



Derin öğrenme tabanlı topluluk sınıflandırıcı yaklaşımı ile gastrointestinal anomalilerin tespiti

Detection of gastrointestinal anomalies with a deep learning-based ensemble classifier approach

Fatma AKALIN^{1*}, Nejat YUMUŞAK²

¹Bilişim Sistemleri Mühendisliği Bölümü, Bilgisayar ve Bilişim Bilimleri Fakültesi, Sakarya Üniversitesi, Sakarya, Türkiye.
fatmaakalin@sakarya.edu.tr

²Bilgisayar Mühendisliği Bölümü, Bilgisayar ve Bilişim Bilimleri Fakültesi, Sakarya Üniversitesi, Sakarya, Türkiye.
nyumusak@sakarya.edu.tr

Geliş Tarihi/Received: 07.12.2022
Kabul Tarihi/Accepted: 12.06.2023

Düzeltilme Tarihi/Revision: 01.06.2023

doi: 10.5505/pajes.2023.90602
Araştırma Makalesi/Research Article

Öz

Gastrointestinal bölgede yer alan anomalilerin teşhisi güncel bir araştırma alanıdır. Bu bölgenin incelenmesi için kablosuz kapsül endoskopi (WCE), geleneksel endoskopi risklerini önlemek ve ağrısız bir süreç sağlamak amacıyla tercih edilen alternatif bir teknolojidir. Fakat birçok avantaja sahip bu teknoloji, düşük çerçeve yoğunluğu sunmaktadır. Verilerin kalitesini etkileyen bu durum, teşhis doğruluk oranının düşmesine neden olmaktadır. Bu çalışmada KID Atlas Veri kümesi 2'den elde edilen WCE endoskopi görüntüleri kullanılmış ve gastrointestinal bölgedeki inflammatory anormali, vascular anormali, polypoid anormali ve normal görüntü kategorilerinin tespiti için üç aşamalı yapay zeka destekli bir tanı süreci geliştirilmiştir. İlk aşama için 5 farklı yaklaşım kullanılarak görüntüler üzerindeki kritik noktalar belirlenmiştir. İyileştirilen bu görüntüler, bölge öneri temelli bir nesne tanıma algoritması ile sınıflandırılmıştır ve kullanılan yaklaşımlara göre performans karşılaştırması yapılmıştır. İkinci aşamada, ilk aşamada maksimum performans gösteren iyileştirilmiş verilere görüntü çoğaltma tekniği uygulanmıştır. Böylece dengeli ve yeterli sayıda görüntü içeren bir veri kümesi oluşturulmuştur. Üçüncü aşamada bu güncel veri kümesi beş ayrı nesne tanıma algoritması ile sınıflandırılmıştır. Ancak her bir algoritmanın sahip olduğu bireysel başarı farklıdır. Bu nedenle her bir kategori için kararlı çıktılar elde etmek ve kategoriler arasında dengeli bir tespit süreci oluşturmak için topluluk öğrenme yaklaşımı kullanılmıştır. Son olarak inşa edilen bu hibrit yapı ile kategoriler arasında dengeli ve kararlı bir tahmin işlevi sağlanmıştır.

Anahtar kelimeler: Gastrointestinal anomaliler, Kablosuz kapsül endoskopi, Derin öğrenme, Topluluk öğrenme

Abstract

Diagnosis of anomalies in the gastrointestinal tract is a current research area. Wireless capsule endoscopy (WCE) for the evaluation of this region is a preferred alternative technology to avoid the risks of traditional endoscopy and to provide a painless process. But this technology, which has many advantages, offers low frame density. This situation affects the quality of the data and causes to a decrease in the diagnostic accuracy rate. In this study, WCE endoscopy images obtained from KID Atlas Dataset 2 were used and a three-stage artificial intelligence-supported diagnostic process was developed for the detection of the inflammatory anomaly, vascular anomaly, polypoid anomaly and normal image categories in the gastrointestinal tract. For the first stage, critical points on the images were clarified using 5 different approaches. These improved images were classified with a region proposal-based object recognition algorithm and performance comparison was made according to the approaches used. In the second stage, the data augmentation technique was applied to the improved images that showed maximum performance in the first stage. Thus, a dataset with a balanced and sufficient number of images was created. In the third stage, this current dataset was classified with five different object recognition algorithms. However, the individual success of each algorithm is different. For this reason, the ensemble learning approach was used to obtain stable outputs for each category and to create a balanced detection process among the categories. Finally, a balanced and stable estimation function was provided between categories with this hybrid structure.

Keywords: Gastrointestinal anomalies, Wireless capsule endoscopy, Deep learning, Ensemble learning

1 Giriş

Gastrointestinal (GI), besin öğelerini sindiren, işleyen ve sindirilmeyen kalıntıları vücuttan uzaklaştırmaya yardımcı olan bir sistemdir. Gastrointestinal sistem de ağız, özafagus, mide, ince bağırsaklar, kalın bağırsaklar, rektum ve anüs yer almaktadır [1]. Bu sisteme ilişkin hastalıklar, insanlarda yaygın olarak görülmektedir. Aynı zamanda kanama, bağırsak maligniteleri, Crohn hastalığı, ülserler, kolon polipleri ve çölyak hastalığı gibi ciddi sağlık sorunlarının da meydana gelme ihtimali vardır. GI hastalıklarının teşhisi, muayenesi ve GI kanalının araştırılması için gastrointestinal endoskopi tıp dünyasında tercih edilen temel bir yöntemdir [2][3][4].

Canlı dokuya ilişkin patolojik bir teşhis sağlayan gastrointestinal endoskopi(GIE), gastrointestinal sistemin araştırılması ve lümen patolojisinin tespitinde kullanılmaktadır[3].Anomalilerin teşhisi için tıpta yaygın olarak kullanılan prosedürler, gastroskopi ve kolonoskopidir[2][3][4]. Gastroskopi ve kolonoskopi yöntemleri sırasıyla gastrointestinal sistemin üst ve alt kısımlarını değerlendirmek için tercih edilmektedir[4]. Uzun, esnek bir kablo ve kameradan oluşan bu yöntemler için oral veya rektal açıklar ile vücuda giriş sağlanmaktadır. Ardından kablo, hedef bölgeye doğru itilmektedir. Ancak bu yaklaşımlar hastaya acı veren, zahmetli ve zaman alıcı bir süreci oluşturmaktadır. Aynı zamanda kalifiye bir tıp uzmanının gözetiminde gerçekleştirilmesi gerekmektedir. Bu sınırlamaların üstesinden gelebilmek amacıyla 2000'li yılların

*Yazışılan yazar/Corresponding author

başında ortaya çıkan [5] mikro boyutlu kamera ve pilden oluşan kablosuz elektronik kapsül geliştirilmiştir. Halk arasında kablosuz kapsül endoskopi(WCE) olarak bilinen bu yapı[2] yutulabilir bir kapsülden meydana gelmektedir. Kapsül, hasta tarafından yutulduktan sonra kamera ile video akışı oluşmakta ve hastanın vücuduna bağlı kayıt ünitesine radyo frekansı iletimi gönderilmektedir. Gelişmiş yazılımlar kullanılarak yeniden oluşturulan görüntüler ile doktorların değerlendirme süreci sağlanmaktadır[2][6]. Özellikle gastrointestinal sistemin alt ve üst kısımları arasındaki ince bağırsak lezyonlarının tespiti için kullanılan WCE yöntemi, geleneksel endoskopinin risklerini önlemekte ve ağrısız bir süreç sağlamaktadır[4]. Bununla birlikte sindirim sisteminin görselleştirilmesinde alternatif ve başarılı bir yaklaşım olarak görülen WCE, düşük video kalitesi sunmaktadır. Bu durum teşhis doğruluğunu doğrudan etkilemektedir [2].

Son yıllarda WCE görüntüleri vasıtasıyla anormal bölgelerin tespiti ve lokalizasyonu için derin öğrenme yöntemi umut verici bir yaklaşım olarak tercih edilmektedir [3][7][8]. Ancak dokulardaki anormalliklerin karmaşıklığı ve örüntülerin hastalıklarla ilişkilendirilmesi halen zorlu bir problem olarak görülmektedir[7].

Bu nedenle sunulan çalışmada derin öğrenme alanındaki hızlı gelişmeler ile birlikte geleneksel mimarilerin daha derin özellikleri öğrenebilmesi hedefi kapsamında geliştirilen nesne tanıma yapısı kullanılmıştır. Bölge önerisi tabanlı değerlendirme yaklaşımını kullanan nesne tanıma algoritmaları ile her bir görüntüye ilişkin gerçek zamanlı çıktılar elde edilmiştir. Fakat algoritmaların mimarisine bağlı olarak gerçekleştirilen eğitim sonucunda kategoriden kategoriye veya örnekten örneğe değişen bir başarıım eğrisi oluşmuştur. Her bir kategori için dengeli ve istikrarlı çıkarımlar üretmek modelin güvenilirliğini arttıracak için farklı algoritmalar vasıtasıyla ulaşılan sonuçların kararlılığının geliştirilmesi gerekmektedir. Bu amaç çerçevesinde topluluk öğrenme yaklaşımı kullanılmıştır. Topluluk öğrenme yaklaşımı kullanılarak ulaşılan sonuçlar, gastrointestinal sisteme ilişkin anomalilerin tespitinde her bir kategori için dengeli bir tahmin işlevi gerçekleştirildiğini göstermektedir.

2. İlgili Çalışmalar

Gastrointestinal anomalilerin tespitine ilişkin bilgisayar destekli farklı birçok çalışma bulunmaktadır. Bu çalışmaların temel amacı uzmanlık gerektiren, zaman alıcı ve yüksek maliyet sunan geleneksel yöntemlere [9] kıyasla efektif çıktılar üretmektir. Bu amaç çerçevesinde literatürdeki çalışmalar incelenmiştir ve karşılaştırmalar sağlanmıştır. Bu doğrultuda zayıf denetimli evrimsel sinir ağı (WCNN) ve yinelemeli küme birleştirme (ICU) algoritması kullanılan [3] çalışmada, gastrointestinal anomalilerin otomatik tespiti ve lokalizasyonu sağlanmıştır. Anomalilerin saptanması ve yerinin belirlenmesinde elde edilen maksimum AUC değerleri sırasıyla geleneksel gastroskopi görüntüleri için %96 ve WCE görüntüleri için %88'dir. Kolonoskopi görüntülerinden elde edilen görüntü ve videoların kullanıldığı [10] çalışmada Inception Resnet mimarisi kullanılarak birleştirilen Faster R-CNN mimarisi ile görüntü ve videolar için kesinlik, duyarlılık ve reaksiyon süresine ilişkin bir tespit işlevi sağlanmıştır. Endoskopik video görüntüleri ile kolorektal poliplerin değerlendirildiği [11] çalışması için derin evrimsel sinir ağı modeli kullanılmıştır. Eğitim sonucunda modelin ulaştığı doğruluk oranı %94'tür. WCE görüntülerinde gastrointestinal kanama tespiti için [12] çalışmada derin evrimsel sinir ağı temelli bir yaklaşım önerilmiştir. Ulaşılan duyarlılık, kesinlik ve

F1 kriteri oranları sırasıyla 0.9920, 0.9990 ve 0.9955'tir. Mide kanserinin tespit ve tedavisi için VGG16, InceptionV3 ve InceptionResNetV2 aktarım öğrenme mimarileri kullanılarak normal mide görüntüleri ve EGC görüntülerinin sınıflandırılması [13] çalışmada sağlanmıştır. 4 farklı deney sonucunda üretilen maksimum başarı, duyarlılık ve özgüllük oranları ince ayarı yapılan InceptionV3 mimarisi ile sırasıyla 0.985, 0.981 ve 0.989 olarak bulunmuştur. Kolonoskopi videoları ile otomatik polip tespitinin sağlandığı [14] çalışması ile yeni çevrimdışı ve çevrimiçi 3D derin öğrenme entegrasyon çerçevesi önerilmiştir. Önerilen bu yaklaşımın ASU-MAYO veri kümesinde ürettiği kesinlik ve duyarlılık oranları sırasıyla %88.1 ve %71.0'dır. Endoskopik videolar kullanılarak GI anomalilerin otomatik denetimi, tespiti ve sınıflandırılmasının hedeflendiği [15] çalışmada öznetelik çıkarma teknikleri ve derin öğrenme yöntemlerinin kapsamlı bir değerlendirilmesi yapılmıştır. WCE veri kümesinde otomatik GI kanama tespitinin hedeflendiği [16] çalışmada yeni Saliency-Aware hibrit ağı (SHNet) yaklaşımı önerilmiştir. GI kanamalarının tespiti için önerilen yöntemin F1 skoru 0.959'dur. WCE verilerinden anormali tespiti ve sınıflandırması için yarı denetimli derin öğrenme modeli olan Dikkat ve Alan Destekli Çekişmeli Üretici Ağ (ADA-GAN) yaklaşımının önerildiği [17] çalışmada, önerilen yaklaşım ile yeterli olmayan etiketli veri kümesi problemine çözüm sağlandığı belirtilmiştir. Endoskopik görüntüler vasıtasıyla gastrointestinal anomalilerin tanımlanması için [9] çalışmada DCNN mimarisi önerilmiştir. Önerilen DCNN mimarisi ile efektif çıktılar üretildiği belirtilmiştir. Gastrointestinal sisteme ilişkin bozuklukların sonucu olan kolorektal kanserinde, kolorektal öncesi kanserlerin tespiti, sınıflandırılması ve lokalizasyonu için [18] çalışmada bir yaklaşım sunulmuştur. SSD, YOLOv4 ve YOLOv5 nesne algılama modellerinin kullanıldığı bu yaklaşımda maksimum performans YOLOv5 çerçevesi ile elde edilmiştir. WCE görüntüleri vasıtasıyla şüpheli lezyonların aynı anda lokalize edilmesini sağlayan iki dallı AGDN yaklaşımı [8] çalışmada sunulmuştur. Halka açık WCE veri kümesi kullanılarak gerçekleştirilen çalışma sonucunda %91,29'luk genel doğruluk oranı elde edilmiştir.

Bilim dünyasında gastrointestinal anomalilerin endoskopik görüntüler kullanılarak tanımlanması deneyimli personeller tarafından dahi zorlu bir görev olarak nitelendirilmektedir[9]. Bunun için gastroenteroloji alanında gerçekleştirilen manuel değerlendirme sürecinde uzmanlar için destek sağlamak bilişim alanının önemli bir amacıdır. Öte yandan yapay zeka çerçevesi, görüntülerin doğru bir şekilde değerlendirilmesinde güçlü bir potansiyele sahiptir[15][19]. Bu nedenle literatürde GI sisteme ilişkin rahatsızlıkların yapay zeka destekli sistemler ile tespitine yönelik çalışmalar gerçekleştirilmiştir. Tüm bu çalışmaların ortak paydası efektif değerlendirme sağlamaktır. Bu nedenle sunulan çalışma kapsamında üç önemli nokta güçlendirilmiştir. İlk olarak geleneksel derin öğrenme yaklaşımlarına kıyasla daha derin çıkarımlar yapılabilmesi için nesne tespit algoritmaları kullanılmıştır. İkinci olarak kararlı, istikrarlı ve dengeli bir tespit süreci inşa etmek için topluluk öğrenme sürecinden faydalanılmıştır. Üçüncü olarak, gerçek zamanlı çıktılar üreten bu sistem ile ivedi tespit gerektiren durumlar için bir çözüm üretilmiştir.

3 Metodoloji

Bu bölümde inflammatory anormali, vascular anormali, polypoid anormali ve normal görüntü kategorilerinin sınıflandırılmasında kullanılan bir yaklaşım sunulmaktadır. Bu

yaklaşım kapsamında veri kümesinin formatı, ön işleme süreci ve sınıflandırma yöntemi aşağıda açıklanmıştır.

3.1 Veri kümesi

Bu çalışmada KID Dataset 2 kullanılmıştır. Veri kümesini oluşturan WCE görüntüleri, MiroCam kapsül endoskopi ile mide bağırsak yolundan elde edilmiştir. 360x360 piksel çözünürlüğüne sahip olan toplam görüntü sayısı 2.352'dir. 4 ayrı kategoride değerlendirilen bu veriler; 303 adet vasküler anomali, 44 adet polypoid anomali, 227 adet inflammatory anomali ve 1778 adet normal kategoriye ilişkin görüntülerden oluşmaktadır[3].

İlk aşamada görüntü kategorilerine ilişkin dengesiz bir orana sahip olan KID Dataset 2 kapsamında görüntüler, veri kümesinden dengeli bir şekilde tedarik edilmiştir. Bu tedarik aşamasında inflammatory anomali, vascular anomali, polypoid anomali ve normal sınıflar için sırasıyla 55, 55, 44 ve 55 adet görüntü verileri kategorilere ilişkin tüm görüntüler arasından rastgele seçilmiştir ve yeni bir veri kümesi oluşturulmuştur.

İkinci aşamada, derin öğrenme temelli sinir ağı yapıları ile 4 ayrı sınıfa ilişkin görüntü ve desenlerin güçlü bir şekilde öğrenilmesi için veri çoğaltma yaklaşımı ile verilerin artırılması hedeflenmiştir. Bu nedenle, 44 adet görüntünün yer aldığı polypoid kategorisi ile 227 adet görüntünün yer aldığı inflammatory kategorisine ilişkin görüntüler; yatay çevirme, dikey çevirme, döndürme, kırpma, gürültü ekleme, kontrast değiştirme, elastic, polar ve jigsaw tekniklerinin uygulanması ile artırılmıştır. Böylece her bir kategorinin sahip olduğu görüntü sayısı 300'e tamamlanmıştır ve toplam 1200 adet görüntüden oluşan ikinci bir veri kümesi oluşturulmuştur.

Eğitim aşamasında kategorilere ilişkin başarılı bir eğitim süreci sağlamak amacıyla veri kümesi eğitim ve test kümesi olarak %80 ve %20 oranlarında ayrılmıştır. Eğitim ve test kümesi için ayrılan görüntüler veri kümesinden rastgele seçilmiştir. Fakat bilgi sızıntısını önlemek amacıyla veri çoğaltma yaklaşımı ile artırılan görüntüler aynı küme içerisinde yer almamıştır.

Bu kısımda tıbbi karar destek sistemlerinin inşa edilmesine katkı sağlayan KID Dataset 2 ile gerçek zamanlı ve bilgisayar destekli güvenilir bir sistem oluşturmak [20] amacıyla dengeli bir veri kümesi inşa edilmiştir.

3.2 Ön İşleme Süreci

Ön işleme, eğitim kümesinde aynı kategoride değerlendirilen verilerdeki metadataların konumunu, benzerliğini ve yoğunluğunu ortaya çıkarmak amacıyla gerekli bir adımdır[21][22][23]. Özellikle görüntüden otomatik özellik çıkarımı sağlayan derin öğrenme temelli yaklaşımların başarı oranını iyileştirmek amacıyla tercih edilmektedir. Bu çalışmada 4 ayrı sınıfa ilişkin görüntüler, 4 farklı teknik ile yeniden ifade edilmiştir. Böylece görüntülerdeki metadatalara ilişkin önemli ayrıntılar kategoriler ile ilişkilendirilmiştir. Aynı zamanda [24] çalışmasında da görüntüler üzerinde gerçekleştirilen ön işleme aşamasının nihai tespit doğruluğu üzerinde bir iyileştirme sağladığı belirtilmektedir. Bu doğrultuda ön işleme aşaması uygulanan orijinal görüntü sırasıyla gri tona çevrilen görüntü, kenarları saptanan görüntü, köşeleri saptanan görüntü ve CLAHE yaklaşımı uygulanan görüntü olarak yeniden ifade edilmiştir. Ön işleme süreci uygulanan bu görüntülerin görsel temsili Şekil 1'de sunulmaktadır.




Şekil 1. Orijinal görüntünün 4 farklı yaklaşım ile ifade edilmesi.

Figure 1. Expressing of the original image with 4 different approaches.

Şekil 1'de gösterildiği gibi farklı iyileştirme yaklaşımı kullanılarak oluşturulan veriler; inflammatory anomali, vascular anomali, polypoid anomali ve normal kategorileri için sırasıyla 55, 55, 44 ve 55 adet ve toplam 209 adet görüntü barındıran veri kümesi ile sınıflandırılmıştır. Sınıflandırma işlevi için nesne tanıma yaklaşımı olan Detectron2 çerçevesi kapsamında Faster R-CNN R50-FPN ön eğitilmiş modeli kullanılmıştır. 3000 iterasyon boyunca gerçekleşen eğitimde yığın sayısı 4 ve öğrenme oranı 0.01 olarak belirlenmiştir. Öğrenme oranı 500 iterasyonda bir 0.05 değeri ile çarpılarak azaltılmıştır. Böylece eğitilen modelin aşırı öğrenme probleminden kaçınılması hedeflenmiştir.

Sınıflandırma sonucunda orijinal veriler, gri tona çevrilen veriler, kenarları saptanan veriler, köşeleri saptanan veriler ve CLAHE yöntemi ile iyileştirilen veriler için sırasıyla %45.31, %42.18, %40.62, %56.25 ve %54.6875 doğruluk oranları elde edilmiştir. Sonuçlar doğrultusunda en başarılı çıktılar, köşeleri saptanan ve CLAHE yöntemi ile iyileştirilen veriler için elde edilmiştir. Bu nedenle çalışmanın ikinci aşamasında, aynı görüntü ilk olarak CLAHE yöntemi ile iyileştirilmiş ve ardından görüntülerdeki köşeler saptanmıştır. Uygulanan bu hibrit yaklaşım sonucunda elde edilen veriler Şekil 2'de gösterilmektedir.



Şekil 2. Orijinal görüntüye hibrit ön işleme aşamasının uygulanması sonucunda elde edilen çıktılar

Figure 2. Outputs obtained as a result of applying the hybrid preprocessing step to the original image

Inflammatory anomali, vascular anomali, polypoid anomali ve normal sınıfa ilişkin kategoriler için görüntülere uygulanan hibrit yöntemin tekrar Faster R-CNN R50-FPN ön eğitilmiş modeli ile sınıflandırılmasının sonucunda %57.81 doğruluk oranı elde edilmiştir. Diğer görüntü iyileştirme yaklaşımlarına kıyasla daha başarılı olan hibrit yöntem, ikinci değerlendirme sürecinde kullanılan veriler için tercih edilen ön işleme aşaması olarak belirlenmiştir.

4 Araştırma Bulguları ve Tartışma

Tıbbi görüntülerdeki anatomik ayrıntıların bilgisayar destekli sistemler ile teşhis edilmesi önemli bir konudur. Özellikle gastrointestinal sisteme ilişkin hastalıkların endoskopik görüntüler ile teşhisi için aktif bir araştırma alanı mevcuttur[25]. Bu nedenle bu çalışmada gastrointestinal sistemde oluşan inflammatory anomali, vascular anomali, polypoid anomali ve normal hasta kategorilerinin sınıflandırılmasını hedeflemiştir. Bu doğrultuda ilk olarak

görüntülerdeki kritik noktaların, yoğunlukların ve metadatalara ilişkin konumların netleştirilmesi amacıyla ön işleme aşaması gerçekleştirilmiştir. 5 farklı ön işleme aşaması ile elde edilen 209 farklı görüntü, Detectron2 çerçevesi kapsamında yer alan algoritmalar ile sınıflandırılmıştır. Sınıflandırma sonucunda en başarılı performans CLAHE yöntemi ile iyileştirilen görüntüler üzerinde köşe kısımların tespitinin sağlandığı hibrit yaklaşım ile elde edilmiştir. Çalışmanın ikinci aşamasında, ilk aşamada en başarılı performans gösteren hibrit yaklaşım ile elde edilen görüntüler veri çoğaltma yaklaşımı ile artırılmıştır. Ardından 1200 adet görüntü içeren güncel veri kümesi Detectron2 nesne tanıma çerçevesi kapsamında farklı algoritmaların kullanıldığı ön eğitilmiş modeller ile eğitilmiştir ve görüntülere ilişkin bir tahmin yapılmıştır.

Detectron2, bölge önerisi temelli değerlendirme yaklaşımını kullanan nesne tanıma çerçevesidir. Regresyon/sınıflandırma temelli değerlendirme yaklaşımlarını kullanan nesne tanıma algoritmalarına kıyasla daha az yerelleştirme hatası üretmektedir. Bu durum, görüntüler üzerinde nesne tespit başarısını pozitif yönde etkileyen bir durumdur[26]. Bu çalışmada Faster R-CNN R101-FPN, Faster R-CNN X101-FPN, Faster R-CNN R50-FPN, Mask R-CNN R101-FPN ve Cascade Mask R-CNN R50-FPN önceden eğitilmiş nesne tanıma modelleri kullanılmıştır. Önceden eğitilmiş bu mimariler ile hedef test veri kümesi üzerinde ulaşılan performans metrikleri Tablo 1’de verilmiştir.

Tablo 1’de, Detectron2 çerçevesi ile eğitilen mimarilerin tespitine ilişkin kesinlik (Ksn.), duyarlılık (Dyr.) ve F kriteri (F Kr.) ölçütlerinin sonuçları yer almaktadır. Kesinlik, tüm kategorilere ilişkin tahminler arasında mevcut verinin doğru tahmin edilme oranıdır. Duyarlılık, aynı kategoriye ilişkin tahminler arasında mevcut verinin doğru tahmin edilme oranıdır. F kriteri, kesinlik ve duyarlılık ölçütlerinin harmonik ortalamasıdır ve aykırı değerlerin dikkate alınmasını sağlar[21]. Tüm bu ölçütlerin %100 ya da %100’e yakın olması ulaşılan sonucun başarılı olduğunu göstermektedir.

Tablo 1’de önceden eğitilmiş her bir mimari için test veri kümesinde ulaşılan duyarlılık, kesinlik ve F ölçütü kriterleri incelenmiştir. Bu kriterlere ilişkin sonuçlara göre her bir mimarinin maksimum başarı gösterdiği bir kategori bulunmaktadır. Bu durum genel ortalamayı iyileştirmiştir. Fakat kategoriler kapsamında hedefe yönelik dengesiz bir tespit süreci sunmuştur. Bu çalışmada kategori çapında maksimum başarı gösteren mimarilerin kolektif öğrenme yaklaşımı ile birlikte kullanılması ve hedef çıktının iyileştirilmesi planlanmaktadır. Bu amaçla ilk olarak Faster R-CNN R101-FPN, Faster R-CNN X101-FPN, Mask R-CNN R101-FPN ve Cascade Mask R-CNN R50-FPN önceden eğitilmiş modellerinin sonuçları birlikte değerlendirilmiştir ve Topluluk Öğrenme1 ismi ile ulaşılan sonuçlar Tablo 2’de verilmiştir. Ardından topluluk öğrenme yaklaşımı ile gerçekleştirilen nesne tespit başarısının pozitif olarak artmasını incelemek amacıyla Faster R-CNN R50-FPN mimarisi kolektif öğrenme yaklaşımına dahil edilmiştir. Beş ayrı mimarinin birlikte kullanılması ile ulaşılan sonuçlar Topluluk Öğrenme2 ismi ile Tablo 2’de sunulmuştur.

5 ayrı mimari kullanılarak gerçekleştirilen değerlendirme sonucunda Inflammatory, Polypoid, Vascular ve Normal kategorilere ilişkin tahminler için başarılı ve dengeli bir sınıflandırma gerçekleştirilmiştir. Bu durum bir kategoriye ilişkin yüksek tahmin oranı ile genel doğruluk oranının yükselmesinin aksine her bir kategori için benzer sonuçların üretilmesi ve genel doğruluk oranına yakın çıktılar elde edilmesini sağlamıştır. Kararlı ve istikrarlı sonuçların üretilmesinde etkisi olan topluluk öğrenme yaklaşımının metodoloji kısmı ile birlikte hibrit kullanımını özetleyen genel çerçevesi Şekil 3’te verilmiştir.

Tablo 1. Bölge önerisi temelli nesne tespit algoritmaları kullanılarak elde edilen değerlendirme ölçütleri


Table 1. Evaluation criteria obtained using site region proposal-based object detection algorithms

Criteria	Inflammatory			Polypoid			Vascular			Normal		
	Ksn.	Dyr.	F kr.	Ksn.	Dyr.	F kr.	Ksn.	Dyr.	F kr.	Ksn.	Dyr.	F kr.
Faster R-CNN R101-FPN	0.397	0.583	0.472	0.710	0.816	0.759	1	0.083	0.153	0.615	0.8	0.095
Faster R-CNN X101-FPN	0.428	0.5	0.461	0.767	0.716	0.740	0.525	0.516	0.520	0.727	0.666	0.695
Faster R-CNN R50-FPN	0.857	0.3	0.444	0.792	0.7	0.743	0.443	0.85	0.582	0.784	0.666	0.7201
Mask R-CNN R101-FPN	0.625	0.6	0.612	0.829	0.65	0.728	0.489	0.783	0.602	0.617	0.833	0.708
Cascade Mask R-CNN R50-FPN	0.418	0.383	0.428	0.687	0.733	0.709	0.391	0.483	0.432	0.659	0.516	0.578

Tablo 2. Topluluk öğrenme yaklaşımı kapsamında elde edilen değerlendirme ölçütleri

Table 2. Evaluation criteria obtained in scope of the ensemble learning approach

Criteria	Inflammatory			Polypoid			Vascular			Normal		
	Ksn.	Dyr.	F kr.	Ksn.	Dyr.	F kr.	Ksn.	Dyr.	F kr.	Ksn.	Dyr.	F kr.
Topluluk Öğrenme1	0.648	0.583	0.613	0.818	0.75	0.782	0.672	0.683	0.677	0.685	0.685	0.685
Topluluk Öğrenme2	0.804	0.616	0.697	0.821	0.766	0.792	0.658	0.866	0.747	0.796	0.78	0.787



Şekil 3. Derin öğrenme tabanlı topluluk sınıflandırıcısı yaklaşımının genel çerçevesi

Figure 3. General framework of deep learning-based ensemble classifier approach

Şekil 3'te verilen genel çerçevede ilk olarak orijinal görüntülerden metadatalara ilişkin önemli ayrıntıların kategoriler ile eşleştirilmesi için 4 ayrı görüntü işleme yaklaşımı kullanılmıştır. Daha sonra işlenen görüntüler sınıflandırılmıştır. Sınıflandırma sonucunda en başarılı çıktılar, köşeleri saptanan ve CLAHE yöntemi ile iyileştirilen veriler için elde edilmiştir. Bu nedenle çalışmanın sonraki aşamasında, CLAHE yöntemi ile iyileştirilen orijinal görüntüler üzerinde köşelerin saptanmasını sağlayan ön işleme aşaması uygulanmıştır ve diğer ön işleme aşamalarının sınıflandırma sonuçlarına kıyasla maksimum başarı elde edilmiştir. Ardından hibrit ön işleme aşaması ile elde edilen görüntüler veri çoğaltma yaklaşımı kapsamında artırılmıştır. Son olarak her bir kategori için eşit sayıda görüntü bulunan güncel veri kümesi, bölge önerisi tabanlı nesne tanıma algoritmaları ile sınıflandırılmıştır. Her bir algoritmaya ilişkin değerlendirme sonuçları incelendiğinde belirli kategoriler için tahmin doğruluğunun daha yüksek olduğu tespit edilmiştir. Kategoriler arasında dengesiz tahmin gücü ile genel doğruluk oranının yükselmesinin aksine her bir kategori için benzer sonuçların üretilmesi ve genel doğruluk oranına yakın çıktılar elde edilmesi amaçlanmıştır. Bu doğrultuda her bir algoritmadan üretilen sonuçlar arasında oylama yapmak suretiyle ana çıktıyı etkileyen topluluk öğrenme yaklaşımı kullanılmıştır. Bu yapıda eşit sayıda oy alınması durumunda nesne tespit algoritmaları tarafından hedef nesne için üretilen tespit doğrulukları incelenmektedir ve ardından yüksek tespit doğruluğuna sahip kategori sınıfına atama yapılmaktadır.

Topluluk öğrenme yaklaşımı kararlı ve istikrarlı bir öğrenme için önemli bir yapıdır. Ancak seçilen mimarilerin eğitiminde kullanılan hiperparametrelere ince ayar verilmesi de hedef sonucu güçlendirmektedir. Bu nedenle topluluk öğrenme yaklaşımı kapsamında kullanılan algoritmalar için varsayılan parametrelere ek olarak 3000 iterasyon boyunca gerçekleşen eğitimde yığın sayısı 4 ve öğrenme oranı 0.01 olarak belirlenmiştir. Öğrenme oranı 500 iterasyonda bir 0.05 değeri

ile çarpılarak azaltılmıştır. Böylece eğitilen modelin aşırı öğrenme probleminden kaçınılması hedeflenmiştir.

Literatürde gastrointestinal bölgeye ilişkin anomalilerin tespiti için farklı yaklaşımlar kullanan birçok çalışma [3] [27] [28] [29] [30] [7] [12] [31] [32] Tablo 3'te verilmiştir.

Tablo 3'te verilen çalışmalar kapsamında gastrointestinal bölgede yer alan anomalilerin tespitine yönelik araştırmalar yapılmıştır. Derin sinir ağı yapıları ya da makine öğrenmesi üzerinde temellenen bu araştırmalar ile uzmanlık gerektiren, zaman alıcı ve yüksek maliyet sunan [9] geleneksel yöntemlere kıyasla yeni yaklaşımlar geliştirilmiştir.

Fakat derin öğrenme alanındaki hızlı gelişmeler ile birlikte geleneksel mimarilerin daha derin özellikleri öğrenebilmesi hedeflenmiştir. Bu hedef doğrultusunda derin öğrenmeye dayalı nesne tanıma çerçeveleri geliştirilmiştir. Bu nesne tanıma çerçeveleri sırasıyla regresyon/sınıflandırma temelli ve bölge önerisi temelli değerlendirme yaklaşımlarını içermektedir. Bu yöntemler arasında regresyon/sınıflandırma temelli yaklaşımlar bölge önerisi tabanlı yaklaşımlardan daha fazla yerleştirme hatası üretmektedir. Bu durum görüntüler üzerinde nesne tespit sürecini etkileyen önemli bir faktördür[26]. Bu nedenle bu çalışmada bölge önerisi temelli nesne tanıma algoritmaları kullanılmıştır.

Ek olarak bölge önerisi temelli Detectron2 yaklaşımı kapsamında farklı algoritmaların kullanıldığı ön eğitilmiş modeller ile gerçekleştirilen eğitimlerde test veri kümesi üzerinde farklı kategoriler için elde edilen doğruluk oranları değişiklik göstermektedir. Algoritmalara bağlı olarak değişen eğitim başarısı ve tespit doğruluğu bireysel olarak değerlendirilen mimarilerin gücüne ilişkin bir çıktı sunmaktadır.

Tablo 3. Gastrointestinal bölgede yer alan anomalilerin tespitine ilişkin çalışmalar

Table 3. Studies related to the detection of anomalies in the gastrointestinal tract

Makale	Amaç	Yöntem
[3]	Gastrointestinal (GI) anomalilerin otomatik tespiti ve lokalizasyonu	WCNN+ICU yöntemleri
[12]	Gastrointestinal (GI) kanama tespiti	Derin evrişimli sinir ağı üzerinde temellenen otomatik kanama algılama stratejisi
[27]	Inflammatory gastrointestinal lezyonların tespiti	Evrişimsel sinir ağı üzerinde temellenen zayıf denetimli öğrenme yöntemi
[28]	Gastrointestinal görüntülerde çok kategorili hastalıkların sınıflandırılması	Anormal özellik dikkat ilişki ağı (AFA-RN)
[29]	Gastrointestinal sistemdeki hastalıkların segmentasyonu ve sınıflandırılması	DH-DSU tabanlı gizli nöron optimizasyonu ile geliştirilmiş derin sinir ağı
[30]	WCE görüntüleri vasıtasıyla anomali tespiti	Hibrit sinir ağı yaklaşımı
[7]	WCE görüntülerinde anomali tespiti ve lokalizasyonu	WCENet segmentasyon modeli
[31]	WCE görüntülerinde polip tespiti	Geliştirilmiş özellik çantası (bag of feature - BoF) yöntemi
[32]	Endoskopik görüntülerde polip segmentasyonu	Uyarlanabilir Markov Rastgele Alan (MRF) tabanlı çerçeve yaklaşımı
Önerilen Yöntem	Kablosuz kapsül endoskopi yardımıyla gastrointestinal bölgedeki inflammatory anomali, vasküler anomali, polypoid anomali ve normal görüntü kategorilerinin tespiti	Bölge önerisi temelli nesne tespit algoritmaları ve topluluk öğrenme yaklaşımının birlikte kullanımı

Bu çıktının niteliği kategoriden kategoriye ve örnekten örneğe değişmektedir. Dolayısıyla tüm bu çıktıların birlikte kullanılması ana hedefe yönelik kararlı sonuçların üretilmesini sağlayacaktır. Bu doğrultuda topluluk öğrenme yaklaşımı kullanılmıştır. Böylece nesne tanıma işlevinin performansı geliştirilmiştir ve istikrarlı çıktılar üretilmiştir. Öte yandan

kesinlik, duyarlılık ve F kriteri ölçütleri ile birlikte değerlendirildiğinde tahmin edilen çıktılar arasında dengesizlik olmadığı görülmektedir. Bu durum önerilen model ile tespit edilen görüntülerin tüm kategoriler üzerinde dengeli bir tahmin işlevi sağladığına işaret etmektedir.

Üç kritik kısmın güçlendirildiği bu çalışmanın ilk aşamasında farklı ön işleme seviyeleri kullanılarak görüntülerin niteliği artırılmıştır. İkinci aşamada, dengeli bir veri kümesi oluşturularak daha hassas çıktılar üretilmiştir. Üçüncü aşamada derin öğrenmeye dayalı Detectron2 nesne tanıma çerçevesi kapsamında farklı algoritmaların kullanıldığı ön eğitilmiş modeller ile eğitimler gerçekleştirilmiş ve topluluk öğrenme yaklaşımı ile eğitim sonuçları değerlendirilmiştir. Nihai durumunda başarılı, istikrarlı ve kararlı çıktılar elde edilmiştir ve tespit doğruluğu iyileştirilmiştir. Genel performans üzerinde bir iyileştirme sağlayan bu çalışmanın literatüre katkı sağlayacağı düşünülmektedir.

5 Sonuçlar

Bu çalışmada gastrointestinal bölgedeki inflammatory anomali, vasküler anomali, polypoid anomali ve normal görüntülerin sınıflandırılması için derin öğrenme temelli bir yaklaşım sunulmuştur. Bu doğrultuda ilk olarak KID dataset 2 veri kümesi kapsamında 4 ayrı kategoriye ilişkin görüntülerdeki kritik noktaların belirginleşmesi için 5 farklı ön işleme tekniği kullanılmıştır. Bu ön işleme teknikleri ile iyileştirilen veriler, önceden eğitilmiş bölge önerisi temelli nesne tanıma algoritması ile sınıflandırılmıştır. Sınıflandırma sonucunda maksimum performans gösteren görüntüler, veri çoğaltma yaklaşımı ile artırılmıştır. Ardından kritik noktaları netleştirilmiş görüntüler ile oluşturulan dengeli ve yeterli veri kümesi, derin öğrenmeye dayalı önceden eğitilmiş farklı nesne tanıma algoritmalarına girdi olarak verilmiştir. Ancak algoritmalarla özgü olarak değişen tespit başarıları kategoriler ve örnekler arasında farklı başarımlar çıktılarını sunmaktadır. Bu nedenle her bir kategori için kararlı çıktılar elde etmek ve kategoriler arasında dengeli bir tespit süreci inşa etmek için sonraki aşamada topluluk öğrenme yaklaşımı tercih edilmiştir. İnşa edilen bu hibrit yapı ile tüm kategoriler arasında dengeli ve kararlı bir tahmin işlevi gerçekleştirilmiştir.

Bu çalışmada kullanılan nesne tanıma çerçevesi, gerçek zamanlı çıktılar üretmektedir. Özellikle ivedi teşhis konulması hedeflenen durumlar için inşa edilen modelin web uygulama ya da mobil uygulama olarak bir ürün formatına dönüştürülmesi gelecek çalışmalar kapsamında hedeflenmektedir.

6 Conclusions

This study presents a deep learning-based approach for classifying inflammatory anomaly, vascular anomaly, polypoid anomaly and normal images in the gastrointestinal region. First, five different preprocessing techniques were used to clarify the critical points in the images of 4 different categories in the KID dataset 2 dataset. The data improved by these preprocessing techniques were classified by a pretrained region proposal-based object recognition algorithm. As a result of classification, images showing maximum performance have been increased with the image augmentation approach. Then, a balanced and sufficient dataset created using images with clarified critical points was given as input to different pre-trained object recognition algorithms based on deep learning. However, the detection success, which varies depending on the algorithms, offers different outputs between categories and samples. For this reason, the ensemble learning approach was

preferred in the next step in order to obtain stable outputs for each category and to build a balanced detection process between categories. With this hybrid structure, a balanced and stable estimation function was performed between all categories.

The object recognition framework used in this study produces real-time outputs. In future studies, it is aimed to transform the model, which was built especially for urgent diagnosis, into a product format as a web application or mobile application.

7 Yazar katkı beyanı

Gerçekleştirilen çalışmada Yazar 1, fikrin oluşması, literatür taraması, makalenin yazılması ve sonuçların irdelenmesi hususunda; Yazar 2, fikrin oluşması, literatür taraması, yazım denetimi ve içeriğin kontrol edilmesi hususunda katkıda bulunmuştur.

8 Etik kurul onayı ve çıkar çatışması beyanı

Hazırlanan makalede etik kurul izni alınmasına gerek yoktur. Hazırlanan makalede herhangi bir kişi/kurum ile çıkar çatışması bulunmamaktadır.

9 Kaynaklar

- [1] Öner RY, 'Sindirim Sistemi Rahatsızlıklarında Kullanılan Tıbbi Çay Formülleri', Yüksek Lisans Tezi, İstanbul Üniversitesi, İstanbul, Türkiye, 2019.
- [2] Sushma B, and Aparna P, 'Recent developments in wireless capsule endoscopy imaging: Compression and summarization techniques', *Computers in Biology and Medicine*, 149, 2022, doi: 10.1016/j.compbio.2022.106087.
- [3] Iakovidis DK, Georgakopoulos SV, Vasilakakis M, Koulaouzidis A, and Plagianakos VP, 'Detecting and Locating Gastrointestinal Anomalies Using Deep Learning and Iterative Cluster Unification', *IST 2016 - 2016 IEEE International Conference on Imaging Systems and Techniques*, Proceedings, 37(10), 2196–2210, 2018, doi: 10.1109/TMI.2018.2837002.
- [4] Du W et al., 'Review on the Applications of Deep Learning in the Analysis of Gastrointestinal Endoscopy Images', *IEEE Access*, 7, 142053–142069, 2019, doi:10.1109/ACCESS.2019.2944676.
- [5] Akalın F and Yumuşak N, 'İnce bağırsak görüntüleri üzerinde sezgisel algoritma teknikleri ile polip teşhisi', Yüksek Lisans Tezi, Sakarya üniversitesi, Sakarya, Türkiye, 2020.
- [6] Muhammad K, Khan S, Kumar N, Del Ser J, and Mirjalili S, 'Vision-based personalized Wireless Capsule Endoscopy for smart healthcare: Taxonomy, literature review, opportunities and challenges', *Future Generation Computer Systems*, 113, 266–280, 2020, doi: 10.1016/j.future.2020.06.048.
- [7] Jain S., et al., 'A deep CNN model for anomaly detection and localization in wireless capsule endoscopy images', *Computers in Biology and Medicine*, 137, 2021, doi: 10.1016/j.compbio.2021.104789.
- [8] Xing, X., Yuan, Y., and Meng, M. Q. H., 'Zoom in Lesions for Better Diagnosis: Attention Guided Deformation Network for WCE Image Classification', *IEEE Transactions on Medical Imaging*, 39(12), 4047–4059, 2020, doi: 10.1109/TMI.2020.3010102.
- [9] Iqbal, I., Walayat, K., Kakar, M. U., and Ma, J., 'Automated identification of human gastrointestinal tract abnormalities based on deep convolutional neural network with endoscopic images', *Intelligent Systems with Applications*, 16, 2022, doi: 10.1016/j.iswa.2022.200149.
- [10] Shin Y, Qadir HA, Aabakken L, Bergsland J, Balasingham I, 'Automatic colon polyp detection using region based deep CNN and post learning approaches', *IEEE Access*, 6, 40950–40962, 2018, doi: 10.1109/ACCESS.2018.2856402.
- [11] Byrne MF et al., 'Real-time differentiation of adenomatous and hyperplastic diminutive colorectal polyps during analysis of unaltered videos of standard colonoscopy using a deep learning model', *Gut*, vol. 68, 94–100, 2019, doi: 10.1136/gutjnl-2017-314547.
- [12] Jia X and Meng MQH, 'A deep convolutional neural network for bleeding detection in Wireless Capsule Endoscopy images', *Proceedings of the Annual International Conference of the IEEE Engineering in Medicine and Biology Society, EMBS*, 639–642, 2016, doi: 10.1109/EMBC.2016.7590783.
- [13] Liu X, Wang C, Hu Y, Zeng Z, Bai J, and Liao G, 'Transfer Learning with Convolutional Neural Network for Early Gastric Cancer Classification on Magnifying Narrow-Band Imaging Images', *Proceedings - International Conference on Image Processing ICIP*, 1388–1392, 2018, doi: 10.1109/ICIP.2018.8451067.
- [14] Yu L, Chen H, Dou Q, Qin J, and Heng PA, 'Integrating Online and Offline Three-Dimensional Deep Learning for Automated Polyp Detection in Colonoscopy Videos', *IEEE Journal of Biomedical and Health Informatics*, 21(1), 65–75, 2017, doi: 10.1109/JBHI.2016.2637004.
- [15] Ali H, Sharif M, Yasmin M, Rehmani MH, and Riaz F, 'A survey of feature extraction and fusion of deep learning for detection of abnormalities in video endoscopy of gastrointestinal-tract', *Artificial Intelligence Review*, 53(4), 2635–2707, 2020, doi: 10.1007/s10462-019-09743-2.
- [16] Xing X, Yuan Y, Jia X, and Max QHM, 'A saliency-aware hybrid dense network for bleeding detection in wireless capsule endoscopy images', *Proceedings - International Symposium on Biomedical Imaging*, 104–107, 2019, doi: 10.1109/ISBI.2019.8759401.
- [17] Muruganatham P and Balakrishnan SM, 'A survey on deep learning models for wireless capsule endoscopy image analysis', *International Journal of Cognitive Computing in Engineering*, 2, 83–92, 2021, doi: 10.1016/j.ijcce.2021.04.002.
- [18] Aliyi, S., Dese, K. and Raj, H., 'Detection of Gastrointestinal Tract Disorders Using Deep Learning Methods from Colonoscopy Images and Videos', *Scientific African*, 20, 2023, doi: 10.1016/j.sciaf.2023.e01628.

- [19] Pannala R et al., 'Artificial intelligence in gastrointestinal endoscopy', *VideoGIE*, 5(12), 598–613, 2020, doi: 10.1016/j.vgie.2020.08.013.
- [20] Koulaouzidis A. et al., 'KID Project: an internet-based digital video atlas of capsule endoscopy for research purposes', *Endoscopy International Open*, 05(06), E477–E483, 2017, doi: 10.1055/s-0043-105488.
- [21] Akalın F, and Yumuşak N, 'DNA genom dizilimi üzerinde dijital sinyal işleme teknikleri kullanılarak elde edilen ekson ve intron bölgelerinin EfficientNetB7 mimarisi ile sınıflandırılması', *Gazi Üniversitesi Mühendislik-Mimarlık Fakültesi Dergisi*, 37(3), 1355–1371, 2022, doi: 10.17341/gazimmfd.900987.
- [22] Pérez-García F, Sparks R, and Ourselin S, 'TorchIO: A Python library for efficient loading, preprocessing, augmentation and patch-based sampling of medical images in deep learning', *Computer Methods and Programs in Biomedicine*, 208, 2021, doi: 10.1016/j.cmpb.2021.106236.
- [23] Akalın F. and Yumuşak N, 'Özellik seçim algoritmaları ve derin öğrenme tabanlı mimarilerin hibrit kullanımıyla akut lösemilerin sınıflandırılması', *Pamukkale University Journal of Engineering Sciences*, doi: 10.5505/pajes.2022.62282.
- [24] Bilginer O, Tunga B, and Demirer RM, 'Classification of skin lesions using convolutional neural networks', *Pamukkale University Journal of Engineering Sciences*, 28(2), 208–214, 2022, doi: 10.5505/pajes.2021.68700.
- [25] Dheir IM, Naser SSA, 'Classification of Anomalies in Gastrointestinal Tract Using Deep Learning', *Philpapers.Org*, 6(3), 15–28, 2022, [Online]. Available: <https://philpapers.org/rec/DHECOA>.
- [26] Akalın F. and Yumuşak N., 'Detection and classification of white blood cells with an improved deep learning-based approach', *Turkish Journal of Electrical Engineering and Computer Sciences*, 30(7), 2725–2739, 2022, doi: 10.55730/1300-0632.3965.
- [27] Georgakopoulos SV, Iakovidis DK, Vasilakakis M, Plagianakos VP and Koulaouzidis A, 'Weakly-supervised Convolutional learning for detection of inflammatory gastrointestinal lesions', *IST 2016 - 2016 IEEE International Conference on Imaging Systems and Techniques, Proceedings*, 510–514, 2016, doi: 10.1109/IST.2016.7738279.
- [28] Zhao Q, Yang W and Liao Q, 'AFA-RN: An Abnormal Feature Attention Relation Network for Multi-class Disease Classification in gastrointestinal endoscopic images', *BHI 2021 - 2021 IEEE EMBS International Conference on Biomedical and Health Informatics, Proceedings*, 2021, doi: 10.1109/BHI50953.2021.9508576.
- [29] Raut V, Gunjan R, Shete VV and Eknath UD, 'Gastrointestinal tract disease segmentation and classification in wireless capsule endoscopy using intelligent deep learning model', *Computer Methods in Biomechanics and Biomedical Engineering: Imaging and Visualization*, 1–17, 2022, doi: 10.1080/21681163.2022.2099298.
- [30] Jain S, Seal A and Ojha A, 'A Hybrid Convolutional Neural Network with Meta Feature Learning for Abnormality Detection in Wireless Capsule Endoscopy Images', *SSRN Electron. J.*, no. M1, 2022, doi: 10.2139/ssrn.4253902.
- [31] Yuan Y, Li B, and Meng MQH, 'Improved Bag of Feature for Automatic Polyp Detection in Wireless Capsule Endoscopy Images', *IEEE Transactions on Automation Science and Engineering*, 13(2), 529–535, 2016, doi: 10.1109/TASE.2015.2395429.
- [32] Sasmal P, Bhuyan MK, Dutta S, and Iwahori Y, 'An unsupervised approach of colonic polyp segmentation using adaptive markov random fields', *Pattern Recognition Letters*, 154, 7–15, 2022, doi: 10.1016/j.patrec.2021.12.014.