, ülkemizde bunların büyük çoğunluğu radyologlar tarafından değerlendirilmemekte, acil hekimi veya poliklinik hekimi tarafından kısıtlı zamanda değerlendirilebilmektedir. 2018 yılında Türk Radyoloji Derneği'nin hazırladığı rapora göre Türkiye'de 100.000 kişiye düşen radyolog sayısı 5 iken, bu sayı OECD ülkelerinde iki üç katı düzeyindedir (WEB 1). Çekilen radyografilere yeterli zaman ayrılamaması veya değerlendiren kişinin deneyimsizliği nedeniyle yanlış negatif değerlendirilen hastalar için gereksiz ek tetkik istenmekte veya hastalığı olduğu halde normal olarak değerlendirilip evine gönderilebilmektedir. Öte yandan yanlış pozitif değerlendirilen hastalar için gereksiz tedaviler veya cerrahi girişimler yapılabilir. Çocuklar çoğu zaman şikâyetlerini doğru anlatamadığı ve laboratuvar tetkiklerinde hızlı değişimler olduğu için radyolojik tetkiklerin önemi daha fazladır. Bu nedenle özellikle acildeki radyografi çekiminden sonra PACS sistemi ile entegre bir ESA modelinin değerlendirdiği radyografiler, sınıflandırılarak ilgili hekimin önüne gelirse hekimin daha dikkatli değerlendirmesini sağlayabilir.

Bu tezde, güncel ESA modellerini abdomen radyografisi üzerinde yeniden eğitmek ve bu modellerden hangisinin normal ve patolojik radyografileri sınıflandırmak için daha başarılı olduğunu değerlendirmek hedeflendi. Patolojik radyografiler içinde de medikal tedavi ile düzelen (enfeksiyöz) ve cerrahi tedavi gerektiren hastaların ayırt

edilmesi amaçlandı. Bu tez için 0-18 yaş arası çocuklardan elde edilmiş 3 farklı kategoride toplam 1152 radyografi görüntüsü (540 normal, 314 medikal tedavi gerektiren distansiyon, 298 cerrahi gerektiren GİS obstrüksiyonları) içeren bir veri kümesi oluşturularak, hazırlanan ESA modellerinde kullanıldı.

Bölüm 2’de literatür taraması kapsamında, radyolojik görüntülerde yapay sinir ağları kullanılarak sınıflandırma yapılan önceki çalışmalara yer verilmektedir. Bölüm 3’te ESA’ya uzanan süreçte neler olduğuna kısaca değinilerek, yapay zeka, derin öğrenme ve evrişimli sinir ağlarının adımları anlatılmaktadır. Bölüm 4’te çalışma kapsamında kullanılan veri kümelerinden ve değerlendirme amaçlı kullanılan metriklerden bahsedilmektedir. Bölüm 5’te kullanılan yöntemler, yapılan denemeler ve onların sonuçları yer almaktadır. Bölüm 6’da tezdeki çalışmaların sonuçlarının değerlendirmesi ve önceki çalışmalar ile karşılaştırılması, kısıtlılıklar ve gelecek çalışma önerileri tartışılmaktadır.

BÖLÜM II – LİTERATÜR ÖZETİ


Bu bölümde öncelikle çocuklarda GİS obstrüksiyonu oluşturan, abdomen radyografisinin kullanıldığı ve tipik görüntüleme bulguları olan hastalıklar tanımlandı. Daha sonra literatürde yapay sinir ağları kullanılarak radyografilerin sınıflandırılması üzerine yapılan çalışmalar detaylı olarak sunuldu.

2.1. ÇOCUKLARDA GİS OBSTRÜKSİYONUNA NEDEN OLAN HASTALIKLAR

Bu bölümde bizim veri kümemizde bulunan ve GİS obstrüksiyonuna neden olan hastalıklar ve bu hastalıkların abdomen radyografilerindeki tipik görüntüleme bulguları anlatılmaktadır. Hastalıklar, etkilenen bölgeye göre mideden anüse doğru sıralanarak sunulmaktadır.

2.1.1 Hipertrofik Pilor Stenozu

Pilor, midenin duodenum (on iki parmak bağırsağı) ile bağlantısını sağlayan en distal bölümüdür. Pilonu saran kas grubu mide boşalmasından sonra kasılarak bağırsak içeriği, safra ve diğer enzimlerin mideye reflüsünü önler. Hipertrofik pilor stenozu (HPS) hastalığı büyük oranda 2-8 hafta yaşındaki bebeklerde görülür. Bu hastalıkta pilor kalınlaşıp uzar ve gevşeyemez. Bu nedenle mide dolduktan sonra etkilenen bebekler safrasız ve fişkırır tarzda kusar. Hastalığın nedeni tam olarak bilinmese de ilk doğan erkek çocuklarda ve sigara içilen ortamda bulunan bebeklerde daha sık görüldüğü bildirilmektedir (Kandasamy ve diğerleri, 2019; Rao, 2016). HPS tanısında en değerli radyolojik görüntüleme yöntemi ultrason olup ultrasonda pilor uzunluğu ve kalınlığı ölçülerek tanı konur (Ayaz, 2021). Abdomen radyografisinde ise epigastrik bölgede distandü ve gaz dolu mide ve devamlılığında normale göre daha az gaz görülmesi veya hiç görülmemesi tanıyı destekleyici bir bulgudur ancak ultrason kadar özgül değildir.




Şekil 2.1. Beslenme sonrası fişkırır tarzda kusma şikayeti ile gelen 50 günlük erkek bebeğin abdomen radyografisinde (A) mide antropilorik düzeyinin genişlediği ve sağ alt kadrana doğru uzandığı (kesikli çizgiler) görülmektedir. Hastaya nazogastrik kateter aracılığıyla verilen kontrast madde sonrası çekilen radyografide (B) mide çıkışından kontrast geçişinin yavaşladığı ve pilor düzeyindeki darlık dikkati çekmektedir (siyah çember). Hastaya yapılan ultrasonda (C ve D) pilor duvarının belirgin kalınlaştığı (7 mm) ve uzunluğunun arttığı (30 mm) (beyaz çember) izlenmektedir. Karşılaştırma amacıyla 35 günlük bebekte, 2 mm duvar kalınlığı ve 12 mm uzunluğa sahip normal pilorun görünümü (E ve F) (kesikli çember) sunulmaktadır.

2.1.2 Duodenal Atrezi / Stenoz

Duodenum, ince bağırsak bölümleri içinde konjenital ve gelişimsel hastalıkların en sık görüldüğü bölümdür. GİS için atrezi terimi tam tıkanıklık anlamına gelirken, kısmi (parsiyel) tıkanıklık durumlarında stenoz ifadesi kullanılır. Duodenal atrezi (DA), gebelikte fetüsün altıncı haftasında gerçekleşmesi gereken rekanalizasyon sürecinin olmamasına bağlı olarak gerçekleşir ve hastaların yaklaşık yarısında başta kardiyak olmak üzere diğer sistem anomalilerine eşlik eder. Ayrıca DA'lı hastaların yaklaşık %30'unda Down sendromu mevcuttur (Rao, 2006). Hastalık yenidoğan döneminde, safralı kusma ve beslenememe ile ortaya çıkar. Karın distansiyonu (şişkinlik) beklenmez. DA'dan şüphelenilen olgularda ilk tercih edilmesi gereken tanı yöntemi abdomen radyografisidir. Radyografide mide ve duodenumda bulunan hava iki baloncuk şeklinde izlenirken tıkanıklık nedeniyle devamına gaz geçişi olmayacağı için daha alt kesimler gazsız olarak izlenir. Bu tipik görüntüye “çift baloncuk” yani “double bubble” bulgusu adı verilir. Bu görüntü varsa


ek görüntüleme ihtiyacı olmadan hasta ameliyat edilerek tıkalı alan çıkarılır ve proksimal ve distal bağırsağın bağlantısı sağlanır (Smith ve diğerleri, 2022).



Şekil 2.2. Down sendromu tanısı olan ve kusma şikayeti ile gelen 11 aylık erkek bebeğin abdomen radyografisi (A) ve işaretli hali (B) sunulmaktadır. Karın üst yarısında midenin ve duodenumun oluşturduğu “double bubble (çift baloncuk)” görünümü bu hastada tipik olarak izlenmektedir (kesikli çizgiler). Distale gaz geçişi olan hastada atrezi dışlanmış olup duodenal stenoz lehine değerlendirildi.

2.1.3 İntestinal Malrotasyon / Midgut Volvulus


Bağırsaklar fetüs döneminde karın içinde saat yönünün tersine doğru yaklaşık 270° dönerek son pozisyonuna gelir ve bu dönüş sürecinde karın arka duvarına mezenter adı verilen yapılarla asılıdır. Dönüşte veya mezenterde oluşan anomaliler nedeniyle ince bağırsakların anormal pozisyonunda bulunmasına malrotasyon bunun sonucunda bağırsakların girdap şeklinde damarların ve mezenterin etrafında dolanarak tıkanıklık oluşturmasına ise volvulus adı verilir (Ayaz, 2021). Bu hastalıkta geçişin tıkanması duodenumun devamlılığında olduğu için abdomen radyografisi bulguları DA ile karışabilir. Ultrason ile damarların değerlendirilmesi tanıya yardımcı iken kesin tanı kontrastlı floroskopide kontrastın bağırsaktan geçişini takip ederek anormal pozisyonun gösterilmesi ile konur.



Şekil 2.3. Safralı kusma ve genel durum bozukluğu ile gelen 11 aylık erkek bebeğin çekilen abdomen radyografisinde (A), mide gazı izlenmekle birlikte karın içinde normal bağırsak gaz dağılımı izlenmemektedir. Ultrason incelemede distandü ve içerik ile dolu mide ve duodenum (B) izlenmiş olup orta hatta superior mezenterik arter ve venin girdap görünümü oluşturduğu izlendi (C). Bu hasta kontrastlı inceleme yapılmadan acil cerrahiye alınmış olup midgut volvulus tanısı kondu. Başka bir olguya kontrast madde içirildikten sonra yapılan incelemede (D) duodenum normalde orta hattan karşıya geçmesi gerekirken intestinal malrotasyon ile uyumlu olarak tekrar sağ üst kadrana doğru ilerlemektedir.

2.1.4 İnvajinasyon


İnvajinasyon (intussusception), bir bağırsak segmentinin daha distalindeki bağırsak segmentinin içine girmesi sonucu normal hareket kabiliyetini (peristalsis) yitirmesi sonucu oluşur. 3 ay – 6 yaş arasındaki ince bağırsak obstrüksiyonlarının en sık sebebidir (Waseem ve Rosenberg, 2008). İnce bağırsakların invajinasyonu ultrason ile daha sık görülmekle birlikte genelde semptom oluşturmaz. Semptomatik olguların ise %90'ı ileoçekal (terminal ileumun çekumun içine girmesi), %10'u ise ileoilealdır (Ayaz, 2021). Hastalarda klasik triad olarak adlandırılan muayene bulguları; karın sağ alt kadranda palpasyonla hissedilen kitle, kolik (aralıklı) tarzda karın ağrısı ve kanlı jöle kıvamında dışkılamadır. Abdomen radyografisinde, dilate ince bağırsak anslarında sıvı-sıvı seviyelenmeleri ve sağ alt kadranda duraklayan gaz gölgesi görülebilir. Ancak ultrasonun tanısallığı daha yüksek olup invajine segment genellikle direk olarak gösterilebilir.



Şekil 2.4. Kusma ve kanlı jöle kıvamında dışkılama şikayeti olan 10 aylık kız bebeğin çekilen abdomen radyografisinde (A), karın sağ tarafında gaz gölgeleri sonlanmakta olup bu düzeyde lümeni dolduran opasite izleniyor (siyah çember). Ultrason görüntülerinde invajine segment longitudinal (B) ve hedef işareti olarak aksiyel (C) (beyaz çember) kesitlerde gösterilmektedir.

2.1.5 Akut / Komplike Apendisit

Akut apandisit daha önce bahsedilen hastalıklar gibi anatomik obstrüksiyon nedeni değildir ancak çekumun devamında bulunan apendiksin inflamasyonu sonucu bağırsak fonksiyon ve hareketini bozarak obstrüksiyon ve buna bağlı radyografi görüntüsü oluşturabilir. Akut apandisit, çocuklarda acil abdomen cerrahisinin en sık nedeni olup acil hekimlerinin sık karşılaştığı bir durumdur (Kandasamy ve diğerleri, 2019). En sık 10-18 yaş arasında görülür (Hryhorczuk ve Lee, 2012). Komplikasyonların önlenmesi ve erken taburculuk için doğru ve zamanında tanı koymak oldukça önemlidir. Klinik bulgular ve lokalize ağrı tipik olmakla birlikte çocuklar genellikle erişkinler kadar başarılı bir şekilde ağrı lokalizasyonu yapamaz. Abdomen radyografisinde sağ alt kadranda iki veya daha fazla hava-sıvı seviyesi bulunan dilate bağırsak gölgeleri destekleyici olmakla birlikte bu hastalığa özgü değildir. Zayıf ve küçük çocuklarda ultrason tanı koydurucu iken, ultrason ile görülemeyen hastalarda kontrastlı BT veya MRG ile tanı konur.




Şekil 2.5. Yaklaşık 3 gündür devam eden ateş, kusma ve sağ alt kadranda ağrısı bulunan 17 yaşındaki erkek hastanın direk radyografisinde (A) sağ alt kadranda opasite ve yaygın hava-sıvı seviyelenmeleri bulunan distandü bağırsaklar izlendi. Ultrason görüntülerinde (B ve C) inflame apendiks hedef şeklinde izleniyor (beyaz çember). Apendiksin lateral komşuluğunda ise kalın duvarlı ve yoğun içerikli apse poşu görülmektedir (kesikli çizgiler).

2.1.6 Mekonyum İleusu / Mekonyum Tıkaç Sendromu

Mekonyum, bebeğin ilk dışkısı olup yoğun ve yapışkandır. Özellikle kistik fibrozisli olgularda mekonyum daha da yoğunlaşarak terminal ileumda kalır; çekuma ve kolon anslarına ilerleyemez. Mekonyum çıkışı görülmeyen bebekte mekonyum ileusundan şüphelenilir ve abdomen radyografisinde çok sayıda dilate ince bağırsak anısı görülür. Bağırsak lümeninde ise gaz ve mekonyum karışımından oluşan sabun köpüğü görünümü mekonyum ileusu için tipiktir. Kolon ansları kullanılmadığı için radyografilerde normalden küçük olarak izlenir veya hiç görülmez. Eğer tanıda gecikme olursa ve ince bağırsak anslarında distansiyon devam ederse, perforasyon sonucu mekonyum peritona dağılır ve mekonyum peritoniti gerçekleşebilir. Mekonyum tıkaç sendromu ise geçici motilite bozuklukları nedeniyle mekonyum çıkışının tam olmaması sonucu daha distal kesimlerde (sigmoid kolon veya rektum) mekonyumun lümeni tıkaması sonucu oluşan obstrüksiyondur. Abdomen radyografisinde mekonyum ileusu veya mekonyum tıkaçından şüphelenilen

olgularda rektal yoldan kontrast madde verilerek yapılan incelemede kolonun ince olduğu ve ileuma kontrast geçişi gösterilerek benzer klinik ve radyografik bulgular oluşturan jejunal/ileal atrezi dışlanabilir. Ayrıca rektal yoldan verilen hiperosmolar kontrast madde mekonyumu yumuşatarak atılımı da kolaylaştırır (Prasad ve Aziz, 2017).




Şekil 2.6. Kusma ve dışkı çıkaramama nedeniyle gelen kız yenidoğanın 3. gün çekilen radyografisinde (A) dilate bağırsak ansları dikkati çekti. Rektal yoldan verilen kontrast madde sonrası çekilen radyografide (B) kolonun belirgin ince kalibrasyonda olduğu vedilatasyonun ince bağırsakta olduğu anlaşıldı. Cerrahi sırasında alınan görüntülerde (C ve D) distandü ince bağırsak anslarını dolduran mekonyum (kalın ok) ve belirgin ince görünümdeki kolon ansları görüldü (D) (Ayaz ve diğerleri, 2017).

2.1.7 Hirschsprung Hastalığı

Hirschsprung hastalığı, etkilenen kolon segmentinde peristalsisi uyaran ganglion hücrelerinin olmaması sonucu ortaya çıkan, yenidoğan dönemindeki en sık distal (kolon ve rektumu içeren) GİS obstrüksiyonu nedenidir. Bu hastalıkta mekonyum çıkışı gecikir ve etkilenen çocuklarda kronik kabızlık olur. Genellikle yenidoğan döneminde şüphelenilir ve çocukların neredeyse tamamı 5 yaşından önce tanı alır. Aganglionik bağırsak segmenti genellikle rektumdan proksimale doğru ilerler ve etkilenen bağırsak segmentinin uzunluğuna göre sınıflandırılır. Hastaların %80-90'ında sigmoid kolon ve rektum etkilenir ve geçiş zonu bu düzeydedir (Rao, 2006). Erkek bebeklerde kızlara göre 4 kat daha fazla görülür. En sık semptomlar, karında şişkinlik ve safralı kusmadır. Abdomen radyografilerinde bulgular spesifik olmayıp genellikle yaygın dilate bağırsak ansları ve çok sayıda hava-sıvı seviyelenmeleri izlenir. Eğer dilate sigmoid kolonun devamında pelviste görece daha

az izlenen veya hiç izlenmeyen rektum gölgesi mevcutsa, Hirschsprung hastalığını destekler. En değerli görüntüleme yöntemi, rektal kontrast madde sonrası floroskopik incelemedir ancak kesin tanı kolonoskopik biyopsi sonrası konur. Rektal kontrastlı incelemede geçiş zonunun gösterilmesi, cerrahide biyopsi alınacak bölgenin belirlenmesi için değerlidir.




Şekil 2.7. Doğuştan beri devam eden kabızlık şikayeti olan 3 aylık erkek bebeğin direk radyografisinde (A) alt batında distandü sigmoid kolon izlendi. Rektal kontrastlı incelemede (B) geçiş zonu görülen hastada biyopsi ile Hirschsprung hastalığı tanısı kondu.

2.1.8 İnguinal Herni

Konjenital inguinal herniler, sıklıkla erkeklerde görülen, inguinal kanal iç halkadan bağırsakların ve diğer batin içi yapıların inguinal kanala ve skrotuma fıtıklaşması sonucu oluşur (Ayaz, 2021). Oldukça sık görülmekte olup tüm çocukların %2-3'ünde izlenir (Hryhorczuk ve Lee, 2012). Ancak hernilerin sadece %10'unda tıkanıklığa veya dolaşım bozukluğuna bağlı olarak obstrüksiyon gelişir (Hryhorczuk ve Lee, 2012). Obstrüksiyon geliştiği takdirde acil cerrahi gerekmektedir. Abdomen radyografisinde obstrüksiyon olan hastalarda karın içinde dilate bağırsak ansları ve çok sayıda hava-sıvı seviyeleri görülür ancak bu bulgular diğer obstrüksiyonlarda da görülen bulgulardır. Sağ veya sol kasık bölgesinde görülen ve skrotuma uzanan gaz dolu bağırsak ansları radyografide görüldüğü

takdirde tanısaldır. Ancak ultrasonun tanısal doğruluğu komplike olmayan hastalarda radyografilerden yüksektir (Ayaz, 2021).



Şekil 2.8. Kusma, huzursuzluk ve sürekli ağlama şikayetleriyle gelen 3 aylık erkek bebeğin radyografisinde (A) dilate bağırsak ansları izlenmekte olup sol skrotuma (beyaz çember) uzandığı dikkati çekti. Hastanın ultrason görüntülerinde (B ve C) longitudinal bakıda iç inguinal halkadan (beyaz çizgi) inguinal kanala giren ve skrotal kesede (beyaz elips) izlenen bağırsak ansları inguinal herni ile uyumludur.

2.1.9 Diğer Hastalıklar

Yukarıda tanımlanan hastalıklar dışında daha nadir olarak çocuklarda obstrüksiyon yapan hastalıklar vardır. Bunlardan konjenital olanlar Meckel divertikülü, duplikasyon kistleri ve diğer kistlerdir. Neoplastik olarak GIS kanserleri, bağırsaklarda basıya veya infiltrasyona neden olan diğer abdominal kanserler ve lenfoma obstrüksiyona neden olabilir. Yutulan yabancı cisimler (özellikle mıknatıs içeren oyuncaklar), saç yeme bağımlılığı olan çocuklarda bağırsak içinde biriken trikobezoar obstrüksiyon oluşturabilir. Geçirilmiş abdomen operasyonu olan hastalarda adhezyonlara ve Ladd bantlarına sekonder obstrüksiyon gelişebilir. Prematüre yenidoğanlarda nekrotizan enterokolit, çocuklarda IgA vaskülopatisi gibi bağırsak tutulumu yapan romatolojik hastalıklar, Crohn Hastalığı gibi inflamatuvar bağırsak hastalıkları, bağırsak motilitesinde bozukluğa neden olarak ileus oluşturur ve abdomen radyografilerinde obstrüksiyonu taklit eden yaygın bağırsak

dilatasyonları ve hava-sıvı seviyelenmeleri oluşturur. Son olarak bizim çalışmamızda gruplandırdığımız ve oldukça sık görülen enfeksiyöz gastroenterit/enterokolitler de benzer şekilde ileus görünümü oluşturarak obstrüksiyonu taklit eder.



Şekil 2.9. Prematüre doğum ve buna bağlı nekrotizan enterokolit öyküsü olan ve bu nedenle karın operasyonu geçiren, bağırsak rezeksiyonu yapılan erkek bebeğin 4 aylıkken, kusma ve gaz-gaita çıkaramama nedeniyle çekilen radyografisinde yaygın dilate bağırsak ansları hava-sıvı seviyelenmeleri izlenmektedir.

2.2 GEÇMİŞTE YAPILAN BENZER ÇALIŞMALAR

Bu bölümde radyografi ile yapılan yapay sinir ağı çalışmaları ve GİS obstrüksiyonunun teşhisi ile ilgili BT, MRG tetkikleri kullanılarak yapılan çalışmalar sunulmaktadır. Amerikan Ulusal Tıp Kütüphanesi veri tabanı olan PubMed'e "neural network" ve "radiology" anahtar kelimeleri girilerek yapılan taramada, radyografi ile yapılan yapay sinir ağı çalışmaları 2016'dan itibaren katlanarak arttı. Ayrıca COVID-19 pandemisi de bu duruma, pandemi döneminde tarama veya tanı amacıyla çekilen akciğer radyografileri ve BT'ler nedeniyle, pozitif anlamda katkı yaptı.

2.2.1. GİS Hastalıklarının Radyografiden Tanısında Derin Öğrenme Uygulamaları

Bu bölümde bizim çalışmamızda olduğu gibi abdomen radyografilerinden GİS hastalıklarının teşhisi için daha önce yapılan çalışmalar incelendi. Kwon ve diğ. yaptığı çalışmada invajinasyonun abdomen radyografilerinden tespiti için üç hastaneden toplamda 11.384 abdomen radyografi (1.449 invajinasyon olan, 9.935 olmayan görüntü) elde edildi (Kwon ve diğerleri, 2020). İnvajinasyon en sık 3 ay – 3 yaş arasında görüldüğü için veri kümesini oluşturan hastaların yaş ortalaması tüm hastaneler ayrı ayrı verilmiş olmak üzere 20-32 ay aralığındaydı. Bu çalışmada veriler ESA modeline sunulmadan önce single shot multibox detector (SSD) ile görüntülerde üst sınır diyafram alt sınır ise kalça eklemelerinin asetabulum bölgesi olarak işaretlendikten sonra abdomen bölgesi seçilerek modele sunuldu. İkili sınıflama için bu çalışmada tercih edilen ESA modeli ResNet oldu. Beş test yapılan çalışmada performans ölçütü olarak ikili kıyaslamalarda kullanılan Youden J indeksi verildi. En yüksek doğruluk değeri 0,76, en düşük değer 0,73 ve ortalama 0,74 olarak elde edildi. Ayrıca ortalama duyarlılık %81,6, özgüllük ise %92,5 olarak bulundu. İnvajinasyon tanısını abdomen radyografilerinden koymak zordur ve tecrübegerektirir. Bu nedenle invajinasyon tanısı genellikle ultrason ile konur. Abdomen radyografisinde deneyimi yeterli olmayan radyologlarda gözlemciler arası uyum %50'nin altındadır (Carrol ve diğerleri, 2017). Bu nedenle çalışmada elde edilen performans değerlerinin gayet iyi olduğu söylenebilir.

Cheng ve diğ. ince bağırsak obstrüksiyonu ile ilgili yaptığı çalışmada 74 obstrüksiyon bulgusu olan toplamda 3.663 ayakta direkt batın radyografisi (2.210 eğitim verisi, 1.453 test verisi) kullanıldı (Cheng ve diğerleri, 2018). Bu çalışmada önceden eğitilmiş InceptionV3 ESA modeli transfer öğrenme metodu ile aktarılarak kendi veri kümesi ile eğitildikten sonra test edildi. Sonuçta elde edilen eğri altındaki alan (EAA) 0,84, duyarlılık %83,8, özgüllük ise %68,1 olarak hesaplandı. Aynı ekibin yaptığı başka bir çalışmada kendi hastaneleri ve ikinci hastaneden elde ettiği radyografilerle 5.558 görüntüden oluşan yeni bir veri kümesi oluşturuldu (Cheng ve diğerleri, 2019). Bu çalışmadaki veri kümesini oluşturan hastaların yaş ortalaması 59,1 ve 59,9 olup obstrüksiyon nedenleri bizim hasta grubumuza göre oldukça farklıdır. Önceki çalışmada olduğu gibi InceptionV3 kullanan araştırmacılar, ikinci

veri kümesiyle modeli eğittikten sonra test etti. Ayrıca karşılaştırmak için 1.453 görüntüden oluşan test verisini üç radyolog birbirinden bağımsız olarak değerlendirdi. Radyologların duyarlılığı %28,5 ile %65,5 arasında (ortalama %44) iken ESA modelinin %82,9; radyologların özgüllüğü %96,4 ile %99,6 arasında (ortalama %98,4) iken ESA modelinin %92,5, radyologların pozitif prediktif değer oranı 0,43 ile 0,78 arasında (ortalama 0,62) iken ESA modelinin 0,28 çıktı. Pozitif prediktif oranın ESA modelinde düşük olmasının nedeni yanlış pozitif olarak teşhis edilen görüntülerin fazla olmasıydı. Bu görüntülere bakıldığında fizyolojik sınırlarda ancak belirgin izlenen bağırsak segmentleri klinik ve radyolojik olarak normal kabul edilirken ESA modeli tarafından pozitif olarak raporlandığı görüldü. Bu sorunun çözümü için benzer görüntüdeki veri sayısı artırılarak sistemin performansının geliştirilebileceği öngörülebilir.

Aynı konudaki İngiltere'den yapılan bir çalışmada 990 erişkin hastanın abdomen radyografisinden (445 normal, 445 GIS obstrüksiyonu) oluşan veri kümesiyle önceden eğitilmiş 5 ESA modelinin (VGG16, Densenet121, NasNetLarge, InceptionV3, and Xception) transfer öğrenme ve birlikte kullanılmasıyla (ensemble model) sınıflandırma yapıldı (Kim; 2021). Veri kümesi içerisinde 800 veri eğitim, 80 veri validasyon ve 110 veri test için kullanıldı. Sonuç olarak duyarlılık %91, özgüllük %93, doğruluk %92, EAA ise 0,96 olarak saptandı. Testte kullanılan 110 veri içerisinde yanlış negatif olgu sayısı 5, yanlış pozitif olgu sayısı ise 4'tü. Modeller içerisinde Densenet121 akciğer radyografisi görüntülerinden oluşan CheXNet ile, diğer modeller ise ImageNet ile eğitilmişti. Densenet121 modelinin validasyon kayıp oranı diğer modellere göre oldukça düşük olup 0,43 olarak saptandı. Bu da transfer öğrenme öncesi eğitim veri kümesinin de önemli olduğunu ortaya koymaktadır.

Bu bölümde söz edilen çalışmaların performans ölçütleri Tablo 2.1'de sunulmaktadır.

Tablo 2.1. Literatürde GİS hastalıklarının tanısı için yapılan ESA çalışmalarındaki performans ölçüt sonuçları

	Veri kümesi	Doğruluk (Accuracy)	Özgüllük (Specificity)	Duyarlılık (Sensitivity)
Kwon, 2020	11.384 (1449 pozitif, 9935 negatif)	0.76	0.925	0.816
Cheng, 2018	3.663 (74 pozitif, 3589 negatif)	0.685	0.681	0.831
Cheng, 2019	5.558 (462 pozitif, 5096 negatif)	belirtilmemiş	0.925	0.829
Kim, 2021	990 (445 pozitif, 445 negatif)	0.918	0.927	0.909

2.2.2. Abdomen görüntülemesi ile ilgili yapılan çalışmalar

Bizim çalışmamızda abdomen radyografileri veri olarak kullanıldığı için aynı anatomik bölgede diğer modaliteler ile ilgili çalışmalar bu başlık altında incelenmektedir. Abdomen radyografileri, akciğer filmlerine göre çok daha az çekilmektedir; içerdiği organlar ve hastalıklar çok çeşitlidir. Ayrıca tanılabilirliği çoğu hastalık için az olmaktadır. Bu nedenle ultrason, BT veya MRG gibi ek görüntüleme yöntemlerine ihtiyaç duyulmaktadır.

Batın için özellikle MR elastografi uygulamalarında karaciğer hastalıklarında doku sertliğini belirlemek için uygulanan destek vektör makineleri gözetimli öğrenme yöntemi ile hazırlanan makine öğrenmesi yazılımları MRG firmaları tarafından klinik kullanıma sunuldu (Dillmann ve diğerleri, 2022). Li ve diğ. tarafından geliştirilen DeepLiverNet modeli patolojik fibrozis oranı ile karşılaştırıldığında %61 duyarlılık, %92 özgüllük, %80 doğruluk oranları elde edildi (Li ve diğerleri, 2020). Bu program ayrıca kullanıcılara fibrozis oranına göre ağırlık haritası çıktısı da sunmaktadır. Abdomen MRG görüntüleri ile bir inflamatuvar bağırsak hastalığı olan Crohn hastalarına yapılan çalışmada öznelik çıkarımı ile normal bağırsak duvarı ile Crohn tutulumu olan bağırsak duvarı ayrımı arasında %90'ın üzerinde doğruluk elde edildi (Dillmann ve diğerleri, 2022).

Abdominal organların onkolojik hastalıklarında benign (iyi huylu) ve malign (kötü huylu) kitleleri ayırt etmek amacıyla da çok sayıda çalışma vardır. Karaciğer kitlelerinin ultrason ile incelendiği bir çalışmada, patolojik olarak kanıtlanmış benign ve malign kitleleri iki radyolog %68 doğruluk oranı ile ayırt ederken, önceden eğitilmiş ve transfer öğrenme sonrası aynı veri kümesi ile test edilen ResNet50 ESA modeli %79 doğruluk ile ayırt etti (Xi ve diğerleri, 2020). BT görüntülerinden benign-malign böbrek kitlelerinin ayırımının yapılmaya çalışıldığı başka bir çalışmada ise toplamda 160 veriden oluşan veri kümesi ile elde edilen doğruluk oranı %79 olarak hesaplandı (Zabihollahy ve diğerleri, 2020). MRG ile 6 farklı karaciğer tümöründen (benign kist, kavernöz hemanjiom, fokal nodüler hiperplazi, hepatosellüler karsinom, intrahepatik kolanjiokarsinom ve kolorektal kanser metastazı) oluşan 494 lezyon (434 eğitim, 60 test) içeren veri kümesi ile yapılan çalışmada toplamda %82,9 duyarlılık, %76,5 kesinlik elde edildi (Hamm ve diğerleri, 2019). Lezyonlar tek tekele alındığında ise benign kistlerde kesinlik %100, kavernöz hemanjiomda duyarlılık %96,1 ile yüksek; kolorektal kanser metastazlarında kesinlik %61,2, hepatosellüler karsinomda ise duyarlılık %64,2 ile düşük saptandı (Wang ve diğerleri, 2019). Rutin pratikte de radyologlar, bu kitlelerden benign kistleri ve kavernöz hemanjiomları MRG görüntülerinden kolaylıkla ayırabilirken, malign kitlelerde, özellikle atipik olgularda tanı zorlaşmakta ve genellikle biyopsi gerekmektedir.

Başka bir çalışmada klinik olarak over (yumurtalık) torsiyonu şüphesi olan, bir yaşından büyük 430 kız çocuğunun ultrason görüntülerinden hazırlanan veri kümesi test edildi (Otjen ve diğerleri, 2022). Bu olguların 99 tanesinde cerrahi olarak torsiyon saptanırken diğerlerinde torsiyon yoktu. Over torsiyonu, overin rahime ve karın duvarına asan bağlarının ve damarlarının spiral şeklinde kendi etrafında dönmesi sonucu oluşan bir durumdur. Damarlar döndüğü için tıkanır ve overe kan gitmez, boğulur, bu nedenle acil tedavi gerektirir. Erken cerrahi olan hastalarda bağlar ters yöne döndürülerek over kurtarılabilir ancak kanlanmanın uzun süre bozulduğu durumda overler çıkarılır. Bazen torsiyona rağmen ultrasonda akım görülebildiği için tanısı zordur. Ancak belirtilen çalışmada over torsiyonu teşhis etmede duyarlılık %95, özgüllük %92, ve EAA 0,96 ile çok güçlü bir performans elde edildiği bildirildi (Otjen ve diğerleri, 2022)

2020 yılında yayınlanan makalede Kim ve diğ. Kim-Monte Carlo algoritması ile hazırlanan yapay sinir ağı modeli ile abdomen radyografilerinden pnömoperitoneumu saptamayı amaçladılar (Kim ve diğerleri, 2020). Pnömoperitoneum, batını saran ve karın duvarının hemen içinde yer alan bir zar olan peritonun içindeki serbest hava anlamına gelmektedir. Bu alanda normalde hava yoktur. Eğer bağırsak perforasyonu, cerrahi operasyon, delici, kesici alet yaralanması gibi havanın bu kesime ulaşacağı bir durum olursa pnömoperitoneum görülür. Bu çalışmada 70 pnömoperitoneum olgusuyla 130 normal abdomen radyografisinden oluşan bir veri kümesi hazırladılar. Kullandıkları modele sunmak için verilerin standart ve aynı boyutlarda olması gerekiyordu, bu nedenle ön işleme uyguladılar. Ayrıca karşılaştırmak için aynı veri kümesini ResNet50’de kullandılar. Kendi sinir ağı modelleri ile duyarlılık %72,9, doğruluk %78,5; ResNet50 modeli ile duyarlılık %85,7, doğruluk %85 olarak elde edildi.

Postoperatif adhezyonlara bağlı ince bağırsak obstrüksiyonlarının BT görüntülerinden teşhisi ile ilgili yapılan bir çalışmada ESA modeli ile obstrüksiyon noktasının belirlenmesi amaçlandı (Vanderbecq ve diğerleri, 2022). 562 veri kümesi kullanılarak, 4 evrişim, 2 yoğunlaştırıcı katmandan oluşan ESA ile yapılan çalışmada en yüksek EAA 0,93, yanlış pozitiflik oranı ise %14 olarak elde edildi. Ayrıca bu çalışmada sınıf aktivasyon haritaları ile tespit edilen obstrüksiyon noktası da kullanıcılara sunulmaktadır. Klinik pratikte bu model inceleme süresini belirgin olarak kısaltabilir.

2.2.3. Akciğer Radyografileri İle İlgili Çalışmalar

Radyografilerde sinir ağları ile ilgili çalışmalar ilk olarak en sık çekilen akciğer radyografilerinde yapıldı. Akciğer radyografileri ucuz, kolay ulaşılabilir olması ve tanısal değeri nedeniyle çok sık kullanılan bir görüntüleme yöntemidir. Ayrıca bazı mesleklerde ve sporcularda yıllık muayenede çekilen akciğer radyografileri tüm medikal görüntülemelerin yaklaşık %45’ini oluşturmaktadır (Yao ve diğerleri, 2017). Bu nedenle yapay sinir ağı ile ilgili çalışmalar ilk olarak akciğer radyografileri üzerinde yapıldı. 2015 yılında Bar ve diğ. yaptığı çalışmada tıp dışı görüntülerden oluşan ImageNet veri kümesi ile eğitilen ESA, normal ve üç patolojik grup olarak etiketlenirilmiş 93 adet akciğer radyografisi üzerinde test edildi (Bar ve

diğerleri, 2015). Bu çalışmada ikili (binary) sınıflamalar yapılmış olup EAA oranlarının 0,7-0,8 arasında olduğu belirtildi.

Özellikle 2017 yılından itibaren açık erişime sunulan akciğer radyografisi içeren büyük veri kümeleri ile birlikte grafik işlem birimlerinin (GPU) gücünün ve erişiminin artması bu konuda dönüm noktası oldu (Cicero ve diğerleri, 2017). Indiana Network for Patient Care tarafından sunulan 7.470 akciğer radyografisi içeren OpenI veri kümesi bu konuda başlangıç oldu. Amerikan Ulusal Sağlık Enstitüsü (National Institute of Health) ekibinin hazırladığı 8 farklı grupta hastalık venormal akciğerler ile toplamda 108.948 akciğer radyografisi içeren “ChestX-ray8” veri kümesi bu konudaki çalışmaları ivmelendiren ilk kaynak oldu (Wang ve diğerleri, 2017). Aynı yıl aynı grup tarafından 14 farklı hastalık grubu ile 112.120 akciğer radyografisi içeren “ChestX-ray14” veri kümesi erişime açıldı. Bu veri kümesi üzerinde 14 hastalığın teşhisi ile ilgili yapılan ve 2017’de yayınlanan çalışmalarda 0,7’nin üzerine çıkan EAA ve radyologlar ile benzer düzeyde F1 skorları elde edildiği belirtildi (Rajpurkur ve diğerleri, 2017; Wang ve diğerleri, 2017; Yao ve diğerleri, 2017)

Aynı yıl Toronto Üniversitesi, St. Michael Hastanesi’nde çekilen radyografilerden oluşturulan normal ve 5 ayrı hastalık grubu olarak etiketlenmiş toplam 35,038 radyografiden oluşan veri kümesi GooLeNet adlı 22 katmanlı ESA’da kullanıldı (Cicero ve diğerleri, 2017). Bu çalışmada elde edilen EAA, önceki çalışmalara göre yüksek (0,85 ile 0,95 arasında) bulundu. En yüksek doğruluk ise normal radyografilerde elde edildi. 2018 yılında University of California, San Francisco (UCSF)’da yapılan çalışmada 3,107 pnömotoraks olan ve 10,185 pnömotoraks olmayan toplam 13,292 radyografiden oluşan kendi veri kümesi hazırlanarak kullanıldı (Taylor ve diğerleri, 2018). Ayrıca VGG16/19, Xception, Inception, and ResNet ESA modelleri kullanılarak oluşturulan ESA, iki farklı tam bağlantılı katmana (fully connected layer) bağlanarak bunların sonuçları karşılaştırıldı. Sonuç olarak bu çalışmada en yüksek duyarlılık (0,84) ve en yüksek özgüllük (0,97) elde edilen modellerin EAA değerleri sırasıyla 0,94 ve 0,96 olarak bulundu (Taylor ve diğerleri, 2018). Kermany ve diğ. 3,883 pnömoni ve 1,349 normal etiketlenmiş toplam 5,232 çocuk akciğer röntgen görüntüleri içeren veri kümesi kullanılan

çalışmalarında, pnömoni tespiti için ESA modeli kullanarak viral ve bakteriyel pnömoni sınıflandırılmasında %92,8 doğruluk elde etti (Keremany ve diğerleri, 2018).

2019 yılında Stanford Üniversitesi Hastanesi'nde 2002 – 2017 yılları arasında çekilen radyografilerden 14 farklı etiket ile etiketlenmiş 224,316 akciğer radyografisi veri kümesi açık erişime sunuldu (Irvin ve diğerleri, 2019). Bu araştırmacılar ESA modellerinden ResNet152, DenseNet121, Inception-v4, ve dSEResNeXt101 denedikten sonra en iyi sonuç veren DenseNet121 modelini kullanmaya karar verdi. Daha sonra yapılan eğitim ve validasyon işlemlerinden sonra test aşamasında ESA modeli üç farklı radyolog ile karşılaştırıldı. Etiketlerden, kardiomegali, plevral efüzyon ve ödem söz konusu olduğunda ESA, üç radyoloji uzmanından da daha iyi sonuç verdi. Konsolidasyonda bir radyolog ESA modeline göre daha başarılı iken atelektazide üç radyoloji uzmanı da modelden daha başarılı oldu. Aynı yıl Jaiswal ve diğ. özellikle ön işleme ile akciğer dışı alanları değerlendirme dışında bırakan piksel tabanlı segmentasyon ile verilere ön işleme yaptıktan sonra ESA modeline sunulmasını sağlayan Mask-RCNN adını verdikleri modeli yayınladılar (Jaiswal ve diğerleri, 2019). Bu modelle özellikle eğitim (training) fazının gücünü arttırdığını düşünerek eğitim ve validasyon kayıp (loss) oranlarına daha erken ulaşılabildiğini belirttiler. 2019'da Kore'den yapılan bir çalışmada 1-5 yaş arası çocuklardan elde edilen 5,856 akciğer radyografisi veri kümesi olarak kullanıldı (Stephen ve diğerleri, 2019). Daha önce belirtilen çalışmalarda önceden hazırlanmış ve medikal dışı büyük verilerle eğitilmiş ESA modellerinin “transfer öğrenme” modeli ile akciğer radyografisi veri kümesinde kullanıldığı görülürken, bu çalışmada kendi hazırladıkları ESA modelini kendi verileri ile sıfırdan bir modelle eğittikleri görülmektedir. Bu sayede doğruluk oranı daha yüksek elde edilmiştir ancak epok (devir) sayısının çok daha fazla, eğitim ve validasyonun daha uzun olması olumsuzdur. Chouhan ve diğ. eğitim için gereken büyük veri kümesi ihtiyacını önlemek amacıyla transfer öğrenme metodunun etkinliğini ölçmeyi amaçlamıştır. Bu amaçla bilinen 5 ESA modelini (AlexNet, DenseNet121, InceptionV3, resNet18 ve GoogLeNet) ImageNet veri kümesi ile eğittikten ve öznetlik çıkarımı işleminden sonra kendi hazırladıkları 5.232 akciğer radyografisinden oluşan veri kümesinde kullandı. Tüm modellerin doğruluğu %90'ın üzerinde iken ensemble modelin doğruluğu %96,4 olarak en yüksek çıktı (Chouhan

ve diğerleri, 2020). Sonuç olarak transfer öğrenme işleminin güvenle kullanılabilceğini belirttiler.

Veri sayısının yeterli olmadığı durumlarda uygulanan veri artırma (data augmentation) işlemleri ile mevcut verilerin bazı özellikleri manipüle edilerek yeni veriler elde edilebilir. Bu şekilde yapılan bir çalışmada, akciğer radyografilerinden pnömoni tespiti için hazırlanan veri kümesinde 1.283 normal radyografi ve 3.873 pnömoni olgusu vardı. Veri oranı dengesizliğinden dolayı normal olgulara veri artırma teknikleri (rotasyon, vertikal ve horizontal şift, kırpma gibi) uygulanarak normal radyografi sayısı 3.399'a çıkarıldı. Bu çalışmada aynı zamanda transfer öğrenme uygulanarak, çıkan sonuçlar tekrar ağırlıklar ile hesaplanıp ağırlıklı sınıflandırma ile %98,4 test doğruluğu elde edildi (Hashmi ve diğerleri, 2020). Ülkemizden yapılan bir çalışmada 5.840 akciğer radyografisinden oluşan veri kümesi kullanılarak kendi hazırladıkları ESA modeli, veri artırma ile birlikte kullanılan ESA modeli ve transfer öğrenme ile kullanılan VGG-16 ESA modeli karşılaştırıldı (Gülgün ve Hamza, 2020). Veri kümesi 5.216 eğitim ve 624 test verisi olarak bölündükten sonra veri artırımı ile eğitim verisi sayısı 6.400'e yükseltildi. Doğruluk oranı kendi ESA modelleriyle %80,4, VGG-16 ile %85,6, veri artırımı kullanıldığında ise %93,4 olarak bulunmuş olup verilerin dengeli olmadığı durumlarda veri artırımı önerilmektedir.

Ülkemizde yapılan başka bir çalışmada ise açık erişime sunulmuş 1.583 normal, 4.266 pnömoni olgusundan oluşan 5.849 adet akciğer radyografisi AlexNet ESA modelinde kullanıldı ve sınıflandırıcı yöntemler (karar ağacı, doğrusal ayırmacılık analizi, lineer regresyon, destek vektör makineleri, en yakın komşu ve softmax) karşılaştırıldı (Toğaçar ve diğerleri, 2019). Sonuç olarak en düşük doğruluk lineer regresyon (% 60,7) en yüksek doğruluk ise destek vektör makineleri (%95,8) ile elde edilmiş olup doğru sınıflandırıcı seçiminin önemi vurgulanmaktadır.

2.2.4. COVID-19 Pandemisi Sürecinde Yapılan Çalışmalar

Bir koronavirüs tipi olan SARS-CoV2'nin (Severe acute respiratory syndrome – Coronavirus 2) sebep olduğu, hızlı yayılan ve şiddetli pnömoni (zatürre) oluşturan hastalık ilk olarak 31 Aralık 2019'da Çin'in Wuhan şehrinde görüldükten sonra 1 ay içinde tüm Çin'e, yaklaşık 3-4 ay içinde de tüm Dünya'ya yayıldı.

Ülkemizde de 11 Mart 2020’de ilk vaka açıklandıktan sonra hastalığın yayılması ve alınan önlemler nedeniyle sağlık sisteminde köklü değişiklikler oldu. Bu süreçte özellikle akciğer radyografisi ve BT çekimlerinde büyük artış olurken kapanma önlemleri ile birlikte diğer hastaların hastaneye erişiminde sıkıntılar ortaya çıktı. Akciğer radyografileri ve BT tetkikleri test kitinin düşük duyarlılığı nedeniyle COVID-19 taramasında da kullanılmaya başlandı (Lee ve diğerleri, 2020). COVID-19 pnömonisinin BT ile tespit oranı ilk çalışmalarda %50-75 civarında iken bu oran pnömoninin yayılmasıyla giderek arttı (Öztürk ve diğerleri, 2020). Akciğer radyografilerinde yuvarlak periferik opasiteler şeklinde görülen COVID-19’un tespit oranı %60 civarındadır (Kanne ve diğerleri, 2020). Ayrıca akciğer radyografisinin hızlı, ucuz, kolay uygulanabilir ve rahat erişilebilir olması, temizlik ve dezenfeksiyon önlemlerinin daha rahat uygulanabilir olması, BT’ye göre oldukça düşük doz iyonize radyasyon içermesi, temaslı ve şüpheli olgularda dahi tarama amacıyla sıklıkla kullanılmasını sağladı.

COVID-19 pandemisinin ilk birkaç ayından itibaren veri sayılarının artması ve buna bağlı olarak iş yükünün artması radyografileri değerlendirmede tanıya destek amaçlı yapay zeka uygulamaları araştırmalarının artışına neden oldu. Bunlar içinde en çok ön plana çıkan halihazırda belli aşama kat edilmiş olan ESA modelleri ile yapılan sinir ağlarıydı. Bu konuda açık erişime sunulan ilk ESA modellerinden biri 19 katmanlı ResNet101 ile benzer mimarideki COVID-NET adı verilen modeldir. COVID-NET ile birlikte 13,975 akciğer radyografisinden oluşan COVIDx veri kümesi de açık erişime sunuldu (Wang ve diğerleri, 2020). COVID-NET’in duyarlılığı %91, doğruluğu %93 ile gayet iyi olarak saptandı. ESA’da katmanlardan bilginin aktarımı sırasında uzaysal bilgide kayıp olduğu ve yüksek doğruluk için çok sayıda veri sağlanması gerekliliği nedeniyle kapsül sinir ağı (capsule network) modelinin kullanılmasını öneren Afshar ve diğ. COVID-CAPS adını verdikleri sinir ağı modelini geliştirdi. Bu modelin doğruluğu %98, duyarlılığı %80 ve EAA 0,97 olarak elde edildi (Afshar ve diğerleri, 2020).

Ülkemizden de Nisan 2020’den itibaren yayınlanan COVID-19 tanısı için kullanılan çok sayıda sinir ağı modeli ve çalışma sunuldu. İlk çalışmalardan birinde Bayesian optimizasyonu ile kullanılan ve önceden eğitilmiş olan SqueezeNet sinir ağı kullanıldı ve COVIDiagnosis-Net adı verildi (Uçar ve Korkmaz, 2020). Bu modelin

daha önce kullanılan ESA'lara göre daha düşük katmanlı ve parametrelili olması avantajları iken verilerin sunulmadan önce standardizasyonu ve veri artırımı gerekliliği dezavantajları olarak göze çarpmaktadır. Bu model ile elde edilen doğruluk % 98,3 olarak ölçüldü.

Öztürk ve diğ. yaptığı çalışmada daha önceden gelişen ve gerçek zamanlı nesne tespitinde sık kullanılan YOLO (you only look once) temelli Darknet-19 modelinden ilham alındı. Darknet-19'a göre daha az filtre ve katman kullanılarak 17 katmanlı DarkCovidNet adını verdikleri modeli geliştirdiler (Öztürk ve diğerleri, 2020). Bu model, normal-COVID-19 ikili sınıflamasında %98,1, normal-pnömoni-COVID-19 üçlü sınıflamasında ise %87 doğruluk elde etti. Üçlü sınıflamada düşük doğruluk oranının sebebi COVID-19 ve pnömoni olan radyografilerdeki benzer bulgular olarak göze çarpmaktadır.

Narin ve diğ. yaptığı çalışmada önceden ImageNet veri kümesi ile eğitilen 5 ESA modeli (ResNet50, ResNet101, ResNet152, InceptionV3 and InceptionResNetV2) iki gruptan oluşan üç veri kümesi (COVID-19-normal, COVID-19-bakteriyel pnömoni, COVID-19-viral pnömoni) ile test edildi. Modeller içinde ResNet50, üç veri kümesinde de en yüksek doğruluğa ulaştı (COVID-19-normal: %96,1; COVID-19-bakteriyel pnömoni: %99,5; COVID-19-viral pnömoni: %99,7 (Narin ve diğerleri, 2021). Bu çalışmada ilginç olan klinik pratikte radyologların en zor ayırdığı COVID-19 ve viral pnömoni ayrımının en yüksek doğruluk oranına ulaşması diğerlerine göre daha kolay ayırım yapılabilecek normal ve COVID-19'un ise en düşük kalmasıdır. Veri sayılarında da (normal: 2800, viral pnömoni:1493, bakteriyel pnömoni: 2772) viral pnömoninin görece düşük olmasına rağmen doğruluğun bu kadar yüksek çıkması ilginçtir. Araştırmacılar yazılarında bununla ilgili bir açıklama yapmamış olup çalışma sırasında verilerin alanında uzman bir radyolog tarafından değerlendirilip bu sonucun nedeninin belirlenmemesi bu çalışmanın kısıtlılığı olarak göze çarpmaktadır.

Şahinbaş ve diğ. yaptığı çalışma da önceki çalışma ile benzer nitelikte olup transfer öğrenimi ile önceden eğitilmiş ESA modelleri (VGG16, VGG19, ResNet, DenseNet, ve InceptionV3), COVID-19 ve normal radyografileri içeren iki gruptan oluşan veri kümesi ile test edildi (Şahinbaş ve Çatak, 2021). Bu çalışmada en yüksek performans

%80 doğruluk oranı ile VGG-16'dan alındı. Doğruluk oranının diğer çalışmalara göre düşük kalmasının muhtemel sebebi veri sayısının her iki grup için 70 (50 eğitim, 20 test) ile çok az olması gibi görünmektedir.

Toraman ve diğ. kapsül sinir ağını iki sınıflı (COVID-19 ve normal) ve üç sınıflı (COVID-19, normal ve pnömoni) veri kümesi üzerinde test ettiler (Toraman ve diğerleri, 2020). Kapsül sinir ağına bulunan kapsüller nöron adı verilen diğer katmanlarla bağlantıyı sağlayan yapılardan çok fazla içerdiği için ESA'da iletilen skaler veri, kapsül ağına vektörel olarak iletilmektedir. Bu nedenle kapsül sinir ağının aktivasyon fonksiyonu, ESA'da kullanılan ve daha sonra açılan aktivasyon fonksiyonlarından farklıdır. Kapsül sayısında nöronlar çok sayıda olduğu için katman sayısı, aynı parametre sayısı içeren ESA'ya göre daha azdır. Bu çalışmada hazırlanan modelde de araştırmacılar 5 katmandan oluşan model hazırladı. İkili sınıflamada %97,4 iken üçlü sınıflamada %84,2 doğruluk elde edildi. Kapsül ağlar daha az katmanla yüksek doğruluk elde etmesine rağmen daha güçlü donanım gerektirmesi, uzun işlem süresi ve verilerin aynı boyut olarak sunulmasının gerekliliği ESA modellerine göre zayıf yanlarıdır.

Toğaçar ve diğ. yaptıkları çalışmada verilerin ön işleme sürecinin performansa etkisini araştırdı (Toğaçar ve diğerleri, 2020). Üç sınıftan oluşan (COVID-19, normal ve pnömoni) ve toplam 295 görüntü içeren veri kümesi kullanıldı. Rekonstrüksiyon tekniklerinden “fuzzy color” ve “stacking” tekniklerini karşılaştırdıktan sonra öznelik çıkarımı yapmak için sosyal mimik optimizasyon algoritmasını kullandılar. Önceden eğitilmiş SqueezeNet ve DenseNetV2 modelleri ile yapılan eğitim ve test işlemlerinden sonra elde edilen doğruluk oranı SqueezeNet için %97,8, DenseNetV2 için %98,5 ve kombine model için %99,3 olarak elde edildi. Ön işleme sayesinde daha az parametre içeren modellerle yüksek doğruluk sağlandı. Bu çalışmada en önemli dezavantajlar ön işleme için verilerin standart boyutlarda olması ihtiyacı ve ön işleme ile görüntü çözünürlüklerinin oldukça düşmesi olarak gösterildi.

Bu bölümde tartışılan COVID-19 tanısı ile ilgili akciğer radyografileri kullanılarak yapılan çalışmaların performans ölçütleri Tablo 2.2'de sunulmaktadır.

Tablo 2.2. Literatürde COVID-19 pnömonisinin tanısı için akciğer radyografilerinde yapılan ESA çalışmalarındaki performans ölçüt sonuçları

	Veri kümesi	Doğruluk (Accuracy)	Özgüllük (Specificity)	Duyarlılık (Sensitivity)
Wang, 2020	13.962 (8066 normal, 5538 nonCOVID pnömoni, 358 COVID-19)	0.933	0.95	0.91
Afshar, 2020	belirtilmemiş	0.957	0.958	0.90
Uçar, 2020	5.979 (1583 normal, 4290 nonCOVID pnömoni, 76 COVID-19)	0.983	0.967	0.991
Öztürk, 2020	1127 (127 COVID-19, 1000 negatif)	0.981	0.953	0.951
Şahinbaş, 2021	140 (70 COVID-19, 70 negatif)	0.8	0.8	0.8
Toğaçar, 2020	458 (65 normal, 98 nonCOVID pnömoni, 295 COVID-19)	0.993	0.991	1.00

BÖLÜM III – KURAMSAL TEMELLER

Tezin bu bölümünde metodoloji ve kullanılan yöntemler hakkında teorik bilgiler verilmektedir.

3.1 YAPAY ZEKA


Yapay zeka çok geniş kapsamda ele alınabilen bir kavram olduğu için tarihçesi ve anlamı ile ilgili olarak farklı görüşler vardır. Bu tezde çok geriye gitmeden yapay zekanın gelişimi sürecini 1950 yılında ünlü İngiliz matematikçi ve mantıksal hesaplamalar konusunda çalışmaları olan Alan Turing'in Mind dergisinde yayımlanan makalesinde sorduğu “Can machines think? (makinelere düşünebilir mi?)” sorusuyla başlatabiliriz (Turing; 1950). Turing, kuramsal olarak makinelerin özellikle ikili sınıflamalar; soru-cevap ve geri bildirimler sonucunda kendilerini geliştirebileceklerini düşünmektedir. Daha sonradan Turing testi olarak adlandırılan ve bir bilgisayarın insanlarla aynı zihinsel yetiye sahip olup olmadığını belirlediği testi hazırlayan Turing, testin bu ayrımı yapamadığı seviyede makinenin insanlar kadar zihinsel yetiye sahip olarak kabul edilebileceğini belirtmiştir. Bu bağlamda yapay zekayı temel olarak insan zekasını taklit eden bilgisayar programları, yapay zekanın amacını ise insan olmaksızın makinelere kompleks işler yaptırabilme yeteneği olarak düşünebiliriz (Pirim; 2006)

3.2 MAKİNE ÖĞRENMESİ VE YAPAY SİNİR AĞLARI

Makine öğrenmesi, yazılım sistemlerinin çok büyük veriler sağlandığı takdirde olasılık hesaplarıyla birlikte algıladığı veriler arasındaki benzerlikleri veya farklılıkları fark etmesi olarak tanımlanabilir. Bu tanım özellikle “perceptron” veya yapay nöron adıyla Rosenblatt tarafından tanımlanmış olup görsel verileri algılayan “photoperceptron”, işitsel verileri algılayan “phonoperceptron” gibi türleri belirtilmiştir (Rosenblatt; 1957). Perceptron, tek katmanlı bir sinir ağıdır ve aktivasyon işlemi uygulanan bir dizi ağırlıklı girdiler olarak tanımlanabilir (Şekil 3.1). Ağırlıklı girdiler bir toplam üretir ve eğer bu toplam belirlenen bir eşik değerin üzerindeyse 1, altındaysa 0 kabul edilir. Perceptron modelini çok katmanlı hale getirerek geriye yayılım teorisini (back propagation) ortaya koyan Rumelhart ve diğ.

ise makine öğrenmesinin bir üst modeli olan yapay sinir ağlarının başlangıcını oluşturan kuramsal temelleri atmış oldular (Rumelhart ve diğerleri, 1986).

Makine öğrenmesindeki temel yöntemler, denetimli öğrenme, denetimsiz öğrenme ve takviyeli öğrenme olarak sınıflandırılabilir. Denetimli öğrenme ile etiketlenmiş veriler ile eğitim yapılarak, yeni gelen verilerden doğru sonuçlar üretilmesi sağlanır. Denetimsiz öğrenmede ise denetimli öğrenmenin aksine etiketlenmiş veri bulunmamaktadır. Bunun yerine hiç görmediği veriler üzerinde benzerlik, farklılık gibi özelliklerine göre gruplandırma yapılmaktadır. Takviyeli öğrenme ile sistemin doğru kararları ödüllendirilir, yanlış kararları cezalandırılır. Makine öğrenmesi modelleri kullanılırken öznel vektörlerinin çıkarılmasına ihtiyaç vardır. Bu işlemlerde yapay zeka uygulamaları ve derin öğrenme kullanılır.

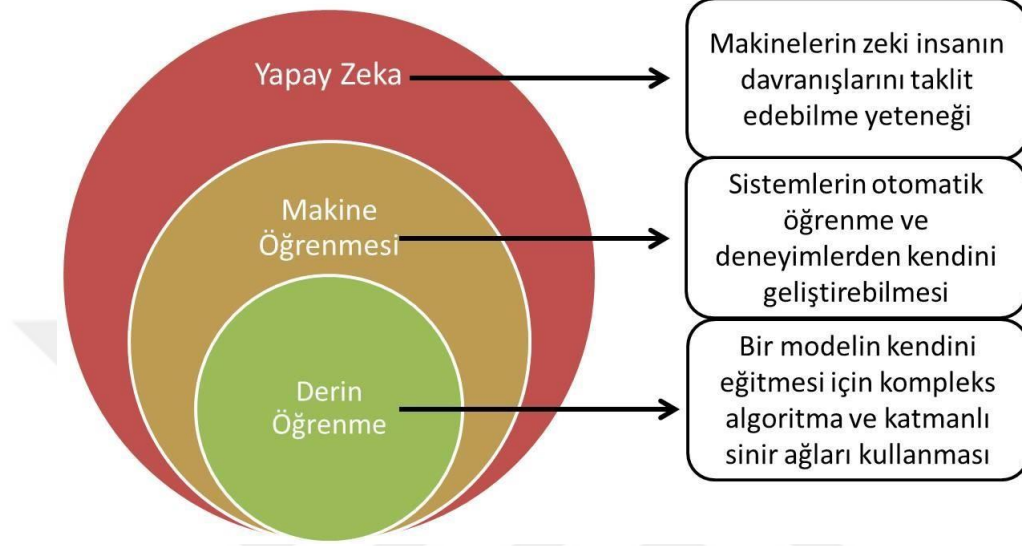


Şekil 3.1. Tek katmanlı perseptron (yapay nöron) modeli (x: girdi, w:ağırlık, y: çıktı)

3.3 DERİN ÖĞRENME

Derin öğrenme, makine öğrenmesinin alt dallarından olup bilgisayarların öğrenme sürecinde verilerden probleme özgü özellikler çıkararak oluşturduğu çok katmanlı bir yapıdır (Şekil 3.2). Derin öğrenme modelleri, elle çıkarılan özellikler

yerine probleme özgü veriyi en iyi tanımlayan öznitelikleri kendisi belirlemektedir. Derin öğrenmenin diğer yaklaşımlara kıyasla daha fazla veri ile çalışabilmesi, daha çok işlem gücü, uzman ihtiyaç olmadan öznitelikleri belirlemesi gibi özellikleri vardır.



Şekil 3.2. Yapay Zeka-Makine Öğrenmesi-Derin Öğrenme Arasındaki Hiyerarşi

Günümüzde pek çok farklı derin öğrenme modeli tanımlanmıştır. Bazı sık kullanılan derin öğrenme modelleri aşağıda listelenmektedir (Doğan ve Türkoğlu, 2019)

- Evrimsel Sinir Ağı (ESA, CNN - Convolutional Neural Networks)
- Tekrarlayan Sinir Ağı (RNN - Recurrent Neural Networks)
- Kapsül Sinir Ağı (CapsNet – Capsule Network)
- Uzun-Kısa Süreli Hafıza (LSTM- Long Short-Term Memory)
- Kısıtlı Boltzmann Makinesi (RBM- Restricted Boltzmann Machine)
- Derin İnanç Ağı (DBN- Deep Belief Network)
- Derin Oto-Kodlayıcılar (AE- Auto Encoder)

Derin öğrenme modellerinde en az üç katmandan oluşan çok katmanlı algılayıcılar kullanılmaktadır. İlk katman girdi katmanı, son katman çıktı katmanıdır. Ortada bulunan en az bir veya daha fazla katman ise gizli katmanlardır. Birkaç gizli katmanı bulunan ağlar yalnızca doğrusal problemleri çözebilirken, karmaşık problemleri çözmeye başarısızdır. Gizli nöron sayısının artması ağın genelleştirme yapmasını

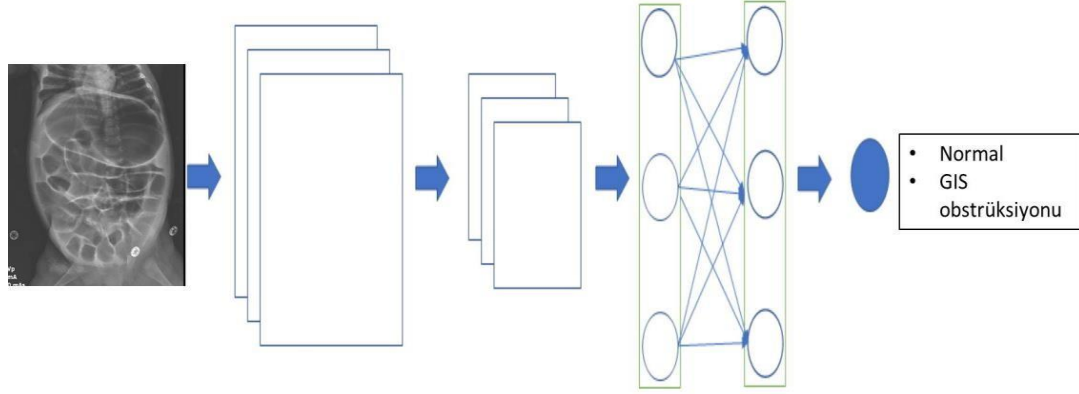
önlemektedir. Ancak gizli katman sayısının artması donanım ihtiyacının ve işlem süresinin artmasına neden olabilmektedir. Çok katmanlı modellerde ağıın eğitimi iki yönlüdür; ileri yayılım (forward propagation) ve geri yayılım (back propagation). İleri yayılımda sisteme verilen girdi, katmandaki ağırlıklar ile çarpılıp, elde edilen değerler toplanarak, eğilim (bias) değeri eklenir. Hesaplanan değer aktivasyon fonksiyonuna girilerek bunun sonucu bir sonraki nörona iletir. Bu işlemler sürekli tekrar edilerek, sonunda çıktı katmanından çıktılar elde edilir. Geri yayılımda ise; çıktılardaki hatalardan elde edilen sonuçlara göre sinir ağındaki ağırlıkların yeniden güncellenmesi için kullanılır. Geri yayılımda optimizasyon, asıl sonuç ve istenilen sonuç arasındaki hata miktarını dikkate alarak, yapılan iyileştirme (İnik ve Ülker, 2017).

3.4 EVRİŞİMSEL SİNİR AĞLARI

Üç boyutlu şekillerin değişkenliğiyle başa çıkmak için özel olarak tasarlanmış birçok katmanlı derin öğrenme algoritması olup ilk olarak el yazısıyla posta kodlarını tanımak için kullanılmıştır (LeCun ve diğerleri, 1989). Bir ESA, bir resmi girdi olarak alıp, bu resimdeki objelere öğrenilebilir ağırlık ve eğilim (bias) değerleri atayarak sonrasında bunları birbirinden ayırt edebilir. Diğer derin öğrenme modellerine göre ağıın performansını artırmak amacıyla çok fazla deneme imkânı mevcuttur ve ağıın parametrelerinin ayarlanması daha kolaydır. ESA'da gerekli olan ön işleme, diğer sınıflandırma algoritmalarına kıyasla çok daha düşüktür. Büyük miktarda veri ile çalışabilmesi avantaj gibi görünse de yetersiz veri olan durumlarda performansı düşer. Şekil 3.3'te örnek bir ESA mimarisi gösterilmiştir.

Görüntüleri tespit ederek doğru bir şekilde sınıflandırmak için yapılan 2014 yılındaki ImageNet Yarışması'nda, en iyi dereceleri elde eden ekiplerin tamamı ESA algoritmaları kullanmışlardır (Girshick ve diğerleri, 2014). Olasılık sayısının en fazla olduğu oyun olan iki kişilik geleneksel Çin oyunu Go'da ESA tabanlı AlphaGo o dönem Dünya'nın en iyi ikinci oyuncusu olan Lee Sedol'ü yenmeyi başardı (Lee ve diğerleri, 2016).

ESA; giriş, evrişim, havuzlama ve tam bağlantılı katmanlar olmak üzere 4 temel katman ve bunların yanında bazı parametreler içerir. Bu bölümün devamında katmanlar anlatılmaktadır.



3.4.1 Giriş Katmanı

Veri kümesindeki görüntü, ses ve diğer verilerin ağıya verildiği, sinir ağının ilk katmanıdır. Görüntünün veri olarak kullanıldığı modellerde, bilgisayar giriş katmanına verilen girdiyi anlamlandırması için görüntüyü sayısal değerlere çevirmesi gerekir. Örneğin; radyografilerden oluşan ve standart boyuttaki (322x322 piksel) bir veri kümesini düşünürsek, siyah-beyaz yani gri seviye olan görüntüler 1 kanalı ile ifade edilip bilgisayarda [322x322x1] matris şekline dönüştürülür.

Eğer renkli görüntülerden oluşan bir veri kümesi söz konusu olursa renkler genellikle kırmızı, yeşil ve mavinin tonları ile 3 kanal olarak ifade edilir. Bu durumda önceki ile aynı boyutta bir veri kümesi olursa bilgisayarda [322x322x3] şeklinde matris olarak ifade edilir.

Görüntünün giriş boyutunun büyük seçilmesi, donanım yetersizliğine neden olup ağın eğitim süresini de olumsuz etkileyebilir. Bununla birlikte görüntülerde daha fazla öz nitelik çıkaracağından ağın performansını olumlu etkileyebilir. Giriş boyutu küçük seçilirse, daha az öz nitelik belirleneceğinden ağın performansı düşebilir. Bu değerlendirmeler göz önüne alınarak, giriş boyutu ön işleme ile değiştirilerek modele göre ayarlanabilir.


3.4.2 Evrişim (Konvolüsyon) Katmanı

Görüntü, video gibi veriler çok fazla parametre içermekte; bu nedenle sınıflama, regresyon gibi işlemlerin doğru şekilde sonuçlanmasını sağlamak için yapay sinir ağları modelini eğitmek çok zor olmaktadır. İlkel yapay sinir ağlarındaki bu parametre problemini çözmek için geliştirilen modellerden en verimli olanlarından biri ESA olup bunu sağlayan kritik katman ise evrişim katmanıdır. Evrişim işleminde verilerin bazı geri planda kalan özellikleri ayıklanarak modelin karmaşıklığı azaltılır.

Evrişim işlemi görüntüyü oluşturan piksellerin özelliklerinden oluşan bir matris üzerinde yapılır. Bu matris üzerinde belirli öznitelikleri ayıklayan filtreler kaydırılarak birbirine komşu matrisler elde edilir. Evrişim işlemi, filtrenin tüm giriş verisi üzerine uygulanmasıyla tamamlanarak öznitelik haritası çıkarılır. Evrişim işleminde, filtreyle işlem yapılan verinin ağırlığı ile filtrenin ağırlığı çarpılarak toplanır, her bir kanal için çarpımların toplamı alınarak elde edilen sonuca o katmanda bulunan eğilim (bias) faktörünün eklenmesiyle evrişim işlemi tamamlanmış olur. Evrişim katmanının ayırt edici parametreleri; filtre boyutu, adım sayısı, kanal sayısı ve aktivasyon fonksiyonudur.

Filtre (kernel), görüntüye yakın özelliklere sahip ise yüksek değerler elde edilirken, görüntüden çok farklı ise düşük değerler elde edilir. Filtreler yatay ve dikey olarak hareket ettirilir ve aynı bölgeden tekrar tekrar geçtiğinde filtrenin ağırlığı belirginleşeceğinden öğrenmeyi olumlu etkileyebilir (Murphy, 2012). Görüntülere farklı filtrelerin uygulanması ile filtrelere yakın özniteliklerin ayıklanması sağlanabilir. Filtreler, evrişim katmanında kullanılabileceği gibi havuzlama katmanında da kullanılabilir. Adım sayısı (stride), görüntü verisi üzerinde filtrenin soldan sağa veya yukarıdan aşağı hareket ettiği sıradaki yer değiştirme miktarını ifade etmektedir. Evrişim ve havuzlama katmanlarında kullanılmaktadır. Matris boyutu azaldıkça adım sayısı artar. Bu nedenle adım sayısı çıkış matrisinin boyunu etkilemektedir. Kanal sayısı, görüntünün özelliklerine göre değişir. Örneğin renkli görüntülerde genellikle üç kanal (kırmızı, yeşil ve mavi) vardır (Şekil 3.4). Adım kaydırma işlemi tüm kanallara uygulanır ve sonuçta çıkan toplam çıktı verisinin oluşmasında kullanılır.

Bazen evrişim işleminde çıkış matrisinin boyutunu ayarlamak için dolgu kullanılabilir. Bunda amaç giriş ve çıkış matrisinin aynı boyutta olmasıdır. Bu amaçla verinin dış çevresine ekstra pikseller eklenir. Bu pikseller en sık 0 değerlerinden oluştuğu için sıfır dolgu (zero padding) olarak da adlandırılır.



Şekil 3.4. Üç kanallı 5x5'den büyük bir girdinin sol üst kenarından başlanarak 3x3 boyutlu filtreye uygulanan evrişim işleminin ilk adımını gösterilmektedir. Ayrıca sıfır dolgulama işlemi de uygulanmıştır (WEB2).

3.4.2.1. Aktivasyon fonksiyonları


Aktivasyon fonksiyonu, sinir ağlarının sonuna veya arasına yerleştirilen bir düğümdür. Nöronun aktive edilip edilmeyeceğine karar vermeye yardımcı olurlar. Aktivasyon fonksiyonunun amacı çıktıyı belli bir aralıkta sınırlayarak sinir ağının daha hızlı sınıflama ve öğrenmesini sağlamaktır. ESA modellerinde en sık kullanılan aktivasyon fonksiyonları sigmoid, hiperbolik tanjant, düzeltilmiş doğrusal birim (ReLU), Sızıntı ReLU, üstel doğrusal birim (ELU) ve softmax'tır.

Sigmoid aktivasyon fonksiyonu, fonksiyon sonucunun 0 ile 1 arasında değer almasını sağlayan doğrusal olmayan sürekli bir fonksiyondur. Bu fonksiyonda uç değerlerin türevi 0'a yaklaştığı için optimizasyon zorlaşmakta ve güncelleme yavaş olmaktadır (Grafik 3.1). Sigmoid fonksiyonun denklemi;

$$F(x) = \frac{1}{1 + e^{-x}}$$


Hiperbolik tanjant (Tanh) fonksiyonu -1 ile +1 arasında çıktı değeri oluşturan bir fonksiyon olup sigmoid fonksiyonda olduğu gibi bunda da uç değerlerin türevi 0'a yaklaştığı için optimizasyon zordur (Grafik 3.2). Tanh fonksiyonunun denklemi;

$$F(x) = \frac{e^{2x} - 1}{e^{2x} + 1}$$




Grafik 3.1 Sigmoid fonksiyon ve türevi **Grafik 3.2** Tanh fonksiyonu ve türevi (Demir; 2021)

ReLU, adından da anlaşılacağı gibi lineer bir fonksiyon olup 0'dan küçük değer almaması için hazırlanan, girdi 0'dan küçük ve eşitse 0; büyükse girdinin kendisini çıktı olarak üreten bir fonksiyondur. Sonucun 0 çıktığı durumlarda türevin de 0 olması fonksiyonun kısıtlılığdır. Bu zorluğun giderilmesi amacıyla sızıntı ReLU (leaky ReLU) geliştirilmiştir. Bu fonksiyonda girdi 0'dan küçük ve eşitse 0,01 ile çarpımı çıktı olarak üretilir. ELU'da ise girdi 0'dan küçük ve eşitse üstel fonksiyonu kullanılır. Aşağıda ReLU, leaky ReLU ve ELU'nun fonksiyonları ve grafikleri gösterilmektedir (Grafik 3.3, grafik 3.4 ve grafik 3.5).




$$g(x) = \max(0, x)$$

Grafik 3.3 ReLU



$$g(x) = \max(\epsilon x, x)$$

Grafik 3.4. Leaky ReLU




$$g(x) = \max(\alpha(e^x - 1), x)$$

Grafik 3.5 ELU (Demir; 2021)

Birden fazla sınıflama yapılmasının istendiği durumlarda Softmax aktivasyon fonksiyonu kullanılır. Üstel bir fonksiyon olup tahminlere göre sınıflara olasılık dağılımını düzenler. Softmax fonksiyonunun denklemini ve grafiğini aşağıda verilmektedir (Grafik 3.6).

$$p = \begin{pmatrix} p_1 \\ p_2 \\ \vdots \\ p_n \end{pmatrix}$$


$$p_i = \frac{e^{x_i}}{\sum_{j=1}^n e^{x_j}}$$



Grafik 3.6 Softmax fonksiyonu
(Demir; 2021)

3.4.3 Havuzlama Katmanı


Bir konvolüsyon işleminden sonra boyut azaltmak için genellikle havuzlama yapılır. Böylece matrisin boyutu küçülür ve parametre sayısı azalır. Bu da eğitim süresini kısaltır, donanım gereksinimini azaltır ve aşırı öğrenmeyi (overfitting) engeller. Havuzlama katmanında en kritik nokta boyut azalırken önemli bilgilerin korunmasıdır. Özellikle, maksimum ve ortalama havuzlama, sırasıyla maksimum ve ortalama değer alındığı özel havuzlama türleridir. Genellikle bunlardan maksimum havuzlama tercih edilir (Şekil 3.5). Havuzlama katmanları iki evrişim katmanı arasında yer alır. Maksimum havuzlama yönteminde matristeki konum değişmeden yükseklik ve genişlik azaltılarak baskın özelliklerin çıkarılması modelin etkili bir şekilde eğitilme sürecini sürdürür.



Şekil 3.5. 2x2 filtre ve (2,2) adım kayması ile yapılan maksimum havuzlama işlemi
(WEB 3)

3.4.4 Tam Bağlantılı Katman

ESA'nın son adımı bu katmanda gerçekleşir. Önceki katmanlardan gelen öznelikler bu katmanda tek boyutlu bir vektör haline getirilir. Bu işleme düzleştirme (flattening) adı verilir. Bu katman öznelik ayıklama için değil sınıflandırma amacıyla kullanılır. Bu katmandaki her nöron, sonraki katmandaki tüm nöronlara bağlıdır, bu nedenle tam bağlantılı katman adını alır (Şekil 3.6). Tüm nöronlar birbirine bağlı olduğu için giriş nöronu tüm nöronları etkilemektedir. Tam bağlantılı katman sayısı bir veya daha fazla olabilir. Bu katmanda parametre sayısının fazla olması yüksek işlem gücü maliyeti yaratacağı için matrisin yükseklik ve genişliği azaltılırken kanal sayısı artırılır (Kuş ve diğerleri, 2019). Sonuç olarak evrişim ve havuzlama katmanlarından matris halinde geçen veriler bu katmanda düz bir vektör haline gelir.



Şekil 3.6. 4 sınıflı bir sonuç veren ESA modelinin tam bağlantılı katmanı (WEB 4)

3.5 ESA MODELİNİN OLUŞTURULMASI VE EĞİTİLMESİ

ESA modelini oluştururken evrişim katmanı, havuzlama katmanı, tam bağlantılı katmanın kaç adet olacağı ve nasıl sıralanacağı belirlenir. Giriş katmanı tek katmandan oluşur. Bu planlama işlemine ESA modelinin mimarisi adı verilir (Özkan ve diğerleri, 2017). Model planlandıktan sonra evrişim ve havuzlama katmanlarında kritik öneme sahip olan filtrelerin sayı ve boyutları, dolgu ve adım sayıları belirlenir. ESA modeli oluşturulduktan sonra belirli sayıda veri modele sunulur ve model eğitimi başlatılır. Verinin modeldeki tüm katmanlardan geçtikten sonra sonuç değeri

üretilmesine ileri besleme (forward propagation) adı verilir ki eğitimin birinci kısmını oluşturur. Daha sonra ESA'dan çıkan sonuçlar ile beklenen sonuçların farkı hata değerlerini oluşturur. Elde edilen hata değerlerine göre bu hata değerini azaltmak için ESA modelindeki evrişim katmanlarının ağırlıklarında güncellemeler yapılır. Bu işlem için ise geriye yayılım algoritması (back propagation) kullanılır ki bu da eğitimin ikinci basamağıdır.

3.5.1 Regülasyon (Düzenleme) Yöntemleri

Sinir ağında bazen eğitim doğruluğu, test doğruluğundan yüksek çıkabilir ve önemli olan test sonucu olduğu için bu eğitim sürecindeki sorunu göstermektedir. Bu durumun en sık nedenleri, ağırlık problemi ezberlemesi (overfitting) ve eğitim veri sayısının yetersiz olmasıdır. Bu durumu önleyen yöntemlere regülasyon (düzenleme) yöntemleri denir. Sık kullanılan düzenleme yöntemleri aşağıda sunulmaktadır.

3.5.1.1 Veri artırma (data augmentation)

ESA modelleri, eğitim için yüksek sayıda veriye ihtiyaç duymaktadır. Ağırlık eğitimi için yeterince veri bulunmadığında, veriler üzerinde kontrast ve parlaklık değiştirme, kırılma, döndürme, yansıtma, büyütme, küçültme gibi birtakım yöntemler uygulanarak veri artırılabilir. Eğitim verisinin artırılması genellikle ağırlık ezberlemesini azaltarak, test doğruluğunu artırmaktadır.

3.5.1.2 L1 / L2 düzenleme (L1/L2 normalization)

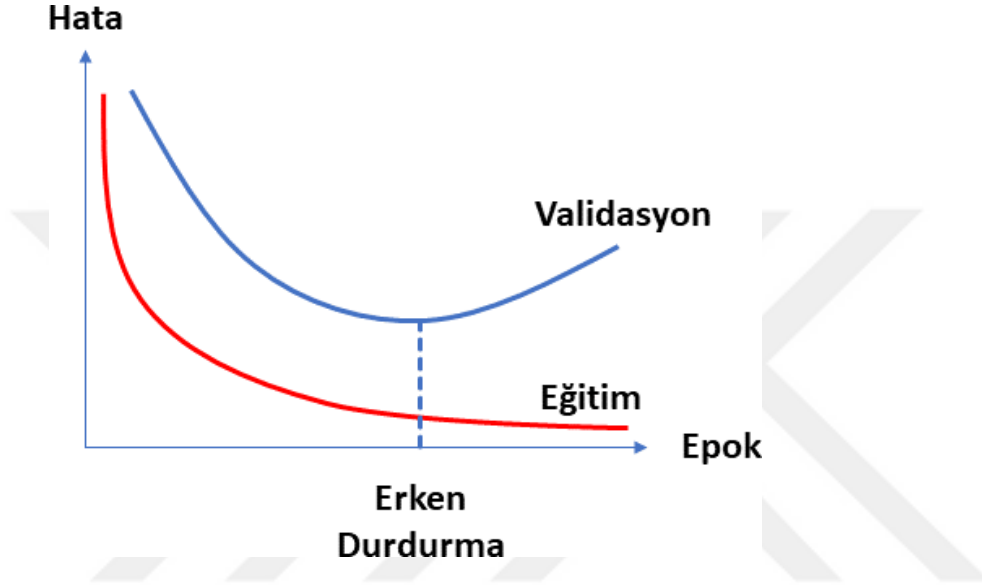
Eğitim sırasında verilerdeki aşırı uyum ve ezberlemeyi önlemek için kullanılır. L1 düzenleme yönteminde ağırlıkların mutlak değerlerinin toplamı düzenleme katsayısı (λ) ile çarpılıp, toplam hata fonksiyonuna eklenir. L2 düzenleme yöntemi ise en küçük kareler yöntemi olarak adlandırılmaktadır. Bu yöntemde veri kümesi ağırlık değerlerinin kareleri toplamı her satırda 1'e eşitlenir. Bu yöntemler ile modeldeki gereksiz karmaşıklığın azaltılması amaçlanır.

3.5.1.3 Bırakma (dropout regularization)

Bu yöntem aşırı uyum ve ezberlemeyi önlemek için kullanılmaktadır. Her epok sırasında evrişim katmanlarındaki belli sayıda nöronlar rastgele çıkarılır. Daha sonra elde edilen hata payları karşılaştırılarak gereksiz nöronların ağırlığının azaltılması sağlanır. Bu işlem tam bağlantılı katman ve çıkış katmanına uygulanmaz.

3.5.1.4 Erken durdurma (early stopping)

Eđitim verisinde, test sonuçlarına göre anormal fazla dođruluk olması ađın modeli ezberlediđi (overfitting) anlamına gelmektedir. Epok sayısına çok fazla olduđu durumda, ađın ezberlemeye bařladıđı anda eđitimin durdurulmasına erken durdurma denmektedir. Durdurma iřlemi validasyon dođruluđu referans alınarak yapılır (řekil 3.7).



řekil 3.7. Erken durdurma iřleminin grafik olarak gsterimi (kırmızı çizgi: eđitim hata fonksiyonu (loss function), mavi çizgi: validasyon hata fonksiyonu) (Demir, 2021)

3.5.2 Optimizasyon Yöntemleri

Sinir ađı modellerinde eđitim sonucundaki deđer ile beklenen deđer arasındaki farka (hata) göre katmanlardaki ađırlıklar güncellenir. Ađırlıkların düzeltilmesi için geriye yayılım algoritmaları kullanılır. ESA modellerinde bunun için kullanılan algoritmalar; stokastik gradyan azalma, momentumlu gradyan azalma, RMS-Prop, Adagrad ve Adam algoritmalarıdır.

3.5.2.1 Stokastik gradyan azalma

ESA modellerinde geriye yayılımda en sık kullanılan optimizasyon algoritması, stokastik gradyan azalma (stochastic gradient descent) algoritmasıdır. Maliyet fonksiyonunu en aza indirgeyerek, küçük adımlarla minimum noktaya yaklařma amaçlanmaktadır (Bottou, 2010). Formülü;

$$\omega^{yeni} := \omega^{eski} - \eta \nabla Q_i(\omega^{yeni})$$

Bu denklemde η : adım sayısı (learning rate); ω : ağırlık değerlerini temsil etmektedir. Ağırlıkların güncellenmesiyle birlikte hata azaltılarak ağırlık tahmin başarısının artması amaçlanır. Model eğitilirken ağırlıkların güncellendiği ve tüm veri kümesinin kullanıldığı her eğitim fazına epok, geçen süreye ise epok süresi adı verilir.

3.5.2.2 Momentumlu gradyan azalma (gradient descent with momentum)

Gradyan azalma yöntemlerinde öğrenme adımlarının en iyi sonuca doğru hızlı hareket etmesi ve ulaşılmak istenen hedefe yakın olması beklenir (Ruder, 2016). Geçmişteki öğrenme adımlarının ortalama hızının bir sonraki öğrenme adımının hızını sınırlamak için kullanıldığı yöntem momentumlu gradyan azalma denir. Bu yöntemde önceki gradyanların azalma ortalaması üstel fonksiyon ile tutularak yeni epokta ağırlık güncellemesi yapılır. Formülü aşağıda verilmiştir.

$$\Delta\omega(t) = - \eta \delta(t)$$

Bu denklemde t : momenti ifade etmekte olup 0 ile 1 arası değer almaktadır. 0'a yaklaştıkça ağırlık güncellemesi yapılmaz veya çok düşük oranda olur.

3.5.2.3 RMS-Prop (root mean square propagation) ve AdaGrad (adaptive gradient)

Uyarlanabilir öğrenme oranı temelli algoritmalarıdır. Öğrenme adımları süresince adım sayısı tüm parametreler için farklı uygulanır ve öğrenme oranı sonuçlara göre sürekli güncellenir. Son iki epoktaki ağırlık gradyanlarının farkına bakarak yakınsa küçük değişimler, uzaksa büyük değişimler yapılarak güncelleme olur (Goodfellow ve diğerleri, 2016). Bu şekilde uygulanan ortalama yaklaşımı ile yakınsama hızlanır. AdaGrad formülü aşağıda verilmektedir.

$$\omega_t = \omega_{t-1} - \eta' \frac{\partial}{\partial \omega_{t-1}} \quad \eta' = \frac{\eta}{\sqrt{\alpha_t + g}}$$

Bu formülde “ η'_t ” bu algoritmaları diğerinden ayıran kritik parametre olup değişen adım sayısını ifade etmektedir.

3.5.2.4 Adam (adaptive moment estimation)

Klasik stokastik gradyan azalma yöntemi yerine kullanılabilir daha verimli bir algoritmadır. Bu algoritmada da her parametrenin adım sayısı dinamik bir şekilde güncellenir ancak diğerlerinden farklı olarak yüksek bellek gereksinimlerine ihtiyaç duymaz (Ruder, 2016). RMS-prop ile AdaGrad'ın kombisyonu olarak görülebilir. Formülü aşağıda verilmektedir.

$$\omega_{t+1} = \omega - \alpha m_t \quad m_t = \beta m_{t-1} + (1 - \beta) \left[\frac{\delta L}{\delta \omega_t} \right]$$

Bu formülde m_t : güncel epoktaki gradyanların toplamı α : adım sayısı, β : hareketli ortalama parametre değerini ifade etmektedir. Bu metot ile hatanın minimuma yakınsaması (konverjansı) daha hızlı olmaktadır.

3.5.3 Transfer Öğrenme

Daha önceden farklı veri kümeleri ile eğitilmiş ESA'daki parametrelerin başlangıç parametresi olarak verilmesi ile yeni problemlerin çözümünde kullanılmasıdır. Transfer öğrenme sayesinde ağırlıkların güncellenmesi, yeniden eğitime gerek duymadan önceden eğitilmiş modeller üzerinden sağlanır. Bu nedenle donanım kaynağı kullanımı ve eğitim zamanı açısından tasarruf sağlanır. Dezavantajı ise, küçük veri setlerinde ezber (overfitting) problemi daha sık yaşanmasıdır. Bu durumda veri sayısını çoğaltmak için veri artırımı uygulamak faydalı olabilir.

3.6 PERFORMANS ÖLÇÜTLERİ

Eğitim aşamasının tamamlanmasının ardından modeller test için oluşturulmuş olan veri kümesi ile test edilir. Modelin performansı doğruluk (ing. accuracy), kesinlik (ing. precision), duyarlılık (ing. sensitivity), özgüllük, F1 skoru ve EAA gibi metrikler ile ölçülür. İkili sınıflamada performans ölçütlerinin elde edileceği dört olasılık vardır. Bu olasılıkların elde ettiği değerlerin oluşturduğu matrise karmaşıklık matrisi (ing. confusion matrix) denir (Tablo 3.1).

Tablo 3.1. Karmaşıklık matrisi

Toplam veri sayısı (DP+YN+YP+DN)	Tahmin pozitif	Tahmin negatif
Gerçek pozitif	Doğru pozitif (DP)	Yanlış negatif (YN)
Gerçek negatif	Yanlış pozitif (YP)	Doğru negatif (DN)

Yukarıdaki tabloya göre performans ölçütlerinin formülleri aşağıda sunulmuştur.

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

$$\text{Kesinlik (precision)} = \frac{DP}{DP + YP}$$

$$\text{Duyarlılık (recall)} = \frac{DP}{DP + YN}$$

$$\text{Özgüllük} = \frac{DN}{DN + YP}$$

$$\text{F1 Skoru} = \frac{2DP}{2DP + YP + YN}$$

3.7 ESA MODELLEMESİNDE KULLANILAN YAZILIMLAR

Bu bölümde, bu çalışmada sinir ağı oluşturmak için kullanılan kodlama dili, kütüphaneler, kodlamanın yapılmasına olanak sağlayan yazılım ortamları anlatılmaktadır.

3.7.1 Python

Python, dinamik semantik ile yorumlanmış, nesne yönelimli, birimsel, üst düzey bir programlama dilidir. Girintilere dayalı söz dizimi ve komut yapısı diğer programlama dillerine göre daha kolay öğrenilmesini sağlamıştır. Bilinen tüm işletim sistemlerinde (Windows, MAC-OS, Linux vs.) çalışabilmektedir. Dinamik yazma ve dinamik bağlama ile birleştirilmiş yüksek düzeyde yerleşik veri yapıları, python dilini hızlı uygulama geliştirme ve mevcut bileşenleri birbirine bağlayan köprü işlevi görece bir yazılım dili olması konusunda avantajlı kılmaktadır. Python, tüm işlevlerini tek bir çekirdekte barındırmak yerine, genişletilebilir modüller şeklinde tasarlandı. Özellikle web programlama, uygulama ve veri tabanı yazılımı programlama konularında en çok tercih edilen dil olması Python'u popüler hale getirdi.

İlk versiyonu Aralık 1989'da Guido van Rossum tarafından Amsterdam'da geliştirilmeye başlanmış olup Python 1.0 versiyonu Ocak 1994'te yayınlandı. Python 2.0 sürümü 16 Ekim 2000'de, Python 3.0 sürümü ise 3 Aralık 2008'de yayınlandı (WEB5). Python 3.x sürümü önceki sürümler ile uyumlu değildir ve Python 2.x serisinin son sürümü Python 2.7 ile birlikte geliştirilme süreci 1 Ocak 2020 itibariyle resmi olarak sona erdi (WEB6).

Dünya çapında bilinen Amazon, Google, Meta, Wikipedia, NASA, CERN gibi dev kurumlar, YouTube, Facebook, Instagram, Django, Mozilla, SurveyMonkey gibi uygulamalar Python kodlama dilini kullanmaktadır. Python, kendisi ile entegre çok sayıda kütüphane sayesinde veri bilimi konusunda, yapay zeka, derin öğrenme ve makine öğrenmesi modelleri oluşturmada en sık kullanılan kodlama dili oldu. 2003 yılından itibaren en popüler 10 programlama dilinden biri olan Python, özellikle web tabanlı uygulamaların yazılım sektöründeki hakimiyeti sonrası 2020 yılından itibaren en popüler kodlama dili unvanını ele geçirdi (WEB7).

3.7.2. Tensorflow

TensorFlow, makine öğrenmesi için geliştirilmiş olan uçtan uca açık kaynaklı ücretsiz yazılım platformudur. İlk olarak, makine öğrenmesi ve derin sinir ağları araştırması yapmak için Google Brain ekibi tarafından Makine Zekası Araştırma

organizasyonu için geliştirildi. TensorFlow'dan önce 2011'de Google Brain ekibi tarafından DistBelief geliştirildi. TensorFlow bu ekibin ikinci nesil kütüphanesi olup ilk sürümü 11 Şubat 2017'de GitHub'da yayınlandı (WEB8). TensorFlow adı sinir ağlarının tensör olarak adlandırılan çok boyutlu veri kümesi üzerinde gerçekleştirdiği işlemlerden türemiştir (WEB9). Ocak 2019'da Google, TensorFlow 2.0 sürümünü duyurmuş olup bu sürüm Eylül 2019'dan itibaren erişilebilir hale geldi. TensorFlow birden çok CPU, GPU veya TPU üzerinde düşük seviyeli tensör işlemlerini verimli bir şekilde yürütme özelliğine sahiptir. Programları sunucular, tarayıcılar, mobil ve gömülü cihazlar gibi harici çalışma zamanlarına aktarma işlemleri TensorFlow üzerinden yapılabilmektedir.

3.7.3. Keras

Keras, Google mühendisi François Chollet tarafından geliştirilen Python dili ile yazılmış açık kaynaklı bir yapay sinir ağı kütüphanesidir. 2015'te geliştirildikten sonra 2017 yılında TensorFlow'un çekirdek kütüphanesinde desteklenmeye devam etti. Microsoft tarafından da geliştirmeler yapıldı. TensorFlow arayüzü olarak kabul edilen Keras, modern derin öğrenmeye odaklı ve makine öğrenmesinde karşılaşılan sorunların çözmek için üretken bir arayüz sağlar. Keras, mühendis ve araştırmacılara TensorFlow 2'nin ölçeklenebilirlik ve platformlar arası geçiş özelliklerinden tam olarak yararlanmaları için yardımcı olur (WEB10).

BÖLÜM IV – KULLANILAN VERİ KÜMELERİ VE YÖNTEMLER

Çalışmanın dördüncü bölümünde, kullanılan veri kümesi ve uygulanan ESA modelleri ile ilgili bilgiler ayrıntılı olarak anlatılmaktadır.

4.1 VERİ KÜMESİ

Bu tezde yapılan retrospektif çalışma için etik kurul onayı Sağlık Bilimleri Üniversitesi Gazi Yaşargil Eğitim ve Araştırma Hastanesi Klinik Araştırmalar Etik Kurulu'ndan alındı (karar no: 2022/108, karar tarihi:10.06.2022). Etik kurul onayı alındıktan sonra veri kümesi için Diyarbakır Çocuk Hastalıkları Hastanesi radyoloji PACS (picture archiving and communication systems) arşivi kullanılarak 1 Ocak 2019 – 1 Haziran 2022 arasında poliklinikte ve acilde çekilen abdomen radyografileri tarandı. Tarama sırasında cerrahi öyküsü olan hastaların PACS sisteminde daha eski görüntüleri varsa onlar da çalışmaya dahil edildi. Poliklinikte ve acil serviste kullanılan her iki röntgen cihazı da tek tüplü Jumong modeli dijital X-ray görüntüleme sistemidir (SG Healthcare co, Gyeonggi-Do, Güney Kore).

Veri kümesi; 1) cerrahi endikasyonu olan GİS obstrüksiyonu hastalar, 2) cerrahi gerektirmeden tedavi olan bağırsak genişlemesi / ileus hastaları ve 3) normal kontrol grubu olmak üzere üç ana gruptan oluşmaktadır. Olguların yaş, cinsiyet özellikleri, patolojik bulguları olan gruplar için hastalık tanıları kaydedildi. Yaş için ortalama ve standart sapma değerleri, ortanca ve çeyrekler hesaplandı. Patolojik grupların istatistiksel karşılaştırması yapıldı. Cinsiyet verilerinin karşılaştırmasında Pearson ki-kare testi kullanıldı. Yaş verilerinin normal dağılım göstermediği Kolmogorov-Smirnov testi ile gösterildi (tüm gruplar için $p < 0,001$). Patolojik grupların karşılaştırılmasında normal dağılım göstermediği için non-parametrik olarak kabul edilerek Mann-Whitney U testi uygulandı. İstatistiksel analizler IBM SPSS versiyon 23.0 (IBM Corporation, Armonk, NY, ABD) paket programı kullanılarak yapıldı.

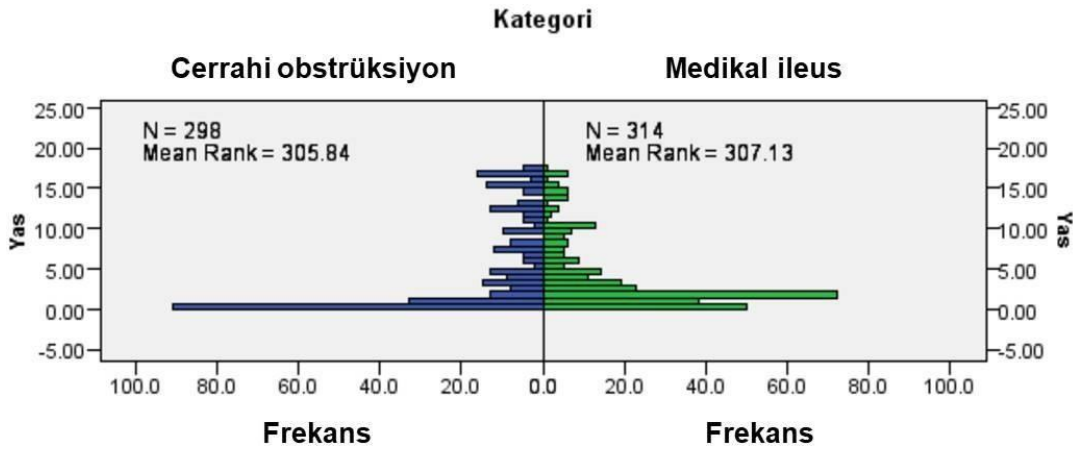
Anormal bulguları olan iki grup birlikte değerlendirildiğinde toplamda 612 radyografi vardır. İlk grup (cerrahi olan hastalar) için arşivde 107 hastanın 298 görüntüsü, ikinci grup (cerrahi gerektirmeyen hastalar) için 189 hastanın 314

görüntüsü taramada elde edildi. Karşılaştırma için ise yaş dağılımının 0 – 18 yaş arasında dengeli dağılımı göz önünde bulundurularak 540 normal abdomen radyografisinden oluşan kontrol grubu oluşturuldu. Gruplara göre verilerin yaş ve cinsiyet özellikleri Tablo 4.1’de sunulmaktadır.

Tablo 4.1. Veri kümesindeki vakaların gruplara göre yaş ve cinsiyet özellikleri

	Normal	Cerrahi gerekli GİS obstrüksiyonu	GİS enfeksiyonu veya medikal ileus
Cinsiyet [erkek (%) / kız (%)]	262 (%48,5) / 278 (%51,5)	232 (% 77,5) / 66 (%22,1)	180 (%57,3) / 134 (%42,7)
Yaş (ortalama ± standart sapma)	7,29 ± 5,05 yıl	5,47 ± 5,82 yıl	4,22 ± 4,44 yıl
Yaş (ortanca ve çeyrek sapmalar)	6,5 yıl (3,1 – 11,3)	3 yıl (0,3 – 10)	2,1 yıl (1,3 – 6)

Patolojik bulguları olan iki grup karşılaştırıldığında cerrahi obstrüksiyon vakaları, diğer dilatasyon vakalarına göre erkeklerde anlamlı olarak daha fazla görülmektedir ($p < 0,001$). İki grubun yaşları karşılaştırıldığında ise anlamlı fark saptanmadı ($p = 0,928$). Patolojik grupların yaş dağılımı Şekil 4.1’de gösterilmektedir.




Şekil 4.1 Veri kümesindeki patolojik grupların yaş dağılımı

Cerrahi obstrüksiyon grubunda olan hastalarda toplamda 16 farklı obstrüksiyon nedeni saptandı. En sık etken olan brid ileus/postoperatif adhezyonlar 27 hastanın 83 radyografisinde (% 27.9) görülürken ikinci en sık 30 hasta ve 67 radyografi (% 22.5) ile komplike apandisit, üçüncü en sık etken ise 11 hasta ve 35 radyografi (% 11.7) ile nekrotizan enterokolit oldu. Sıklık sırasına göre diğer etyolojiler; hipertrofik pilor stenozu [12 hasta, 19 radyografi (% 6.4)], Hirschsprung hastalığı [7 hasta, 15 radyografi (% 5)], intraperitoneal kateter enfeksiyonuna sekonder apse/peritonit [5 hasta, 15 radyografi (% 5)], mekonyum ileusu/mekonyum tıkaç sendromu [5 hasta, 12 radyografi (% 4)], duodenal atrezi [2 hasta, 11 radyografi (% 3.7)], invajinasyon [9 hasta, 9 radyografi (% 3)], inguinal herni [4 hasta, 8 radyografi (% 2.7)], komplike Crohn hastalığı [2 hasta, 8 radyografi (% 2.7)], intestinal malrotasyon/midgut volvulus [3 hasta, 6 radyografi (% 2)], Burkitt lenfoma [1 hasta, 5 radyografi (% 1.7)], Meckel divertikülü [1 hasta, 2 radyografi (% 0.7)], ileal atrezi [1 hasta, 2 radyografi (% 0.7)] ve perfore duodenal ülser [1 hasta, 1 radyografi (% 0.3)] şeklindedir. Brid ileus/postoperatif adhezyon vakalarının bazıları diğer gruptaki hastaların ameliyatlarından sonra takipte görüldüğü için grupların vaka sayıları toplandığında bu gruptaki toplam hasta sayısından yüksek çıkmaktadır. Hastalık tiplerine göre yaş ve cinsiyet dağılımı tablo 4.2’de sunulmaktadır.

Hastalıklara göre hastaların yaş dağılımı grafik olarak şekil 4.2’de gösterilmektedir. Nekrotizan enterokolit, hipertrofik pilor stenozu, mekonyum ileusu, Hirschsprung hastalığı, duodenal atrezi/stenoz ve inguinal herni olguları yenidoğan ve infant döneminde görülürken, intraperitoneal katetere sekonder apse/peritonit ve invajinasyon olguları küçük çocukluk döneminde, komplike apandisit ve Crohn hastaları ise ağırlıklı olarak 10 yaş üstü grupta görülmektedir. En geniş yaş dağılımına sahip hastalık grupları aynı zamanda en sık görülen iki hastalık olan brid ileus/postoperatif adhezyon ve komplike apandisit olgularıdır. Sık görülen hastalıklardan yaşları birbirine yakın olan gruplar istatistiksel olarak student T testi ile karşılaştırıldı. Komplike apandisit vakalarının yaşları, brid ileusa göre anlamlı olarak daha yüksek ($p < 0.001$), nekrotizan enterokolit vakalarının yaşları hipertrofik pilor stenozuna göre anlamlı olarak daha yüksek ($p = 0.003$) izlendi. Brid ileus olguları ile kateter enfeksiyonları ($p = 0.379$) ve Hirschsprung hastalığı ile duodenal atrezi/stenoz arasında ($p = 0.719$) arasında ise anlamlı fark saptanmadı.

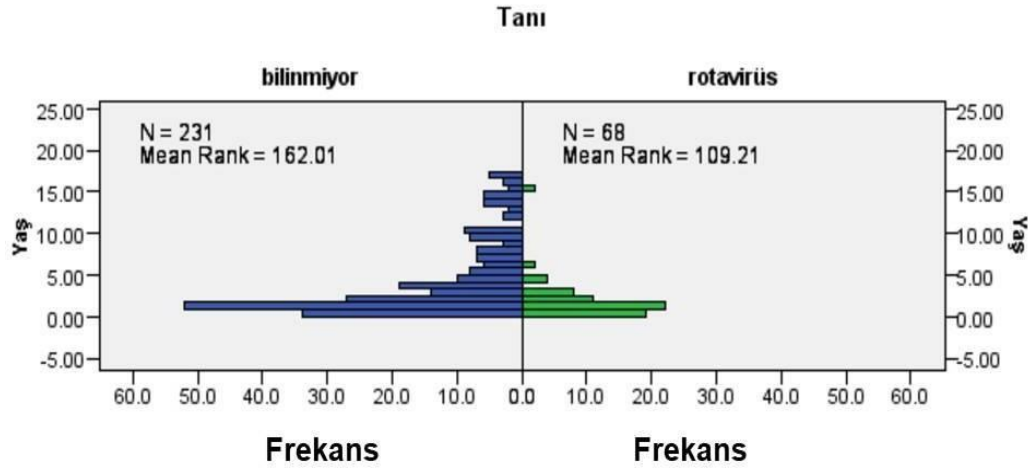
Tablo 4.2. Cerrahi gerektiren vakaların tanılara göre sayısı, yaş ve cinsiyet özellikleri

Tanı	Vaka / radyografi sayısı	Cinsiyet (kız / erkek)	Yaş (ortalama ± standart sapma) (yıl)
Brid ileus/ postoperatif adhezyon	27 / 83	5 (% 18.5) / 22 (% 81.5)	6.48 ± 5.32
Komplike akut apandisit	30 / 67	8 (% 26.7) / 22 (% 73.3)	11.33 ± 4.75
Nekrotizan enterokolit	11 / 35	6 (% 54.5) / 5 (% 45.5)	0.39 ± 0.53
Hipertrofik pilor stenozu	12 / 19	0 / 12 (% 100)	0.11 ± 0.06
Hirschsprung hastalığı	7 / 15	1 (% 14.3) / 6 (% 85.7)	1.02 ± 1.38
İntraperitoneal katetere sekonder apse/peritonit	5 / 15	1 (% 20) / 4 (% 80)	5.13 ± 6.08
Mekonyum ileusu/ mekonyum tıkaç	5 / 12	1 (% 20) / 4 (% 80)	0.34 ± 0.27
Duodenal atrezi/stenoz	2 / 11	1 (% 50) / 1 (% 50)	1.15 ± 0.10
İnvajinasyon	9 / 9	4 (% 44.4) / 5 (% 55.6)	3.18 ± 4.41
İnguinal herni	4 / 8	0 / 4 (% 100)	0.95 ± 0.78
Komplike Crohn hastalığı	2 / 8	0 / 2 (% 100)	11.89 ± 1.48
Midgut volvulus	3 / 6	0 / 3 (% 100)	1.80 ± 2.26
Diğer	4 / 9	0 / 4 (% 100)	6.87 ± 4.79



Şekil 4.2 Cerrahi gerektiren bağırsak dilatasyonu grubundaki hastaların etyolojilerine göre yaşlarının dağılımı [x eksen: hastalıklar, y eksen: yaş (yıl)]

Üçüncü grup olan GİS enfeksiyonları / medikal ileus olgularında, 231 (%73.6) radyografinin elde edildiği 142 hastada enfeksiyon etkeni saptanmazken, 68 (%21.7) radyografinin elde edildiği 41 hastada rotavirüs antijeni, 3 (% 1) radyografinin elde edildiği 2 hastada adenovirüs antijeni, 6 (% 1.9) radyografinin elde edildiği 2 hastada dışkıda amip saptandı. Altı radyografisi bulunan 2 hastada (% 1.9) ise COVID-19'a bağlı MIS-C (multi inflamatuvar sendrom – Covid 19'a sekonder) hastalığının GİS tutulumu tanısı kondu. En sık iki grup olan rotavirüs vakaları ile tanı konulamayan olguların yaşları karşılaştırıldığında rotavirüs olgularının anlamlı olarak daha küçük yaş gruplarında olduğu görüldü ($p < 0,001$) (Şekil 4.3)



Şekil 4.3 Cerrahi olmayan bağırsak dilatasyonu olan grupta etken bulunamayan hastalar ile rotavirüs olgularının yaşlarının karşılaştırılması

4.2 ÇALIŞMADA KULLANILAN ESA MODELLERİ


Çalışmamızda öncelikle eğitilmiş (pre-trained) ve açık kullanıma sunulan ESA mimarileri ile veriler analiz ve test edilmiştir. Çalışmada kullanılan ESA modelleri aşağıda sıralanmaktadır.

4.2.1 ResNet50

Temel ESA mimarilerinde etkinliği artırmak için katman sayısı (derinlik) artırılır. Ancak özellikle görüntü sınıflandırmada derinlik artırıldıkça belli bir noktadan sonra etkinlik (accuracy) doygunluğa ulaşır, hatta daha da artırılırsa düşmeye başlar. ResNet mimarisini oluşturan araştırmacılar bunun sebebini overfitting'e değil, optimizasyonda oluşan sorunlara bağlı olan eğitim hatasına (training error) bağlamıştır (He ve diğerleri, 2016). ResNet'in amacı bu performans düşüşünü önlemek olup bunun için artık sinir ağları eklemeyi önermiştir. Artık sinir ağlarını optimize ederek eğitim hatasının önüne geçileceği öngörülmektedir. Artık sinir ağları, iki katman arasında bağlantı kuran kısa yollar şeklinde mimariye dahil edilir ve her konvolüsyondan sonra düzleştirilmiş doğrusal birim (ReLU) aktivasyonunun kullanıldığı alt örnekleme işlemi olarak çalışır. Bu artık nöral ağların kullanılabilmesi için giriş ve çıkış boyutları aynı olmalıdır. Boyut değişimi

uygulanan katmanlarda ya artık nöral ağ kullanılmaz veya 1x1 evrişim ile boyut eşleşmesi uygulanır. İki durumda da adım sayısı değişmez. He ve diğ. hazırladığı ve ImageNet veri kümesi üzerinde denediği ResNet50 mimarisi Şekil 4.4’te gösterilmiştir (He ve diğerleri, 2016).

ResNet50 modeli ImageNet veri tabanı üzerindeki etkinliği ile 2015’teki ImageNet yarışmasını kazandı. Ancak işlem süresi, Inception modellerine göre daha uzun sürmektedir.




Şekil 4.4 ResNet50 model mimarisi. Burada stage 1’de 3, stage 2’de 4, stage 3’de 6 ve stage 4’de 3 artık sinir ağı (deep residual network) kullanılarak toplamda 50 katman oluşturulmuştur (He ve diğerleri, 2016).

4.2.2 Inception

Genel olarak Inception mimarisinin temelini oluşturan fikir 2013 yılında yayınlanan “The network in network” makalesi ile ortaya çıkmış olup ilk Inception modeli (Inception v1) aynı zamanda GoogleNet olarak da bilinir ve 2015 yılında Google Brain ekibi tarafından tasarlanmıştır (Lin ve diğerleri, 2013, Szegedy ve diğerleri, 2015). Bu ağın mimarisindeki amaç, ağın derinliğini artırarak işlem sayısını düşürmektir. Temel ESA mimarilerinde sırasıyla ilerleyen evrişim, havuzlama ve tam bağlantılı katmanlar ile ESA modelinin gücü katman sayısı değiştirilerek ayarlanır. Ancak havuzlama katmanındaki veri kaybı ve çözünürlük kaybı ayrıca katman artışının beraberinde getirdiği “overfitting” sorunu değişik veriler içeren veri kümelerinde sorun oluşturabilir. Bunun için Inception modelinde performans gereksinimini artırmadan ağ içinde ağ katmanları oluşturulmuştur.

Ağ içinde ağ mimarisi oluşturmak için tam bağlantılı katman yerine seyrek bağlantılı katmanlar oluşturulmuştur (Szegedy ve diğerleri, 2015). Burada önemli nokta ağ içindeki lokal mimarilerin seyrek bağlantılarının optimal ayarlanması ve sonraki katmanda hepsinin toplanacağı filtreleme algoritmasına sunulmasıdır. Burada parametre sayısına göre 1x1, 3x3, 5x5 boyutlarında evrişim sağları sunulmuştur ancak boyut arttıkça işlem sayısı da çok artmakta ve verim azalmaktadır. Bu nedenle çok boyutlu katmanların olduğu ağların içine 1x1 evrişim katmanları da eklenerek kompresyon oluşturulmuştur (Şekil 4.5).

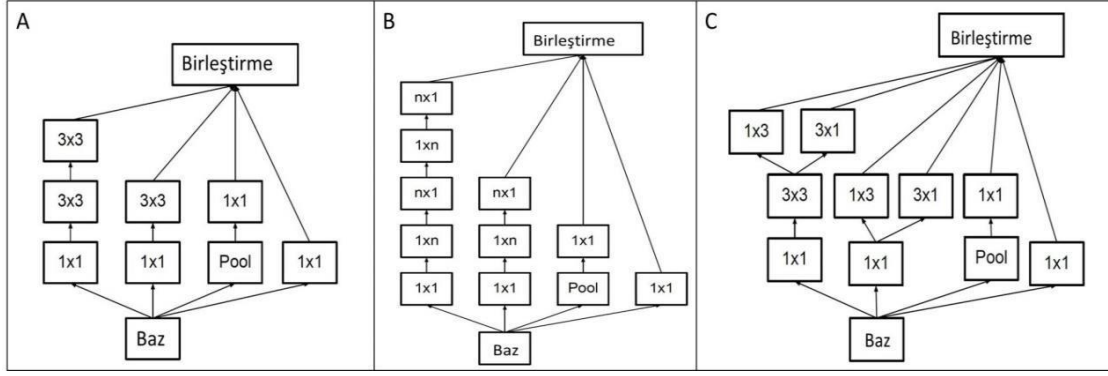


Şekil 4.5 ESA mimarisi içinde oluşturulan temel Inception katmanı (A), ve bu katmana boyut küçültme uygulanması sonrası oluşturulan model (B) (Szegedy ve diğerleri, 2015).

Daha sonra geliştirilen Inception sürümlerinde veri kaybını en aza indirmek, verimliliği artırmak ve bunu da en düşük zaman ve performans maliyeti ile elde etmek için boyut küçültme yöntemlerinde değişik mimariler denendi. Burada aşamalı boyut küçültme (ör. her 5x5 yerine sırasıyla 2 adet 3x3 evrişim katmanı koymak gibi) yöntemleri denenmiş ve olumlu sonuçlar elde edildi. Son geliştirilen Inception v3 modeli (Tablo 4.3) üç adet Inception ağ katmanı (Şekil 4.6) içermekte olup toplamda 42 katmandan oluşmaktadır (Szegedy ve diğerleri, 2016).

Tablo 4.3 Inception v3 model mimarisi

Tip	Yama boyutu/ adım sayısı	Girdi boyutu
Evrişim	3x3/2	299x299x3
Evrişim	3x3/1	149x149x32
Evrişim	3x3/1	147x147x32
Havuzlama	3x3/2	147x147x64
Evrişim	3x3/1	73x73x64
Evrişim	3x3/2	71x71x80
Evrişim	3x3/1	35x35x192
3x Inception	Şekil 4.6A	35x35x288
5x Inception	Şekil 4.6B	17x17x768
12x Inception	Şekil 4.6C	8x8x1280
Havuz	8x8	8x8x2048
Lineer	Logits	1x1x2048
Softmax	Sınıflayıcı (classifier)	1x1x1000



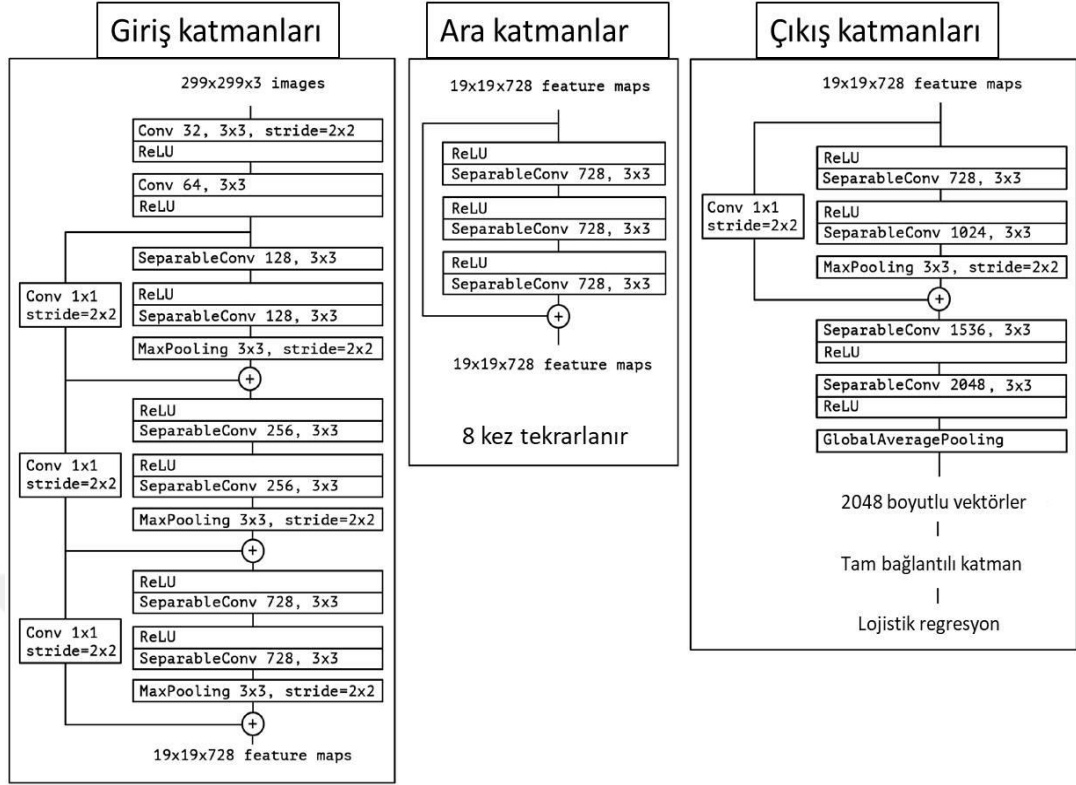
Şekil 4.6 Inception v3 modelindeki Inception katmanlarının mimarisi (Szegedy ve diğerleri, 2016)

4.2.3 Xception

Xception modeli Inception modelleriyle aynı mantık üzerine hazırlanan bir ESA mimarisi olup François Chollet tarafından geliştirilmiştir (Chollet, 2017). Bu modelde parametre sayısı aynı tutulup Inception katmanlarındaki üst üste gelme (overlapping) önlenmeye çalışılarak verimliliğin artırılması amaçlanmıştır. Bu nedenle inception katmanları ayrılmadan önce tüm katmanlar için kullanılan ortak 1x1 evrişim katmanı ve üstüne bir uzaysal evrişim (spatial convolution) katmanı eklenmiştir. Uzaysal evrişim katmanı içinde derinlik temelli (depthwise convolution) ve nokta temelli (pointwise convolution) evrişim algoritmaları kullanılarak belirli girdiler belirli inception modüllerine yönlendirilir. 36 katmandan oluşan Xception modelinin mimarisi Şekil 4.7’de sunulmaktadır.

4.2.4 EfficientNet

Bu modeli oluşturan araştırmacılar ESA modelinde verimliliğin artırılması için en önemli ölçütlerin derinlik, genişlik ve çözünürlük arasındaki dengenin korunması olduğunu düşünmektedir (Tan ve Le, 2019). Bu mantıkla temel olarak hazırladıkları EfficientNet-B0 modeline (Tablo 4.4) sabit üstel oranlarla derinlik, genişlik ve çözünürlük artırımını yapılarak EfficientNet-B1-7 modelini tasarlayıp sundular. Çok daha düşük parametre sayısı içeren bu modelle ResNet, Inception, Xception ve AmeobaNet gibi modellere göre farklı görüntü veri kümeleri üzerinde yapılan sınıflandırma çalışmalarında daha yüksek etkinlik elde ettiler (Tan ve Le, 2019).



Şekil 4.7 Xception model mimarisi. Ara evrişim katmanları 8 kez tekrarlanmaktadır ve tüm Conv ve SeperableConv katmanlarından sonra şekilde gösterilmeyen düzenleme (batch normalization) uygulanmaktadır (Chollet, 2017).

Bu mimari ile temel modelin (EfficientNet-B0) üzerine sabit oranı değiştirilerek eldeki donanım ve süre imkanlarına göre optimal modelin kolayca oluşturulması sağlanabilmektedir.

4.2.5 ConvNeXt


İlk olarak doğal dil işleme işlemleri için kullanılan ve 2017’de makine öğrenme modellerine entegre edilen “transformers”lar özellikle çeviri ve arama motorlarında çok başarılı oldu. Transformer bir girdi olarak verilen bir diziyi, kodlayıcı (encoder) ve kod çözücü (decoder) yardımıyla çıktı olarak sunulacak bir başka diziyi dönüştürmek için kullanılan bir mimaridir (Vaswani ve diğerleri, 2017). Burada girdi olarak verilen dizinin belli noktalarına seçici olarak odaklanması ve komşuluklarına göre skaler çarpımlarla ağırlıklar atanması transformers’ın daha hızlı, etkin ve paralel işlem yapabilmesine olanak sağlar.

Tablo 4.4 EfficientNet-B0 model mimarisi (Tan ve diğeri, 2019)

Tip	Yama boyutu	Çözünürlük	Kanal	Katman sayısı
Conv	3x3	224x224	32	1
MBCConv1	3x3	112x112	16	1
MBCConv6	3x3	112x112	24	2
MBCConv6	5x5	56x56	40	2
MBCConv6	3x3	28x28	80	3
MBCConv6	5x5	14x14	112	3
MBCConv6	5x5	14x14	192	4
MBCConv6	3x3	7x7	320	1
5x Inception	1x1	7x7	1280	1
Conv	1x1	7x7	1280	1
Tam bağlantılı katman	1x1	7x7	1280	1

Transformers'ın doğal dil işleme süreçlerindeki başarısıyla birlikte yapay zeka araştırmacıları bu modelleri bilgisayarlı görü alanına entegre etmek istediler. Shifted windows transformer (SWIN Transformer) hiyerarşik yapıda olan bir transformer modeli olup görüntüyü RGB piksel değerlerine göre katmanlarına ayıran ve her katmanda değişen pencerelerdeki örtüşmeyen kısımlara odaklanarak bunlara değer atayan bir modeldir. Bu modelde ESA'larda sıklıkla kullanılan ReLU yerine Gaussian hata doğrusal birim (GELU) non-lineer aktivasyon fonksiyonu ile girdilere ağırlık değeri verilir (Liu ve diğeri, 2021).

ConvNeXt modeli, ResNet50 modelinin uyarlaması olup her aşamadaki artık sinir ağları yerine transformers modeli, buna bağlı olarak ReLU yerine GELU aktivasyon fonksiyonları oluşturulmasıyla hazırlanmıştır (Liu ve diğerleri, 2022). ConvNeXt'in ESA model mimarisi Şekil 4.8'te gösterilmektedir. ResNet50 modeli girişte 7x7 boyutlu giriş katmanı kullanırken, Swin Transformer 4x4 boyutlu 4 adımlı giriş katmanı kullanmaktadır ki bu durum yamaların örtüşmesini öneler. Bir diğer fark ise yığın düzenleme (batch normalization) yerine katman düzenleme (layer normalization) kullanılmasıdır.




Şekil 4.8 ConvNeXt model mimarisi. Burada stage 1'de 3, stage 2'de 3, stage 3'de 9 ve stage 4'de 3 blok kullanılarak toplamda 56 katman oluşturulmuştur (Liu ve diğerleri, 2022).

4.2.6 Deneyde Modellere Yapılan Eklemeler ve İnce Ayar (İng. Fine Tuning)

Bu tezde, transfer öğrenme metoduyla kullanılan ve yukarıda anlatılan ESA modelleri, kendi veri kümemiz ile tekrar eğitildi. Daha sonra Bölüm 5'te detaylı anlatılan veri artırma işlemleri uygulandı.

Transfer öğrenme ile kullanılan ESA modellerinin önceden eğitildiği veri kümeleri, çok fazla sayıda veri içerdiği için bizim veri kümemiz ile eğitimi sırasında, öznelik çıkarımı için filtre ağırlıklarının belirlenmesi süreci ilk birkaç evrişim basamağında (genellikle ilk üç) sınırlı kalmakta, son basamakların eğitimi gerçekleşmemektedir (Tajbakhsh ve diğerleri, 2016). İnce ayar (fine tuning) adı verilen işlemde girdiye yakın basamaklar dondurularak sonraki basamakların öznelik çıkarımı için ağırlık belirlenmesinin sağlanması amaçlanır. İnce ayar, özellikle doğal dil işleme ve görüntü analizi için kullanılan transfer öğrenme yöntemlerinde rutin olarak

uygulanmakta ve modelin performansını artırmaktadır. Epok süreleri normal eğitim sürecine göre daha uzun olmakla birlikte daha az epok sayısı ile eğitim ve validasyon hatalarında belirgin düşüş sağlanır (Şekil 4.9).



Şekil 4.9 Tezimizde veri kümesinin ResNet50 modelinde eğitim ve ince ayar epoklarının eğitim ve validasyon hata grafiği. Dikey yeşil çizgiden sonraki epoklar ince ayar işlemine ait olup bu dönemdeki hata düşüşü çok daha belirgindir.

BÖLÜM V – BULGULAR

Bu bölümde yapılan işlemlerin ve deneylerin sonuçları sunulacaktır.

5.1 VERİ KÜMESİNİN ÖN İŞLEMESİ

Hasta (612 radyografi) ve kontrol (540 radyografi) grubu olmak üzere iki sınıfta toplam 1.152 görüntü, 160x160 piksel boyutlarına indirgenerek her birinde 36 görüntü olan 32'lik paketler (İng. Batch) haline getirildi. Sonraki adımda her paket için 28 eğitim, 3 validasyon ve 5 test verisi olarak üçe bölündü.


5.1.1 Veri Artırma

Eğitim verileri için veri artırma işlemi uygulandı. Veri artırılırken problem alanıyla ilgili uygun yöntem seçilmelidir. Aksi halde veri artırımı ağın başarısını azaltırken, ağın eğitim için geçen zaman ve donanım maliyetlerini de beraberinde getirmektedir. Bu çalışmada veri artırma yöntemlerinden yatay yansıtma (horizontal flip) ve rotasyon işlemleri keras kütüphanesi kullanılarak uygulandı (Şekil 5.1). Bu işlemler ile elde edilen görüntüler, çekim sırasında hasta dönüklüğüne bağlı uygun pozisyonda çekilmeyen ve PACS sistemine ters gönderilen görüntüler ile benzer olacaktır. Bu sayede uygun olmayan görüntülerin model tarafından değerlendirilebilmesi için de esneklik sağlanması hedeflendi. Dönüştürülen görüntüler sadece eğitim sırasında aktif olarak kullanılır ve bellekte saklanmaz.

Deneylerde kullanılan beş model de eğitim aşamasında 100 epok çalıştırıldı. Transfer öğrenme sırasında performansı artırmak ve başka veri kümesi ile eğitilen modellerin kendi verilerimizin özneliliklerine adapte olabilmesi için ince ayarlama amacıyla 20 epok daha çalıştırıldı.

5.1.2 Kırpma

Veri kümesindeki röntgen görüntüleri hastaların çekim sırasındaki pozisyonu, görüntü alanına giren vücut kısımlarının genişliği, vücudun görüntü alanının tamamına oranı (çekim alanının optimizasyonu), çekim sırasında hastanın üzerindeki materyaller, daha önceki çekimlerden bağırsak içerisinde kalan ve kontrast oluşturan




Şekil 5.1 Çalışmada kullanılan veri artımı yöntemlerinden yatay yansıtma ve döndürme örnekleri

materyaller gibi birçok etken nedeniyle homojen yapıda değildi. Çekim bölgesinin standardizasyonunun modelin başarısına etkisini belirlemek için ön işleme aşamasında verilere hazırlanan bir kod ile otomatik olarak kırpma işlemi uygulayarak veri kümesi oluşturduk. Kırpma işlemi yapan kodda kriterimizi, tüm kenarlardan başlayarak tamamı siyah olan satır veya sütunları beyaz tonda piksel buluncaya kadar kırpmak şeklinde belirledik (Şekil 5.2). Otomatik kırpma işlemi sırasında bazı görüntülerde görüntü üzerindeki veri etiketleri modelin görüntüye ulaşmadan önce kırpmayı durdurmasına neden oldu. Bu durum, manuel kırpma işlemine göre uyguladığımız modelin kısıtlılığını oluşturmaktadır (Şekil 5.3).



Şekil 5.2. Veri kümemiz içerisindeki ham görüntü (A) örneği ile bu görüntüye otomatik kırılma işlemi yapıldıktan sonraki hali (B).



Şekil 5.3. Veri kümemiz içerisindeki görüntü (A) örneğinde sol alt taraftaki etiket yazıları nedeniyle alttan ve soldan kırılma işlemi istenildiği gibi olmayan kırılmış görüntü örneği (B) gösterilmektedir.

Bu çalışmanın klinik kullanımında röntgen çekimi ile elde edilen görüntünün otomatik ön işleme ve model analizi ile sınıflandırma sonucunun direk olarak hekimesunulması amaçlandığı için manuel kırılma işlemi tercih edilmedi.

5.2 ESA MODELLERİ İLE SINIFLANDIRMA SONUÇLARI

Bu deneyde önce ham veriler, sonra kırılmış veriler ile normal kontrol ve anormal hasta grubu modele sunuldu. Daha sonra iki hasta grubu kırılmış haliyle ikili sınıflama açısından aşağıda belirtilen modellere transfer öğrenme metodu ile sunuldu. Eğitim için 100 epok, ince ayarda (fine tuning) ise 20 epok çalıştırıldı.

Elde edilen sonuçların karmaşıklık matrisleri sırasıyla ResNet50 modeli için Tablo 5.1, InceptionResNetV2 modeli için Tablo 5.2, Xception modeli için Tablo 5.3, EfficientNetV2L modeli için Tablo 5.4 ve ConvNeXtXLarge modeli için Tablo5.5'te sunulmaktadır.

Tablo 5.1 ResNet50 modeliyle yapılan sınıflandırmaların karmaşıklık matrisleri

		Gerçek Değeri		
			Normal	Hasta
Tahmin Değeri	İşlenmemiş görüntüler	Normal	109	15
		Hasta	0	100
	Kırılmış görüntüler	Normal	109	7
		Hasta	3	105
	Kırılmış görüntüler	Cerrahi hastaları	117	4
		Diğer GIS dilatasyonları	21	82

Tablo 5.2 InceptionResNetV2 modeliyle yapılan sınıflandırmaların karmaşıklık matrisleri

		Gerçek Değeri		
			Normal	Hasta
Tahmin Değeri	İşlenmemiş görüntüler	Normal	103	3
		Hasta	18	100
	Kırılmış görüntüler	Normal	119	1
		Hasta	9	95
	Kırılmış görüntüler	Cerrahi hastaları	106	6
		Diğer GIS dilatasyonları	16	96

Tablo 5.3 Xception modeliyle yapılan sınıflandırmaların karmaşıklık matrisleri

Gerçek Değeri				
Tahmin			Normal	Hasta
Değeri	İşlenmemiş görüntüler	Normal	120	10
		Hasta	28	66
	Kırılmış görüntüler	Normal	100	17
		Hasta	13	94
	Kırılmış görüntüler	Cerrahi hastaları	104	21
		Diğer GIS dilatasyonları	7	92

Tablo 5.4 EfficientNetV2L modeliyle yapılan sınıflandırmaların karmaşıklık matrisleri

Gerçek Değeri				
Tahmin			Normal	Hasta
Değeri	İşlenmemiş görüntüler	Normal	84	28
		Hasta	0	112
	Kırılmış görüntüler	Normal	118	0
		Hasta	12	94
	Kırılmış görüntüler	Cerrahi hastaları	108	5
		Diğer GIS dilatasyonları	7	104

Tablo 5.5 ConvNeXtXLarge modeliyle yapılan sınıflandırmaların karmaşıklık matrisleri


Gerçek Değeri				
Tahmin			Normal	Hasta
Değeri	İşlenmemiş görüntüler	Normal	102	6
		Hasta	17	99
	Kırılmış görüntüler	Normal	121	3
		Hasta	4	96
	Kırılmış görüntüler	Cerrahi hastaları	107	7
		Diğer GIS dilatasyonları	13	97

Tüm modeller, eğitimden sonra 224 görüntü üzerinde test edilmiş olup modellerin başarıları performans ölçütleri ile değerlendirilmiştir ve Tablo 5.6'da sunulmaktadır.

Tablo 5.6 Deneyde kullanılan ESA modeli ve veri kümelerine göre performans ölçütleri

ESA modeli	Veri kümesi	Doğruluk (Accuracy)	Kesinlik (Precision)	Duyarlılık (Sensitivite)	F1-Ölçütü (F1-Score)
ResNet50	Normal vs Hasta (ham görüntüler)	0,938	0,935	0,940	0,933
	Normal vs Hasta (kırılan veriler)	0,944	0,955	0,956	0,955
	Cerrahi hastalar vs Diğer hastalar	0,861	0,901	0,882	0,886
InceptionResNetV2	Normal vs Hasta (ham görüntüler)	0,881	0,911	0,910	0,906
	Normal vs Hasta (kırılan veriler)	0,950	0,960	0,953	0,955
	Cerrahi hastalar vs Diğer hastalar	0,889	0,905	0,902	0,902
Xception	Normal vs Hasta (ham görüntüler)	0,863	0,840	0,813	0,820
	Normal vs Hasta (kırılan veriler)	0,869	0,866	0,867	0,866
	Cerrahi hastalar vs Diğer hastalar	0,861	0,876	0,880	0,875
EfficientNetV2L	Normal vs Hasta (ham görüntüler)	0,881	0,900	0,875	0,873
	Normal vs Hasta (kırılan veriler)	0,962	0,954	0,943	0,946
	Cerrahi hastalar vs Diğer hastalar	0,972	0,947	0,946	0,946
ConvNeXtXLarge	Normal vs Hasta (ham görüntüler)	0,913	0,900	0,899	0,897
	Normal vs Hasta (kırılan veriler)	0,956	0,969	0,968	0,968
	Cerrahi hastalar vs Diğer hastalar	0,889	0,912	0,910	0,911

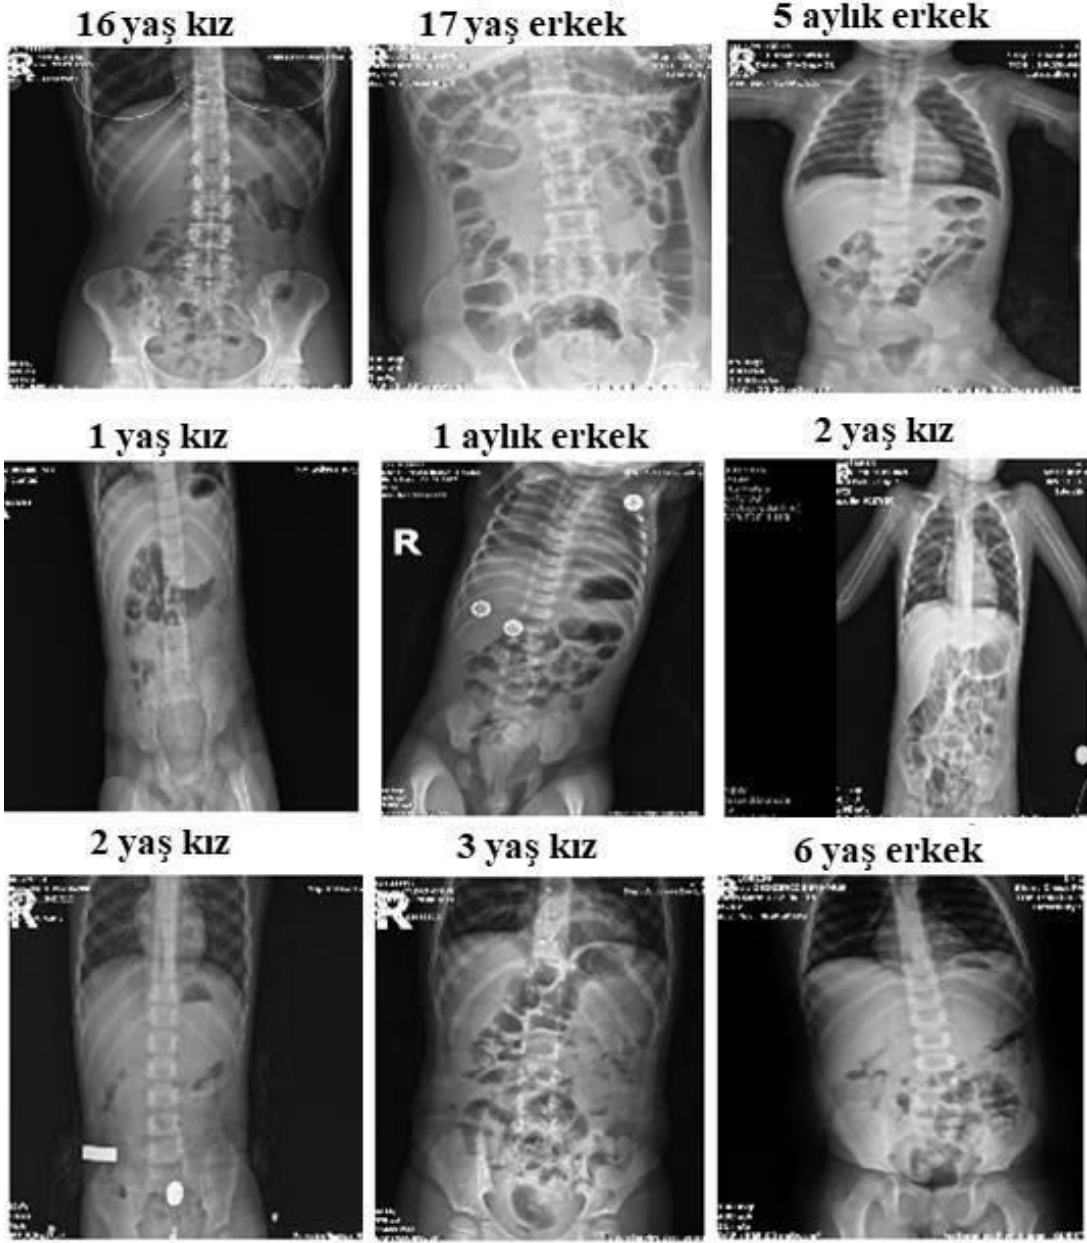
Tabloda da görüldüğü gibi modellerin en yüksek performans ölçütleri farklı veri kümelerinde farklı sıralamada görülmekle birlikte genel olarak EfficientNetV2L ve ConvNeXtXLarge ESA modelleri ile elde edildi. Örnek olarak Xception modelinin analizi sonucu bazı veriler üzerinde uygulanan gradyan ağırlıklı sınıf aktivasyon haritası (Grad-CAM) ile sınıflandırmada en çok ağırlığı olan pikseller Şekil 5.4'te gösterilmektedir (Selvaraju ve diğerleri, 2016).



Şekil 5.4. (A) duodenal atrezi, (B) midgut volvulus, (C) mekonyum ileus, (D) perforate apandisit tanılı cerrahi endikasyonlu GIS dilatasyonu olan hastaların görüntülerinin Grad-CAM ağırlık haritasında patolojik bulgular doğru olarak saptanmıştır. İntestinal malrotasyon/midgut volvulus tanılı iki hastada ise (E ve F) Grad-CAM haritasının ağırlığı yanlış olarak saptanmıştır.

Son olarak, modelde hatalı olarak etiketlenen olguların (yanlış pozitif veya yanlış negatif) hangi hastalıklarda, yaşta ve cinsiyette olduğunu belirlemek için veri kümemiz ConvNeXtXLarge modeli ile analiz edildi. Her analizde randomize olarak dağıtılan 7 pakette toplam 224 görüntü kullanılarak model üç kez çalıştırıldı. Üç model analizinde toplam 4 cerrahi obstrüksiyonu olan 6 diğer dilatasyonu olan görüntü yanlış negatif olarak etiketlendi. Normal olan gruptan üç analizde toplam 33 görüntü ise yanlış pozitif olarak etiketlendi. Model analizine göre normalde sağlıklı

olduğu halde anormal olarak sınıflandırılan hasta örnekleri Şekil 5.5'te yaş ve cinsiyetleri ile sunulmaktadır.



Şekil 5.5. Normalde sağlıklı olduğu halde ConvNeXtXLarge ile test edildiğinde anormal olarak sınıflandırılan (yanlış pozitif) olgulara örnekler.

Cerrahi obstrüksiyon olduğu halde normal olarak etiketlenen olgular ise Şekil 5.6'da sunulmaktadır. Yanlış negatif olgular, üç farklı hastalık grubunda ve veri kümesinde sık olan hastalıklar olduğu için belirli bir hastalık grubunun teşhis edilemediği gibi bir sonuca ulaşamadık.

11 yaş ♂ perfore
appandisit



16 yaş ♂ perfore
appandisit



2 yaş ♂ brid ileus ve Ladd
bandı eksizyonu



2 aylık ♂ Hirschsprung
hastalığı



Şekil 5.6. Normalde cerrahi obstrüksiyonu olduğu halde ConvNeXtXLarge ile test edildiğinde normal olarak sınıflandırılan (yanlış negatif) olguların cerrahi tanısı, yaşı ve cinsiyeti ile radyografileri gösterilmektedir.

BÖLÜM VI – TARTIŞMA VE SONUÇ

Bu tezde çocukluk çağı GİS obstrüksiyonları veya bağırsak dilatasyonu oluşturan etkenlerin direk radyografilerle tanısı konusunda tanı desteği sağlayabilecek sınıflandırma temelli ESA modeli oluşturulması amaçlandı. 0-18 yaş arası tüm yaş gruplarını kapsayan normal bulguları olan, cerrahi gerektiren GİS obstrüksiyonu bulunan ve enfeksiyöz veya diğer nedenli GİS dilatasyonu oluşturan hastaların radyografilerinden oluşan veri kümesi hazırlandı. Bu veri kümesi, görüntü analizi ve sınıflandırması konusunda başarı gösteren ve bu alanda en bilinen ESA modelleri ile transfer öğrenme metodu ile değerlendirildi. Ayrıca otomatik kırpma gibi ön işleme yöntemlerinin modelin performansına katkısı denendi. Sonuç olarak normal – anormal radyografilerin ayırımında %90 doğruluğun üzerine ResNet50 (0,938) ve ConvNeXtXLarge (0,913) ESA modelleriyle, kırılma ön işlemi uygulandıktan sonra aynı veri gruplarında %90 doğruluğun üzerine ResNet50 (0,944), InceptionResNetV2 (0,950); %95 doğruluğun üzerine ise EfficientNetV2L (0,962) ve ConvNeXtXLarge (0,956) ile ulaşıldı. Cerrahi GIS obstrüksiyonu ile diğer GİS dilatasyonu olan hastaların ayırımı için kırılmış görüntüler üzerinde yapılan analizde ise %90 doğruluğun üzerine EfficientNetV2L (0,972) ile ulaşıldı. Tablo 5.6'dan görülebileceği gibi kırılma ön işleminin tüm modellerde performans üzerinde belirgin katkısı olduğu görülmektedir. Bunun en önemli sebeplerinin elde edilen radyografi çekimlerinin acil ve poliklinik şartlarında standart olmaması, uygun pozisyonun verilmemesi, uygun görüntüleme alanının ayarlanmaması, çekim sırasında hastaların üzerindeki kontrast oluşturacak maddelerin çıkarılmaması gibi etkenler olduğu düşünülmektedir.

Çocukluk çağında abdomen radyografisi ile ilgili daha önce yapılan çok az sayıda çalışma mevcuttur. Literatürdeki radyografi ile ilgili çalışmalar veri sayısının da çok ve ulaşılabilir olması nedeniyle ağırlıklı olarak akciğer radyografisi ile ilgilidir. Özellikle COVID-19 pandemisi sonrasında çekimlerin belirgin artışıyla veri kümelerinin ve çalışmaların sayısı da belirgin arttı. Ülkemizde ve yurt dışında yapılan çalışmalarda akciğer grafileri değerlendirildiğinde COVID-19, viral pnömoni ve bakteriyel pnömoni gibi hastalıklarının sınıflandırılmasında doğruluk oranı 0,95 –

0,99 seviyelerine ulaşmaktadır (Narin ve diğerleri, 2021; Taylor ve diğerleri, 2018; Ucar ve Korkmaz, 2020). Akciğer radyografilerinde kardiomegali, plevral efüzyon ve pulmoner ödem gibi bazı hastalıkların tanısında radyologlarla yapılan karşılaştırmada modellerin daha yüksek oranlara ulaştığı belirtildi (Irvin ve diğerleri, 2019).

Abdomen radyografilerinin ESA modellerinde veri olarak kullanıldığı çalışmalarda en yüksek doğruluk oranı 0,96 düzeyine ulaştı (Kim ve diğerleri, 2021). Bizim çalışmamızda benzer düzeyde performans ölçütlerine ulaşılma ile birlikte çalışmamız çocuk hasta grubunda bu düzeylere ulaşan ilk çalışmadır. Ayrıca bahsedilen çalışmanın görüntü örneklerine bakıldığında görüntülerin standart boyutta olduğu ve yalnızca abdomeni içerecek şekilde kırılma yapıldığı görülmektedir. Çalışmamızda otomatik kırılma yapılmış olup, kırılma işlemi her veride istenen seviyede olmadı. Bu durum performans ölçütlerinde düşüşe neden olmuş olabilir. Kwon ve diğ. yaptığı ve veri sayısının (11.384 abdomen radyografisi) bizimkinden çok daha fazla olduğu çalışmada ResNet modeli ile invajinasyon ve sağlıklı hastalar karşılaştırılmış olup doğruluk oranı 0,76 olarak bulunmuştu (Kwon ve diğerleri, 2020). Bizim çalışmamızda ResNet50 modeli ile 0,938 doğruluk oranına ulaşılmış olup ham verilerde en yüksek doğruluk oranı bu model ile elde edildi. Hangi cerrahi olgularının yanlış negatif olduğuna bakılan analizde ise dört vakanın ikisi komplike apandisit, biri brid ileus ve biri Hirschsprung iken invajinasyon olgularında hatalı sınıflama saptanmadı.

Modelin veri kümemizle test edildiği üç seferde de yanlış pozitif sonuçlar yanlış negatiflere göre daha çok çıktı. Bu durum ilk bakışta gereksiz cerrahi veya medikal tedaviye yol açabilir diye düşünülebilirse de hastaların değerlendirilmesi sırasında pozitif sonucu olan olguların laboratuvar verileri, klinik muayeneleri, semptomları da değerlendirileceği için yanlış pozitif sonuçlar nedeniyle gereksiz cerrahi olma olasılığı çok düşüktür. Ancak ek tetkik ve muayene kaynaklı zaman ve işgücü kaybına neden olabilir. Öte yandan yanlış negatif olgular, acil veya poliklinik şartlarındaki yoğun çalışma ortamında pozitif vakaların gözden kaçmasına neden olabileceği için daha tehlikelidir. Model analizinde yanlış negatif olgular, yanlış pozitif olgulara göre 1/3 oranında daha az olup bunların da %60'ı enfeksiyon/inflamasyon nedeni bağırsak dilatasyonu olan hastalardı. Esas önemli

olan cerrahi obstrüksiyon vakalarında ise yanlış negatif oranı oldukça düşük çıktı. Yanlış negatif verilerin sonucu en çok etkilediği doğruluk parametresi olan duyarlılık değerlerine bakıldığında ConvNeXtXLarge ve ResNet50 modellerinde 0,95'in üzerinde duyarlılık olduğu görülmektedir.

6.1 ÇALIŞMANIN KISITLILIKLARI VE GELECEK ÇALIŞMA ÖNERİLERİ

Çalışmanın en önemli kısıtlılığı veri sayısının az olmasıdır. ESA modellerinde veri sayısı, performansın yükselmesindeki en önemli etkenlerdendir. Radyografi araştırmaları için farklı kurumlar tarafından açık erişime sunulan akciğer radyografisi veri kümeleri mevcut olup bunların içindeki görüntü sayısı 225.000'e yaklaştı (Irvin ve diğerleri, 2019). Ancak abdomen radyografileri ile ilgili bildiğimiz kadarıyla henüz böyle bir veri kümesi bulunmamaktadır. Çocuklarda erişkine oranla iyonize radyasyonun olası zararları nedeniyle radyografi çok daha az kullanılmaktadır. Bu nedenle yeterli sayıya ulaşmak için çok merkezli araştırmalara ihtiyaç vardır. Bu kısıtlılığı önlemek için eğitim aşamasında veri artırımı uygulandı. Ancak veri artırımının da performans ölçütlerinde pratik uygulamaya göre dahayüksek değerler oluşturabileceği düşünülebilir.

Çalışmada cerrahi obstrüksiyon grupları içerisinde 16 farklı etyoloji mevcut olup bu hastalıkların sayısı tek başına değerlendirildiğinde çok az olacağı için hastalık gruplarının ayrı ayrı performans ölçütlerine bakılamadı. Gelecekte çok merkezli çalışmalarla ESA modellerinin hangi hastalık gruplarında daha yüksek performans gösterdiği ile ilgili çalışmalar yapılabilir.

Çalışmamızdaki bir diğer kısıtlılık bazı hastaların hastalığı süresince farklı günlerde çekilen birden fazla görüntüsü mevcut olup tanı konduktan sonra takipte çekilen radyografiler de veri sayısını artırmak için çalışmaya dahil edildi. Hastaların hastaneye ilk gelişinde belli belirsiz olan GİS obstrüksiyonu bulguları, tanı süreci uzadıkça çekilen radyografilerde giderek belirginleşmektedir. Bu nedenle sadece ilk gelişte alınan radyografiler kullanılsaydı performans ölçütleri daha düşük çıkabilirdi.

Kontrol veri kümesi oluştururken 0-18 yaş arası tüm yaş gruplarının görüntülerinin modelin eğitiminde kullanılması için her yaş grubunu temsil eden görüntü sayısının dengeli olması amaçlandı. Ancak anormal bulguları olan hastalar daha çok infant ve küçük çocuklardı. Bu nedenle kontrol grubunun ($7,29 \pm 5,05$ yıl) yaş ortalaması hasta gruplarından ($5,47 \pm 5,82$ ve $4,22 \pm 4,44$ yıl) yüksektir. Bilimsel arařtırmalarda cinsiyet ve yaş ortalamalarında denek grubu ile cinsiyet dağılımında anlamlı fark deney ve kontrol grubunun yaş ortalamaları arasında anlamlı fark olmaması beklendiđi için bu durum bias oluşturmuş olabilir. Ancak biz, hazırladığımız modelin tüm çocukluk çağında kullanılabileceđini düşünerek 0-18 yaş arası daha dengeli bir kontrol grubu oluşturmayı bilinçli olarak tercih ettik. Gelecekte açık erişime sunulan büyük veri kümeleri hazırlanırsa yaş filtresi kullanılarak veri çekilip bu tarz çalışmalarda kullanılabilmesinin faydalı olacağını düşünüyoruz.

KAYNAKÇA

- Afshar, P., Heidarian, S., Naderkhani, F., Oikonomou, A., Plataniotis, K. N., & Mohammadi, A. (2020). Covid-caps: A capsule network-based framework for identification of covid-19 cases from x-ray images. *Pattern Recognition Letters*, 138, 638-643. DOI: 10.1016/j.patrec.2020.09.010
- Atlan, F. & Pençe, I. (2021). Yapay zekâ ve tıbbi görüntüleme teknolojilerine genel bakış. *Acta Infologica*, 5(1), 207-230. DOI: 10.26650/acin.813736
- Ayaz, E. (2021). Ultrasound of the Pediatric Gastrointestinal Emergencies. In: Eröndü, F.O., editor. *Ultrasound Imaging - Current Topics* [Internet]. London: IntechOpen. DOI: 10.5772/intechopen.99759
- Ayaz, E., Özdamarlar, U., Demir, M. K., & Somuncu, S. (2017). Tipik radyografi bulguları ile yenidoğan alt GIS obstruksiyonu: Mekonyum İleusu/Neonatal lower GIS obstruction with typical radiographic findings: Meconium Ileus. *Turkish Journal of Radiology*, 36(3), 83-86. DOI: 10.5152/turkjradiol.2017.755
- Bar, Y., Diamant, I., Wolf, L., & Greenspan, H. (2015). Deep learning with non-medical training used for chest pathology identification. In *Medical Imaging 2015: Computer-Aided Diagnosis* (Vol. 9414, pp. 215-221). SPIE. DOI: 10.1117/12.2083124
- Bucher, B.T., Hall, B.L., Warner, B.W. & Keller, M.S. (2011). Intussusception in children: Cost-effectiveness of ultrasound vs diagnostic contrast enema. *J Pediatr Surg*, 46, 1099-1105. DOI: 10.1016/j.jpedsurg.2011.03.034
- Bottou, L. (2010). Large-scale machine learning with stochastic gradient descent. In *Proceedings of COMPSTAT'2010* (pp. 177-186). Physica-Verlag HD. DOI: 10.1007/978-3-7908-2604-3_16
- Carroll, A. G., Kavanagh, R. G., Leidhin, C. N., Cullinan, N. M., Lavelle, L. P., & Malone, D. E. (2017). Comparative effectiveness of imaging modalities for the diagnosis and treatment of intussusception: a critically appraised topic. *Academic Radiology*, 24(5), 521-529. DOI: 10.1016/j.acra.2017.01.002

- Cheng, L.K., O'Grady, G., Du, P., Egbuji, J.U., Windsor, J.A. & Pullan, A.J. (2010). Gastrointestinal system. *WIREs Syst Biol Med*, 2, 65-79. DOI: 10.1002/wsbm.19
- Cheng, P. M., Tran, K. N., Whang, G., & Tejura, T. K. (2019). Refining convolutional neural network detection of small-bowel obstruction in conventional radiography. *American Journal of Roentgenology*, 212(2), 342-350. DOI: 10.2214/AJR.18.20362
- Cheng, P. M., Tejura, T. K., Tran, K. N., & Whang, G. (2018). Detection of high-grade small bowel obstruction on conventional radiography with convolutional neural networks. *Abdominal Radiology*, 43(5), 1120-1127. DOI: 10.1007/s00261-017-1294-1
- Chollet, F. (2017). Xception: Deep learning with depthwise separable convolutions. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 1251-1258). DOI: 10.1109/CVPR.2017.195
- Chouhan, V., Singh, S. K., Khamparia, A., Gupta, D., Tiwari, P., Moreira, C., Damasevicius, R., & De Albuquerque, V. H. C. (2020). A novel transfer learning based approach for pneumonia detection in chest X-ray images. *Applied Sciences*, 10(2), 559. DOI: 10.3390/app10020559
- Cicero, M., Bilbily, A., Colak, E., Dowdell, T., Gray, B., Perampaladas, K., & Barfett, J. (2017). Training and validating a deep convolutional neural network for computer-aided detection and classification of abnormalities on frontal chest radiographs. *Investigative radiology*, 52(5), 281-287. DOI: 10.1097/RLI.0000000000000341
- Demir, Y., (2021) Pediatrik Akciğer Röntgen Görüntülerinden Evrişimsel Sinir Ağı İle Pnömoni Tespiti. Yüksek Lisans Tezi, Gümüşhane Üniversitesi Lisansüstü Eğitim Enstitüsü, 18s. <https://tez.yok.gov.tr/UlusalTezMerkezi/> adresinden erişildi.
- Dillman, J. R., Somasundaram, E., Brady, S. L., & He, L. (2022). Current and emerging artificial intelligence applications for pediatric abdominal imaging. *Pediatric Radiology*, 52(11), 2139-2148. DOI: 10.1007/s00247-021-05057-0
- Dodge, J., Ilharco, G., Schwartz, R., Farhadi, A., Hajishirzi, H., & Smith, N. (2020). Fine-tuning pretrained language models: Weight initializations, data orders, and early stopping. DOI: 10.48550/2002.06305.

- Doğan, F., & Türkoğlu, İ. (2019). Derin öğrenme modelleri ve uygulama alanlarına ilişkin bir derleme. Dicle Üniversitesi Mühendislik Fakültesi Mühendislik Dergisi, 10(2), 409-445. DOI: 10.24012/dumf.411130
- Farrel, M.B., & Zimmerman, J. (2020). Meckel's Diverticulum Imaging. Journal of Nuclear Medicine Technology, 48(3), 210-213. DOI: 10.2967/jnmt.120.251918
- Girshick, R., Donahue, J., Darrell, T., & Malik, J. (2014). Rich feature hierarchies for accurate object detection and semantic segmentation. In Proceedings of the IEEE conference on computer vision and pattern recognition (pp. 580-587). DOI: 10.1109/CVPR.2014.81.
- Goodfellow, I., Bengio, Y., & Courville, A. (2016). Deep learning. MIT press. ISBN: 978-026-2035-61-3, Cambridge, Massachusetts, USA. p. 767
- Gülgün, O. D., & Hamza, E. (2020). Classification performance comparisons of deep learning models in pneumonia diagnosis using chest x-ray images. Turkish Journal of Engineering, 4(3), 129-141. DOI: 10.31127/tuje.652358
- Hamm, C. A., Wang, C. J., Savic, L. J., Ferrante, M., Schobert, I., Schlachter, T., Lin, M., Duncan, J. S., Weinreb, J. C., Chapiro, J. & Letzen, B. (2019). Deep learning for liver tumor diagnosis part I: development of a convolutional neural network classifier for multi-phasic MRI. European radiology, 29, 3338- 3347. DOI: 10.1007/s00330-019-06205-9
- Hashmi, M. F., Katiyar, S., Keskar, A. G., Bokde, N. D., & Geem, Z. W. (2020). Efficient pneumonia detection in chest xray images using deep transfer learning. Diagnostics, 10(6), 417. DOI: 10.3390/diagnostics10060417
- He, K., Zhang, X., Ren, S., & Sun, J. (2016). Deep residual learning for image recognition. In Proceedings of the IEEE conference on computer vision and pattern recognition (pp. 770-778). DOI: 10.1109/CVPR.2016.90
- Hryhorczuk, A.L. & Lee, E.Y. (2012). Imaging evaluation of bowel obstruction in children: updates in imaging techniques and review of imaging findings. Semin Roentgenol, 47, 159-70. DOI: 10.1053/j.ro.2011.11.007.
- Irvin, J., Rajpurkar, P., Ko, M., Yu, Y., Ciurea-Ilcus, S., Chute, C., Marklund, H., Haghgoo, B., Ball, R., Shpanskaya, K., Seekins, J., Mong, D.A., Halabi, S.S., Sandberg, J.K., Jones, R., Larson, D.B., Langlotz, C.P., Patel, B.N.,

Lungren, M.P., & Ng, A. Y. (2019). Chexpert: A large chest radiograph dataset with uncertainty labels and expert comparison. In Proceedings of the AAAI conference on artificial intelligence (Vol. 33, No. 01, pp. 590-597). DOI: 10.1609/aaai.v33i01.3301590

- İnik, Ö. & Ülker, E. (2017). Derin Öğrenme ve Görüntü Analizinde Kullanılan Derin Öğrenme Modelleri . Gaziosmanpaşa Bilimsel Araştırma Dergisi , 6 (3) , 85-104 . <https://dergipark.org.tr/en/pub/gbad/issue/31228/330663> adresinden erişildi.
- Jaiswal, A. K., Tiwari, P., Kumar, S., Gupta, D., Khanna, A., & Rodrigues, J. J. (2019). Identifying pneumonia in chest X-rays: A deep learning approach. *Measurement*, 145, 511-518. DOI: 10.1016/j.measurement.2019.05. 076
- Kandasamy, D., Sharma, R. & Gupta, A.K. (2019). Bowel Imaging in Children: Part 1. *Indian J Pediatr*, 86, 805-816. DOI: 10.1007/s12098-019-02877-9.
- Kanne, J. P., Little, B. P., Chung, J. H., Elicker, B. M., & Ketai, L. H. (2020). Essentials for radiologists on COVID-19: an update—radiology scientific expert panel. *Radiology*. DOI: 10.1148/radiol.2020200527
- Kermany, D. S., Goldbaum, M., Cai, W., Valentim, C. C., Liang, H., Baxter, S. L., McKeown, A., Yang, G., Wu, X., Yan, F., Dong, J., Prasadha, M. K., Pei, J., Ting, M.Y.L., Zhu, J., Li, C., Hewett, S., Dong, J., Ziyar, I., Shi, A. & Zhang, K. (2018). Identifying medical diagnoses and treatable diseases by image-based deep learning. *Cell*, 172(5), 1122-1131. DOI: 10.1016/j.cell.2018.02.010
- Kim, D. H., Wit, H., Thurston, M., Long, M., Maskell, G. F., Strugnell, M. J., Shetty, D., Smith I. M. & Hollings, N. P. (2021). An artificial intelligence deep learning model for identification of small bowel obstruction on plain abdominal radiographs. *The British Journal of Radiology*, 94(1122), 20201407. DOI: 10.1259/bjr.20201407
- Kim, M., Kim, J. S., Lee, C., & Kang, B. K. (2021). Detection of pneumoperitoneum in the abdominal radiograph images using artificial neural networks. *European Journal of Radiology Open*, 8, 100316. DOI: 10.1016/j.ejro.2020.100316
- Kwon, G., Ryu, J., Oh, J., Lim, J., Kang, B. K., Ahn, C., Bae, J., & Lee, D. K. (2020). Deep learning algorithms for detecting and visualising intussusception

on plain abdominal radiography in children: a retrospective multicenter study. *Scientific Reports*, 10(1), 1-10. DOI: 10.1038/s41598-020-74653-1

- LeCun, Y., Boser, B., Denker, J. S., Henderson, D., Howard, R. E., Hubbard, W., & Jackel, L. D. (1989). Backpropagation applied to handwritten zip code recognition. *Neural computation*, 1(4), 541-551. DOI: 10.1162/neco.1989.1.4.541
- Lee, C. S., Wang, M. H., Yen, S. J., Wei, T. H., Wu, I. C., Chou, P. C., Chou, C.H., Wang, M.W., & Yan, T. H. (2016). Human vs. computer go: Review and prospect [discussion forum]. *IEEE Computational intelligence magazine*, 11(3), 67-72. DOI: 10.1109/MCI.2016.2572559
- Lee, E. Y., Ng, M. Y., & Khong, P. L. (2020). COVID-19 pneumonia: what has CT taught us?. *The Lancet Infectious Diseases*, 20(4), 384-385. DOI: 10.1016/S1473-3099(20)30134-1
- Li, H., He, L., Dudley, J. A., Maloney, T. C., Somasundaram, E., Brady, S. L., Parikh, N.A., & Dillman, J. R. (2021). DeepLiverNet: a deep transfer learning model for classifying liver stiffness using clinical and T2-weighted magnetic resonance imaging data in children and young adults. *Pediatric radiology*, 51(3), 392-402. DOI: 10.1007/s00247-020-04854-3
- Lin, M., Chen, Q., & Yan, S. (2013) Network in network. *CoRR*, DOI: 10.48550/arXiv.1312.4400
- Liu, Z., Mao, H., Wu, C. Y., Feichtenhofer, C., Darrell, T., & Xie, S. (2022). A convnet for the 2020s. In *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition* (pp. 11976-11986). DOI: 10.48550/arXiv.2201.03545
- Liu, Z., Lin, Y., Cao, Y., Hu, H., Wei, Y., Zhang, Z., Lin, S. & Guo, B. (2021). Swin transformer: Hierarchical vision transformer using shifted windows. In *Proceedings of the IEEE/CVF international conference on computer vision and Pattern Recognition* (pp. 10012-10022). DOI: 10.1109/ICCV48922.2021.00986.
- Mirvis, S.E., Young, J.W., Keramati, B., McCrea, E.S. & Tarr, R. (1986). Plain film evaluation of patients with abdominal pain: Are three radiographs necessary? *AJR Am J Roentgenol*, 147, 501-503. DOI: 10.2214/ajr.147.3.501

- Mollard, B.J., Smith, E.A. & Dillman, J.R. (2014). Pediatric MR enterography: technique and approach to interpretation—how we do it. *Radiology*, 274, 29–43. DOI: 10.1148/radiol.14122449
- Murphy, K. P., (2012) *Machine Learning: A Probabilistic Perspective*. MIT Press. Cambridge, Massachusetts, USA. ISBN: 978- 0-262-01802-9, 1054s. http://noiselab.ucsd.edu/ECE228/Murphy_Machine_Learning.pdf adresinden erişildi.
- Narin, A., Kaya, C., & Pamuk, Z. (2021). Automatic detection of coronavirus disease (covid-19) using x-ray images and deep convolutional neural networks. *Pattern Analysis and Applications*, 24(3), 1207-1220. DOI: 10.1007/s10044-021-00984-y
- Otjen, J. P., Stanescu, A. L., Alessio, A. M., & Parisi, M. T. (2020). Ovarian torsion: developing a machine-learned algorithm for diagnosis. *Pediatric Radiology*, 50(5), 706-714. DOI: 10.1007/s00247-019-04601-3
- Ozturk, T., Talo, M., Yildirim, E. A., Baloglu, U. B., Yildirim, O., & Acharya, U. R. (2020). Automated detection of COVID-19 cases using deep neural networks with X-ray images. *Computers in biology and medicine*, 121, 103792. DOI: 10.1016/j.compbimed.2020.103792.
- Pirim A., G., H. (2006) *Yapay Zeka, Yaşar Üniversitesi E-Dergisi*, 1(1), 81-93. <https://dergipark.org.tr/tr/pub/jyasar/issue/19113/202842> adresinden erişildi.
- Prasad, G.R., & Aziz A. (2017) Abdominal Plain Radiograph in Neonatal Intestinal Obstruction, *J Neonatal Surg*, 6(1), 6. DOI: 10.21699/jns.v6i1.483.
- Rajpurkar, P., Irvin, J., Zhu, K., Yang, B., Mehta, H., Duan, T., Ding, D., Bagul, A., Langlotz, C.P., Shpanskaya, K., Lungren, M.P., & Ng, A. Y. (2017). Chexnet: Radiologist-level pneumonia detection on chest x-rays with deep learning. DOI: 10.48550/arXiv.1711.05225.
- Rao, P. (2006). Neonatal gastrointestinal imaging. *Eur J Radiol*, 60, 171–186. DOI: 10.1016/j.ejrad.2006.07.021
- Rothrock, S.G., Green, S.M. & Hummel, C.B. (1992). Plain abdominal radiography in the detection of major disease in children: A prospective analysis. *Ann Emerg Med*, 21, 1423-1429. DOI: 10.1016/s0196- 0644(05)80053-8

- Rosenblatt, F. (1957). The perceptron, a perceiving and recognizing automaton Project Para. Cornell Aeronautical Laboratory. <https://blogs.umass.edu/brainwars/files/2016/03/rosenblatt-1957.pdf> 22 adresinden erişildi.
- Ruder, S. (2016). An overview of gradient descent optimization algorithms. DOI: 10.48550/arXiv.1609.04747
- Rumelhart, D. E., Hinton, G. E., & Williams, R. J. (1986). Learning representations by back-propagating errors. *nature*, 323(6088), 533-536. DOI: 10.1038/323533a0
- Şahinbaş, K., & Catak, F. O. (2021). Transfer learning-based convolutional neural network for COVID-19 detection with X-ray images. In *Data Science for COVID-19* (pp. 451-466). Academic Press. DOI: 10.1016/B978-0-12-824536-1.00003-4
- Selvaraju, R.R., Das, A., Vedantam, R., Cogswell, M., Parikh, D. & Batra, D. (2016) Grad-CAM: why did you say that? Cornell University. DOI: 10.48550/arXiv.1611.07450.
- Smith, K., Folaranmi, S.E., & Goel, N. (2022) Intestinal obstruction and ileus in newborn. *Pediatrics and Child Health*, 32, 7-12. DOI: 10.1016/j.paed.2021.10.003
- Stephen, O., Sain, M., Maduh, U. J., & Jeong, D. U. (2019). An efficient deep learning approach to pneumonia classification in healthcare. *Journal of healthcare engineering*, 2019. DOI: 10.1155/2019/4180949
- Szegedy, C., Vanhoucke, V., Ioffe, S., Shlens, J., & Wojna, Z. (2016). Rethinking the inception architecture for computer vision. In *Proceedings of the IEEE conference on computer vision and pattern recognition*, 2818-2826. DOI: 10.1109/CVPR.2016.308
- Szegedy, C., Liu, W., Jia, Y., Sermanet, P., Reed, S., Anguelov, D., Erhan, D., Vanhoucke V., & Rabinovich, A. (2015) Going deeper with convolutions. In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 1–9. DOI: 10.1109/CVPR.2015.7298594
- Tajbakhsh, N., Shin, J. Y., Gurudu, S. R., Hurst, R. T., Kendall, C. B., Gotway, M. B., & Liang, J. (2016). Convolutional neural networks for medical image

analysis: Full training or fine tuning? IEEE transactions on medical imaging, 35(5), 1299-1312. DOI: 10.1109/TMI.2016.2535302

- Tan, M., & Le, Q. (2019). Efficientnet: Rethinking model scaling for convolutional neural networks. In International conference on machine learning (pp. 6105-6114). PMLR. DOI: 10.48550/arXiv.1905.11946
- Taylor, A. G., Mielke, C., & Mongan, J. (2018). Automated detection of moderate and large pneumothorax on frontal chest X-rays using deep convolutional neural networks: A retrospective study. PLoS medicine, 15(11), e1002697. DOI: 10.1371/journal.pmed.1002697
- Toğaçar, M., Ergen, B., & Cömert, Z. (2020). COVID-19 detection using deep learning models to exploit Social Mimic Optimization and structured chest X-ray images using fuzzy color and stacking approaches. Computers in biology and medicine, 121, 103805. DOI: 10.1016/j.combiomed.2020.103805
- Toğaçar, M., Ergen, B., & Sertkaya, M. E. (2019). Zatürre Hastalığının Derin Öğrenme Modeli ile Tespiti. Firat University Journal of Engineering, 31(1) 223-230. <https://dergipark.org.tr/tr/pub/fumbd/issue/43638/498364> adresinden erişildi.
- Toraman, S., Alakus, T. B., & Turkoglu, I. (2020). Convolutional capsnet: A novel artificial neural network approach to detect COVID-19 disease from X-ray images using capsule networks. Chaos, Solitons & Fractals, 140, 110122. DOI: 10.1016/j.chaos.2020.110122
- Turing, A. M. (1950). Computing machinery and intelligence. Mind, 59(236), 433-460. DOI: 10.1093/mind/lix.236.433
- Ucar, F., & Korkmaz, D. (2020). COVIDiagnosis-Net: Deep Bayes- SqueezeNet based diagnosis of the coronavirus disease 2019 (COVID-19) from X-ray images. Medical hypotheses, 140, 109761. DOI: 10.1016/j.mehy.2020.109761.
- Vanderbecq, Q., Ardon, R., De Reviere, A., Ruppli, C., Dallongeville, A., Boulay-Coletta, I., D'Assignies, G., & Zins, M. (2022). Adhesion-related small bowel obstruction: deep learning for automatic transition-zone detection by CT. Insights into imaging, 13(1), 1-9. DOI: 10.1186/s13244-021-01150-y.

- Vaswani, A., Shazeer, N., Parmar, N., Uszkoreit, J., Jones, L., Gomez, A. N., Kaiser, L. & Polosukhin, I. (2017). Attention is all you need. *Advances in neural information processing systems*, 30. DOI: 10.48550/arXiv.1706.03762
- Wang, C. J., Hamm, C. A., Savic, L. J., Ferrante, M., Schobert, I., Schlachter, T., Lin, M., Weinreb, J. C., Duncan, J. S., Chapiro, J. & Letzen, B. (2019). Deep learning for liver tumor diagnosis part II: convolutional neural network interpretation using radiologic imaging features. *European radiology*, 29, 3348-3357. DOI: 10.1007/s00330-019-06214-8
- Wang, L., Lin, Z. Q., & Wong, A. (2020). Covid-net: A tailored deep convolutional neural network design for detection of covid-19 cases from chest x-ray images. *Scientific Reports*, 10(1), 1-12. DOI: 10.1038/s41598-020-76550-z
- Wang, X., Peng, Y., Lu, L., Lu, Z., Bagheri, M., & Summers, R. M. (2017). Chestx-ray8: Hospital-scale chest x-ray database and benchmarks on weakly-supervised classification and localization of common thorax diseases. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 2097-2106). DOI: 10.48550/arXiv.1705.02315
- Waseem, M., & Rosenberg, H.K. (2008). Intussusception. *Pediatr Emerg Care*, 24(11), 793-800. DOI: 10.1097/PEC.0b013e31818c2a3e
- WEB 1: <https://www.turkrad.org.tr/assets/slider-photos/Radyolojik-Tetkik-Yogunlugu-Raporu.pdf> adresinden 12.01.2023 tarihinde erişilmiştir
- WEB2: https://miro.medium.com/max/4800/1*ciDgQEjViWLnCbmX-EeSrA.gif adresinden 04.02.2023 tarihinde erişilmiştir.
- WEB3: <https://media.geeksforgeeks.org/wpcontent/uploads/20190721025744/Screenshot-2019-07-21-at-2.57.13-AM.png> adresinden 04.02.2023 tarihinde erişilmiştir.
- WEB4: https://bultin.com/sites/www.bultin.com/files/styles/ckeditor_optimize/public/inline-images/3_fully-connected-layer_0.jpg adresinden 05.02.2023 tarihinde erişilmiştir.
- WEB5: <https://tr.wikipedia.org/wiki/Python> adresinden 11.02.2023 tarihinde erişilmiştir.

- WEB6: <https://www.python.org/doc/sunset-python-2/> adresinden 11.02.2023 tarihinde erişilmiştir.
- WEB7: <https://www.tiobe.com/tiobe-index/> adresinden 11.02.2023 tarihinde erişilmiştir.
- WEB8: <https://github.com/tensorflow/tensorflow> adresinden 19.02.2023 tarihinde erişilmiştir.
- WEB9: <https://tr.wikipedia.org/wiki/TensorFlow> adresinden 19.02.2023 tarihinde erişilmiştir.
- WEB10: <https://github.com/keras-team/keras> adresinden 19.02.2023 tarihinde erişilmiştir.
- Xi, I. L., Wu, J., Guan, J., Zhang, P. J., Horii, S. C., Soulen, M. C., Zhang, Z., & Bai, H. X. (2021). Deep learning for differentiation of benign and malignant solid liver lesions on ultrasonography. *Abdominal Radiology*, 46(2), 534-543. DOI: 10.1007/s00261-020-02564-w
- Yao, L., Poblens, E., Dagunts, D., Covington, B., Bernard, D., & Lyman, K. (2017). Learning to diagnose from scratch by exploiting dependencies among labels. DOI: 10.48550/arXiv.1710.10501.
- Yosinski, J., Clune, J., & Bengio, Y. (2014). How transferable are features in deep neural networks? *Advances in Neural Information Processing Systems*, 27, 3320–3328. DOI:10.48550/arXiv.1411.1792
- Zabihollahy, F., Schieda, N., Krishna, S., & Ukwatta, E. (2020). Automated classification of solid renal masses on contrast-enhanced computed tomography images using convolutional neural network with decision fusion. *European Radiology*, 30(9), 5183-5190. DOI: 10.1007/s00330-020-06787-9

EKLER

Ek-1 Etik Kurul Onayı





Ek-2 Tezde Kullanılan Kodlara Örnekler

Transfer Öğrenme ve ResNet50 Modeli ile Veri Kümesi İkili Sınıflandırma

```
import matplotlib.pyplot as plt
import numpy as np
import os
import tensorflow as tf

## veri kümesini Google Drive'dan çekmek için;

from google.colab import drive
drive.mount("/content/drive/")
!unzip "/content/drive/MyDrive/Colab Notebooks/GIS3" -
d "/content/GIS"
train_data_path = "/content/GIS/GIS3/Train"
test_data_path = "/content/GIS/GIS3/Test"
BATCH_SIZE = 32
IMG_SIZE = (160, 160)
train_dataset = tf.keras.utils.image_dataset_from_directory(train
_data_path, shuffle=True, batch_size=BATCH_SIZE, image_size=IMG_SIZE
)

n = sum(1 for _ in train_dataset)
n_train = int(n * 0.8)
n_valid = int(n * 0.1)
n_test = n - n_train - n_valid

train_dataset2 = train_dataset.take(n_train)
validation_dataset = train_dataset.skip(n_train).take(n_valid)
test_dataset = train_dataset.skip(n_train + n_valid).take(n_test)
train_dataset=train_dataset2

AUTOTUNE = tf.data.AUTOTUNE
train_dataset = train_dataset.prefetch(buffer_size=AUTOTUNE)
validation_dataset = validation_dataset.prefetch(buffer_size=AUTO
TUNE)
test_dataset = test_dataset.prefetch(buffer_size=AUTOTUNE)

data_augmentation = tf.keras.Sequential([
    tf.keras.layers.RandomFlip('horizontal'),
    tf.keras.layers.RandomRotation(0.1),
])
```

```

preprocess_input = tf.keras.applications.resnet50.preprocess_input
rescale = tf.keras.layers.Rescaling(1./127.5, offset=-1)
IMG_SHAPE = IMG_SIZE + (3,)
base_model = tf.keras.applications.ResNet50(input_shape=IMG_SHAPE
,include_top=False,weights='imagenet')

image_batch, label_batch = next(iter(train_dataset))
feature_batch = base_model(image_batch)
base_model.trainable = False

global_average_layer = tf.keras.layers.GlobalAveragePooling2D()
feature_batch_average = global_average_layer(feature_batch)
prediction_layer = tf.keras.layers.Dense(1)
prediction_batch = prediction_layer(feature_batch_average)

inputs = tf.keras.Input(shape=(160, 160, 3))
x = data_augmentation(inputs)
x = preprocess_input(x)
x = base_model(x, training=False)
x = global_average_layer(x)
x = tf.keras.layers.Dropout(0.2)(x)
outputs = prediction_layer(x)
model = tf.keras.Model(inputs, outputs)

base_learning_rate = 0.0001
model.compile(optimizer=tf.keras.optimizers.Adam(learning_rate=base_learning_rate),loss=tf.keras.losses.BinaryCrossentropy(from_logits=True),metrics=['accuracy'])

initial_epochs = 100
loss0, accuracy0 = model.evaluate(validation_dataset)

history = model.fit(train_dataset, epochs=initial_epochs, validation_data=validation_dataset)

acc = history.history['accuracy']
val_acc = history.history['val_accuracy']
loss = history.history['loss']
val_loss = history.history['val_loss']

base_model.trainable = True
fine_tune_at = 100
for layer in base_model.layers[:fine_tune_at]:
    layer.trainable = False

```

```

model.compile(loss=tf.keras.losses.BinaryCrossentropy(from_logits
=True),
              optimizer = tf.keras.optimizers.RMSprop(learning_rate=base_learning_rate/10),
              metrics=['accuracy'])

fine_tune_epochs = 20
total_epochs = initial_epochs + fine_tune_epochs

history_fine = model.fit(train_dataset, epochs=total_epochs,
initial_epoch=history.epoch[-1],
validation_data=validation_dataset)

acc += history_fine.history['accuracy']
val_acc += history_fine.history['val_accuracy']
loss += history_fine.history['loss']
val_loss += history_fine.history['val_loss']

loss, accuracy = model.evaluate(test_dataset)

```

Yukarıda verilen model örneği ve benzer kod dizilimi ile diğer ESA modelleriyle yapılan ikili sınıflamaların web adresleri aşağıda sunulmaktadır.

ResNet50 modeli ile veri kümesi ikili sınıflandırma:

https://github.com/RadDrEAYaz/Convolutional-Neural-Netwok-Usage-on-Abdominal-Radiographs-for-the-Diagnosis-of-Gastrointestinal-Obs/blob/c87b7b3f7aa00e9253d43c2fc61a8bce6e8a9512/transfer_learning_Resnet50_TD.ipynb

InceptionResNetV2 ile veri kümesi ikili sınıflandırma:

https://github.com/RadDrEAYaz/Convolutional-Neural-Netwok-Usage-on-Abdominal-Radiographs-for-the-Diagnosis-of-Gastrointestinal-Obs/blob/c87b7b3f7aa00e9253d43c2fc61a8bce6e8a9512/transfer_learning_InceptionResNetV2.ipynb

EfficientNetV2 ile veri kümesi ikili sınıflandırma:

https://github.com/RadDrEAYaz/Convolutional-Neural-Netwok-Usage-on-Abdominal-Radiographs-for-the-Diagnosis-of-Gastrointestinal-Obs/blob/c87b7b3f7aa00e9253d43c2fc61a8bce6e8a9512/transfer_learning_EfficientNetV2.ipynb

Xception modeli ile veri kümesi ikili sınıflandırma:

https://github.com/RadDrEAYaz/Convolutional-Neural-Netwok-Usage-on-Abdominal-Radiographs-for-the-Diagnosis-of-Gastrointestinal-Obs/blob/c87b7b3f7aa00e9253d43c2fc61a8bce6e8a9512/transfer_learning_Xception.ipynb

ConvXnet modeli ile veri kümesi ikili sınıflandırma:

https://github.com/RadDrEAyaz/Convolutional-Neural-Network-Usage-on-Abdominal-Radiographs-for-the-Diagnosis-of-Gastrointestinal-Obs/blob/c87b7b3f7aa00e9253d43c2fc61a8bce6e8a9512/transfer_learning_convXnet.ipynb

Veri Kümesine Uygulanan Kırpma Ön İşlemesi

```
import matplotlib.pyplot as plt
import numpy as np
import os
import cv2

## veri kümesini Google Drive'dan çekmek için;

from google.colab import drive
drive.mount("/content/drive/")
!unzip "/content/drive/MyDrive/Colab Notebooks/GIS2" -
d "/content/GIS"

train_data_path = "/content/anormal/CerrahiObstruction"
test_data_path = "/content/anormal/MedikalIleus"

def load_images_from_folder(folder):
    images = []
    for filename in os.listdir(train_data_path):
        img = cv2.imread(os.path.join(train_data_path, filename))
        if img is not None:
            images.append(img)
    return images

im=load_images_from_folder(train_data_path)

for filename in os.listdir(train_data_path):
    img = cv2.imread(os.path.join(train_data_path, filename))
    if img is not None:
        gray = cv2.cvtColor(img, cv2.COLOR_BGR2GRAY)
        # threshold
        thresh = cv2.threshold(gray, 0, 255, cv2.THRESH_BINARY+cv2.T
HRESH_OTSU)[1]
        hh, ww = thresh.shape
        thresh[hh-3:hh, 0:ww] = 0
    white = np.where(thresh==255)
    xmin, ymin, xmax, ymax = np.min(white[1]), np.min(white[0]),
    np.max(white[1]), np.max(white[0])
    print(xmin, xmax, ymin, ymax)
    crop = img[ymin:ymax, xmin:xmax]
```

Özgeçmiş

KİŞİSEL BİLGİLER

Adı Soyadı: Ercan AYZAZ

Uyruğu: T.C.

Doğum Tarihi ve Yeri:

Elektronik Posta:

EĞİTİM

Derece	Kurum	Mezuniyet Yılı
Lisans	İstanbul Üniversitesi, Cerrahpaşa Tıp Fakültesi, İngilizce Tıp	2012
	Anadolu Üniversitesi, İşletme Fakültesi, İşletme	2014
Tıpta Uzmanlık	İstanbul Medeniyet Üniversitesi, Tıp Fakültesi, Radyoloji Anabilim Dalı	2017
Yandal Uzmanlığı	Hacettepe Üniversitesi, Tıp Fakültesi, Çocuk Radyolojisi	2022

İŞ TECRÜBESİ

Tarih	Kurum	Görev
2012-2013	Elazığ/Merkez Toplum Sağlığı Merkezi	Pratisyen Hekim
2017-2018	Bingöl Devlet Hastanesi	Radyoloji Uzmanı
2018- halen	Diyarbakır Çocuk Hastalıkları Hastanesi	Çocuk Radyoloğu

YABANCI DİLLER

İleri düzeyde İngilizce, orta düzeyde Fransızca; başlangıç düzeyinde Almanca.

YAYINLAR

- Tandircioglu UA, Turer OB, Soyer T, **Ayaz E**, Ozcan HN, Yigit S, Celik HT. Effect of prostaglandin-E1 treatment on pyloric wall thickness in newborns with ductal-dependent critical congenital heart diseases. *Pediatr Surg Int.* 2023;39(1):144
- **Ayaz E**, Özcan HN, Hızarcıoğlu Gülşen H, et al. Acute pancreatitis and acute recurrent pancreatitis in children: Imaging findings and outcomes. *Turk Arch Pediatr.* 2023;58(1):89-97
- **Ayaz E**, Ozkale Yavuz O, Ozcan HN. et al. Are the thickness and ADC values reliable to evaluate pancreas in children? A retrospective MRI study. *Abdom Radiol* 2023;48, 925–935
- **Ayaz E**, Yıldırım, R, Çelebi, C, Ozalkak, S. Noonan syndrome: Neuroimaging findings and morphometric analysis of the cranium base and posterior fossa in children. *J Neuroimaging.* 2022; 1– 10. <https://doi.org/10.1111/jon.13075>
- **Ayaz E**. Impact of the coronavirus disease 2019 pandemic on ultrasound screening of developmental dysplasia of the hip and follow-up imaging: a report from southeastern Turkey. *J Int Med Res.* 2022 Nov;50(11):3000605221133009.
- **Ayaz E**, Bozaci AE. Radiographic Findings of Mucopolysaccharidosis and Comparison with Bone Mineral Density: A Study from Southeastern Turkey. *J Clin Densitom.* 2022 Oct-Dec;25(4):475-484
- Ozkale Yavuz O, **Ayaz E**, Yıldız Y, Akgoz Karaosmanoglu A, Bulut E, Kalkanoglu Sivri HS, Oguz KK. Increased ocular wall thickness and decreased globe volume in children with mucopolysaccharidosis type VI. *Diagn Interv Radiol.* 2022 Sep;28(5):516-521
- **Ayaz E**, Ozcan HN, Oguz B, Haliloglu M. Beyond Wilms tumor: imaging findings and outcomes of rare renal tumors in children. *Pediatr Radiol.* 2022;52:2557–2567
- **Ayaz E**, Gündoğdu F, Gedikoğlu G, Aydınöz Ü. Whole-Body MRI Showing Unusual Pancreatic Metastasis from a Forearm Rhabdomyosarcoma without Lung Involvement. *Turk Arch Pediatr.* 2022 Nov;57(6):675-678.
- **Ayaz E**. Turkish Neonatal Society Guideline on the Diagnosis and Management of Germinal Matrix Hemorrhage-Intraventricular Hemorrhage and Related Complications. *Turk Arch Pediatr.* 2022;57(2):251-252.
- **Ayaz E**, Haliloglu M. Radiologic diagnosis of tracheoesophageal fistula in children. *Curr Chall Thorac Surg* 2022;4(25):1-11
- Ozkale Yavuz O, Ozcan HN, Oguz B, **Ayaz E**, Ekinci S, Ciftci TT, Haliloglu M. Imaging findings of benign and malignant pediatric splenic lesions. *Abdom Radiol (NY).* 2021 Jul;46:3245-3252
- **Ayaz E**, Ademhan D, Yuksel K, Yalcin E, Oguz B, Ozcelik U, Haliloglu M. Complicated pneumonia due to exogenous toxic substances in children. *The Turkish Journal of Pediatrics* 2021; 63: 149-154
- **Ayaz E**, Ayaz M, Önal C, Yıkılmaz A. Seeing the unseen: evaluating testicular vascularity in neonates by using the Superb Microvascular Imaging ultrasound technique. *Journal of Ultrasound in Medicine* 2019; 38:1847-1854.
- **Ayaz E**, Aslan A, İnan İ, Yıkılmaz A. Evaluation of ovarian vascularity in children by using the “superb microvascular imaging” ultrasound technique in

- comparison with conventional Doppler ultrasound techniques. Journal of Ultrasound in Medicine 2019; 38:2751-2760.
- **Ayaz E**, Aşık M. Endobiliary radiofrequency ablation and percutaneous biliary stent placement for choledocal invasion of renal cell carcinoma. Turk J Gastroenterol. 2019; 30:854-857.
 - **Ayaz E**, Aktan A, Alimoğlu A, Ozdas I. Unusual Causes of the Acute Abdominal Pain: Imaging and Clinical Findings. Journal of Emergency Medicine Case Reports 2019; 10:53-58.
 - **Ayaz E**, Haliloğlu M. Radyolojik Tanımız Nedir?. Çocuk Enfeksiyon Dergisi 2019; 13:174-176 (Turkish)
 - Aslan A, Barutca H, **Ayaz E**, Aslan M, Kocaaslan C, Inan I, Sahin S, Yıkılmaz A. Is real-time elastography helpful to differentiate acute from subacute deep venous thrombosis? A preliminary study. Journal of Clinical Ultrasound 2018; 46:116-121.
 - Aslan A, Inan İ, Aktan A, **Ayaz E**, Aslan M, Özkanlı SŞ, Yıldırım A, Yıkılmaz, A. The utility of ADC measurement techniques for differentiation of low-and high-grade clear cell RCC. Polish journal of radiology 2018; 83:e446-e451.
 - Aslan A, **Ayaz E**, Inan I, Acar M. (2018). Isolated hepatic actinomycosis mimicking hepatocellular carcinoma: Case report and review. Advances in Digestive Medicine, 5(1-2), 55-58. *Top downloaded article in Advanves in Digestive Medicine 2017-2018*
 - Çavuş B, Çaydaşı Ö, Aktan A, **Ayaz E**. Brucellosis as the Cause of Non-Viral Bacterial Hepatitis: A Case Report. Open access Macedonian journal of medical sciences 2018; 6:1260-1262.
 - Balyemez F, Aslan A, Inan I, **Ayaz E**, Karagöz V, Özkanlı S Ş, Acar M. Diffusion-weighted magnetic resonance imaging in cystic renal masses. Canadian Urological Association Journal 2017; 11:E8-E14.
 - **Ayaz E**, Atalay B, Baysal B, Senturk S, Aslan A. Giant arachnoid granulation mimicking dural sinus thrombosis. Northern clinics of Istanbul 2017; 4:185-187.
 - Altaiar A, Aslan A, Gündüz N, Alimoğlu O, **Ayaz E**. Unilateral primary adrenal B-cell lymphoma clinically mimicking chronic gastritis. Polish journal of radiology 2017; 82:612-615.
 - Aslan A, Kartal Y, **Ayaz E**, Aslan M, Bulut SSD, Ağırbaşı MA, Oysu AS. Bone Deformities as a Complication of Giant Thoracic Aortic Aneurysm. Vascular and endovascular surgery 2017; 51:312-315.
 - **Ayaz E**, Ozdamarlar U, Demir MK, Somuncu S. Tipik radyografi bulgulari ile yenidoğan alt GIS obstruksiyonu: Mekonyum Ileusu/Neonatal lower GIS obstruction with typical radiographic findings: Meconium Ileus. Turkish Journal of Radiology, 2017; 36:83-86 (Turkish)
 - Özdamarlar U, **Ayaz E**, Küçükodacı Z, Değer E, Demir MK. A Rare Cause of Acute Abdomen Due to Hemorrhage of Renal Mass: Wunderlich Syndrome. Journal of Emergency Medicine Case Reports 2017; 8:55-58.
 - Aslan A, **Ayaz E**, Inan I, Duman E, Acar M. (2016). Pancreas rotation anomaly with intestinal malrotation. Acta gastro-enterologica Belgica 2016; 79:383-384.
 - **Ayaz E**, Asik M, Onder B, Acar M. Obturator Hernia : Supremacy of CT over clinical findings. Medeniyet Medical Journal (former Göztepe Tıp Dergisi) 2014; 29:250-253