



# Kahramanmaraş Sütçü İmam University

## Journal of Engineering Sciences



Geliş Tarihi : 19.09.2023  
Kabul Tarihi : 29.11.2023

Received Date : 19.09.2023  
Accepted Date : 29.11.2023

### ÖZNETELİK ENTEGRASYONUNA DAYALI ESA MİMARİSİ KULLANILARAK ENDOSKOPIK GÖRÜNTÜLERİN SINIFLANDIRILMASI

### CLASSIFICATION OF ENDOSCOPIC IMAGES USING CNN ARCHITECTURE BASED ON FEATURE INTEGRATION

Hüseyin ÜZEN<sup>1</sup> (ORCID: 0000-0002-0998-2130)  
Hüseyin FIRAT<sup>2\*</sup> (ORCID: 0000-0002-1257-8518)

<sup>1</sup> Bingöl Üniversitesi, Bilgisayar Mühendisliği Bölümü, Bingöl, Türkiye  
<sup>2</sup> Dicle Üniversitesi, Bilgisayar Mühendisliği Bölümü, Diyarbakır, Türkiye

\*Sorumlu Yazar / Corresponding Author: Hüseyin FIRAT, huseyin.firat@dicle.edu.tr

#### ÖZET

Derin öğrenme (DL) tekniklerindeki son gelişmeler, tıbbi görüntüler kullanılarak gastrointestinal (GI) hastalıkların sınıflandırılmasını otomatikleştirmek için umut verici bir potansiyel göstermektedir. Zamanında ve kesin teşhis, tedavi etkinliğini önemli ölçüde etkilemektedir. Bu araştırma, GI hastalıklarını tanımlamak için yeni bir DL tabanlı model tanıtmaktadır. Bu model, önceden eğitilmiş ağ mimarilerinin ara katmanlarından elde edilen öznetelikleri birleştirerek sınıflandırma işlemini gerçekleştirmektedir. Öznetelik entegrasyonuna dayalı evrimsel sinir ağı (ESA) olarak adlandırılan bu modelde, endoskopik görüntüleri sınıflandırmak için önceden eğitilmiş ağ mimarilerinin yüksek ve düşük seviyeli öznetelikleri birleştirilerek nihai öznetelik haritası elde edilmektedir. Daha sonra bu öznetelik haritası sınıflandırma için kullanılmaktadır. Kvasirv2 veri seti kullanılarak yapılan deneysel analizler sonucunda, önerilen model ile başarılı bir performans elde edilmiştir. Özellikle, DenseNet201 modelinin ara katmanlarındaki özelliklerin birleştirilmesi, sırasıyla %94.25, %94.28, %94.24 ve %94.24 doğruluk, kesinlik, duyarlılık ve F1 puanı ile sonuçlanmıştır. Diğer ESA tabanlı önceden eğitilmiş modellerle ve son çalışmalarla yapılan karşılaştırmalı analizler, önerilen modelin üstünlüğünü ortaya koymuş ve doğruluğu %94.25'e yükseltmiştir. Bu, endoskopik görüntülerden GI hastalık tespitinde gelişmiş sınıflandırma doğruluğu için DenseNet201'in ara katmanlarındaki özelliklerden yararlanma potansiyelinin altını çizmektedir.

**Anahtar Kelimeler:** DenseNet201, endoskopik görüntü sınıflandırma, evrimsel sinir ağı, kvasirv2 veri seti

#### ABSTRACT

Recent developments in deep learning (DL) techniques show promising potential for automating the classification of gastrointestinal (GI) diseases using medical images. Timely and accurate diagnosis significantly impacts treatment effectiveness. This research introduces a new DL-based model for identifying GI diseases. This model performs classification by combining features extracted from intermediate layers of pretrained network architectures. In this model, named CNN based on feature integration, high and low-level features from pretrained network architectures are combined to obtain a final feature map for classifying endoscopic images. This feature map is then utilized for classification. Experimental analyses conducted using the Kvasirv2 dataset resulted in successful performance with the proposed model. Specifically, combining features from the intermediate layers of the DenseNet201 model resulted in accuracies, precision, recall, and F1 scores of 94.25%, 94.28%, 94.24%, and 94.24%, respectively. Comparative analyses against other CNN-based pretrained models and recent studies highlighted the superiority of the proposed model, elevating the accuracy to 94.25%. This underscores the potential of leveraging features from the intermediate layers of DenseNet201 for enhanced classification accuracy in detecting GI diseases from endoscopic images.

**Keywords:** DenseNet201, endoscopic image classification, convolutional neural network, kvasirv2 dataset

ToCite: ÜZEN, H., & FIRAT, H., (2024). ÖZNETELİK ENTEGRASYONUNA DAYALI ESA MİMARİSİ KULLANILARAK ENDOSKOPIK GÖRÜNTÜLERİN SINIFLANDIRILMASI. *Kahramanmaraş Sütçü İmam Üniversitesi Mühendislik Bilimleri Dergisi*, 27(1), 121-132.

## GİRİŞ

İnsan gastrointestinal (GI) sistemi, vücudun sindirim işlevini yerine getiren karmaşık bir sistemdir. Bu sistem, besinlerin ağızdan başlayarak mide, ince bağırsak ve kalın bağırsak boyunca işlenmesini ve besin maddelerinin emilmesini sağlamaktadır. GI hastalıklar söz konusu olduğunda, GI sistemi bu işlevleri başarılı bir şekilde yerine getirememektedir. GI hastalıklar arasında kabızlık, iritabl bağırsak sendromu, hemoroid, anal fissür, anorektal apseler, anal fistüller, perianal enfeksiyonlar, divertiküler hastalıklar, kolit, kolon polipleri ve kanser vb. gibi hastalıklar yer almaktadır (Iqbal vd., 2022). Bu hastalıkların birçoğu, insan yaşam kalitesini düşüren ve hayatı tehdit eden hastalıklara kadar çeşitli anormal sonuçlar doğurabilmektedir. Bundan dolayı, GI hastalıklar ve kanser günümüz dünyasında ciddi bir endişe kaynağıdır. GI hastalıklar insan sindirim sisteminde yaygındır. İnsanlarda yüksek ölüm oranlarının önemli bir nedeni, sindirim sistemi ile ilgili çeşitli bulaşıcı hastalıklardan kaynaklanmaktadır. Ülser, mide kanaması, polipler, Crohn hastalığı, kolorektal kanser, tümör ve diğer ilgili hastalıklar gibi GI sistem hastalıkları bugün dünya çapında iyi bilinmektedir (Mohapatra vd., 2023; Haile vd., 2022). Uluslararası Kanser Araştırmaları Ajansı, 2018 yılında dünya genelinde GI kanser oranının 4,8 milyon yeni vaka olarak tahmin edildiğini, bunun dünya genelindeki tüm kanser vakalarının %26' sını oluşturduğunu ve GI kanserle ilişkili ölümlerin sayısının dünya genelinde kansere bağlı tüm ölümlerin %35' i olarak tahmin edildiğini bildirmiştir (Naz vd., 2021).

Çeşitli GI hastalıkların erken teşhisi etkili tedaviye neden olabilmekte ve ölüm riskini azaltabilmektedir. Ancak mide-bağırsak gibi bazı hastalıkların saptanmasında zorluklar oluşturması veya önemli ayrıntıları gizleyen görüntü parazitlerinin varlığı nedeniyle tıbbi tarama sırasında belirsizlik oluşturması hastalığın tespit edilememesine veya karışıklık oluşturmaya neden olabilmektedir (Borgli vd., 2020). Endoskopi ve kolonoskopi şu anda GI hastalıklarının araştırılması için uygulanan standart prosedürlerdir. Endoskopi ve kolonoskopi, GI kanal organlarının içini incelemek ve polipler, ülserler veya kanser gibi herhangi bir anomaliyi araştırmak için bir doktor tarafından kapsamlı bir inceleme gerektiren, ağızdan veya rektal olarak küçük bir kamera takılı bir tüpün yerleştirilmesini içeren müdahaleci prosedürlerdir. Polipleri belirleme yeteneği, kanserin gelişme olasılığını etkilemektedir. Poliplerin %20 kadarı muayene sırasında tespit edilememektedir (Kaminski vd., 2010). Ayrıca, endoskopi görüntülerinin subjektif olarak yorumlanması zaman alıcı ve minimal düzeyde tekrarlayıcı olabilmekte ve potansiyel olarak yanlış tanıya yol açabilmektedir. İnsan hatası ve diğer sınırlamaların bir sonucu olarak doktorlar tarafından tanıda yanlışlık potansiyeli göz önüne alındığında, bilgisayar destekli otomatik bir sistemin kullanılması, GI poliplerin ve kanserlerin erken evrelerinde tespit edilmesinde avantajlı olabilmektedir. Bu doğrultuda, yapay zekanın çeşitli GI endoskopik uygulamalarda kullanılması, klinik uygulamayı iyileştirme ve mevcut tanı yöntemlerinin verimliliğini ve hassasiyetini iyileştirme potansiyeline sahiptir. Son yıllarda, yapay zekanın bir alt dalı olan ve makine öğrenme yöntemlerinin alternatif bir formunu temsil eden derin öğrenme yöntemleri, kolorektal polip tespiti ve sınıflandırması, helicobacter pylori enfeksiyonunun teşhisi için endoskopik görüntülerin analizi ve erken mide kanserinin derinlik değerlendirmesi ve kablosuz kapsül endoskopi görüntülerinde çeşitli anormalliklerin tespiti gibi GI endoskopinin birçok alanında başarılı bir şekilde uygulanmıştır (Su vd., 2022; Majid vd., 2020; Khan vd., 2020). Derin öğrenmenin avantajlarını göz önünde bulunduran araştırmacılar, kablosuz kapsül endoskopi tarafından üretilen verilerin özellik çıkarımı ve sınıflandırılması için evrişimli sinir ağı (ESA) tabanlı yöntemleri kullandılar. Yapılan deneysel çalışmaların sonuçları, diğer görüntü tanıma teknikleri ve tıp uzmanları tarafından yapılan tanıma teknikleri ile karşılaştırıldığında, ESA tabanlı yöntemlerin daha iyi performans elde ettiğini göstermektedir (Su vd., 2022; Soffer vd., 2020).

Gunasekaran vd. (2023) GI sistem hastalıklarını sınıflandırmak için GIT-NET adı verilen bir topluluk modeli önerdiler. Topluluk modeli DenseNet201, InceptionV3 ve ResNet50 olmak üzere üç temel modelden oluşmaktadır. Öncelikle, sınıflandırma için bireysel modeller kullanıldığında, tüm sınıfların özelliklerini yeterince öğrenemeyebilecekleri için genellikle yanlış sınıflandırmaya eğilimli olduğunu gördüler. Bunun nedeni, her modelin belirli sınıfların özelliklerini diğer sınıflardan daha verimli bir şekilde öğrenebilmesidir. Daha sonra bu üç modelden oluşan topluluk öğrenimini kullanarak deneysel çalışmalarını gerçekleştirdiler. Modeli sekiz sınıflı bir Kvasirv2 veri seti üzerinde değerlendirdiler. Önerilen bu topluluk modeli %92.96 sınıflandırma doğruluğu ile sonuçlanmıştır. Lonseko vd. (2021) sınıflandırma performansını iyileştirmek için uzamsal faktörlerin uygulanmasını önermektedir. Spesifik olarak, GI hastalıklarının sınıflandırılması için kodlayıcı-kod çözücü katmanlarla uygulanan derin ESA tabanlı bir uzamsal dikkat mekanizması önerdiler. Veri dengesizliği sorununun üstesinden gelmek için veri büyütme tekniklerini uyarladılar. Kvasirv2 veri seti üzerinde gerçekleştirilen deneysel çalışmalar sonucunda %93.19 sınıflandırma doğruluk sonucu bulunmuştur. Xing vd. (2020) kablosuz kapsül endoskopi görüntü sınıflandırması için iki dallı bir dikkat kılavuzlu deformasyon ağı önerdiler. Özellikle, birinci dalın dikkat haritaları, ikinci dalın giriş görüntülerindeki lezyon bölgelerinin büyütülmesine rehberlik etmek için kullanıldı, böylece küçük lezyonların daha

iyi temsil edilmesine ve incelenmesine yol açtı. Ayrıca, ağa üçüncü dereceden uzun menzilli özellik toplama modülleri eklendi. Bu modüller, uzun menzilli bağımlılıkları yakalayarak ve bağlamsal özellikleri bir araya getirerek ağa küresel bir bağlamsal görünüm ve daha güçlü özellik temsili ve ayırt etme kabiliyeti kazandırdı. Dahası, dikkat haritalarını rafine etmek ve iki dalın karşılıklı terfisini sağlamak için yeni bir deformasyona dayalı dikkat tutarlılığı kaybı önerildi. Son olarak, iki daldan gelen global özellik yerleştirmeleri, görüntü etiketi tahminleri yapmak için birleştirildi. Kvasirv2 veri seti üzerinde gerçekleştirilen deneysel çalışmalar sonucunda %91.33 doğruluk sonucu elde ettiler. Pozdeev vd. (2019) otomatik iki aşamalı sınıflandırma kullanarak polip segmentasyon görevini ve çözümünü tartışmaktadır. İlk aşama, ilk endoskopik görüntülerden alınan genel özelliklere dayalı ikili sınıflandırmadır. İkinci aşama, segmentasyon için evrişimli sinir ağlarının kullanımını içermektedir. Yöntemin başarısını test etmek için Kvasirv2 veri seti ile gerçekleştirilen deneysel çalışmalar sonucunda %88 doğruluk sonucu elde edilmiştir. Agrawa vd. (2017) endoskopik görüntülerle GI sistem anormalliklerinin sınıflandırılması için VGG ve InceptionV3 mimarilerinden oluşan bir yöntem geliştirmiştir. Geliştirilen yöntemi test etmek için Kvasirv2 üzerinde yapılan deneysel çalışmalar sonucunda %83.8 sınıflandırma doğruluğu ve %84.7 F1 skor değeri elde ettiler. Pogorelov vd. (2017) altı katmandan oluşan bir ESA modeli kullanarak endoskopik görüntü sınıflandırmasını gerçekleştirdiler. Kvasirv2 veri seti kullanılarak gerçekleştirilen deneysel çalışmalar sonucunda %91.4 sınıflandırma doğruluğu elde ettiler. Ucan vd. (2022) endoskopik görüntülerin sınıflandırılması için EfficientNetB0 modelini kullandılar. Kvasirv2 veri seti kullanılarak gerçekleştirilen deneysel çalışmalar sonucunda %93.5 doğruluk değeri elde ettiler. Kahsaygebressie vd. (2019) endoskopik görüntülerde farklı GI sistem hastalıklarını tanımlamak ve sınıflandırmak için DenseNet121 ve ResNet50 yaklaşımlarını kullandı. Sekiz farklı sınıfa ait GI endoskopik görüntüleri içeren halka açık Kvasirv2 veri seti kullanılarak gerçekleştirilen deneysel çalışmalar sonucunda sırasıyla %86.9 ve %87.8 sınıflandırma doğruluk sonucu elde ettiler. Du vd. (2020) GI görüntülerden oluşan veri seti üzerinde transfer öğrenme yöntemlerinden ince ayarlı ResNet152, EfficientNetB7 ve DenseNet161 yöntemlerini uyguladılar. Kvasirv2 veri setinden üç sınıftan oluşan GI görüntüleri üzerinde gerçekleştirilen deneysel çalışmalar sonucunda, sırasıyla %90.17, %89.17 ve %89.50 doğruluk değeri elde ettiler. Du vd. (2022) küçük etiketli GI görüntü veri setlerinde sınıflandırma yeteneğini geliştirmek için özofagus hastalığı için yeni bir yarı denetimli bilimsel kontrast öğrenme sınıflandırma yöntemi önerdiler. Önerdikleri yöntemde, ilk olarak, aynı lezyondan alınan görüntülerin yüksek benzerlik özelliklerinden yararlanılan verimli kontrast çiftleri oluşturmak için verimli bir kontrast çifti oluşturma modülü geliştirdiler. Ardından, özofagus GI görüntülerinin genel özelliklerini içeren denetimsiz bir görsel özellik temsili, denetimsiz bilimsel kontrast öğrenme ile öğrenilmiştir. Son olarak, özellik temsili alt akış özofagus hastalığı sınıflandırma görevine aktarılmıştır. Önerdikleri yöntem ile gerçekleştirilen deneysel çalışmalar sonucunda sınıflandırma performansını %92.57 olarak buldular. Owais vd. (2019) endoskopik videolar kullanılarak çoklu GI hastalıklarının sınıflandırılması için uzamsal-zamansal özelliklere dayalı yeni bir ESA ve LSTM tabanlı sınıflandırma çerçevesi önerdiler. Önerilen yöntem, yalnızca uzamsal bilgilerden öğrenilen özelliklere kıyasla çoklu endoskopi taramalarının daha ayırt edici temsillerini kodlayabilmektedir. Bu nedenle, hem uzamsal hem de zamansal bilgi daha iyi sınıflandırma ve geri getirme performansı ile sonuçlanmaktadır. Önerilen yöntemin performansı, GastroLab ve kvasir veritabanından kamuya açık bir veri seti kullanılarak kapsamlı bir şekilde değerlendirilmiştir. Değerlendirmeler sonucunda ortalama %92.57 doğruluk değeri elde ettiler. Poudel vd. (2020) endoskopik görüntü sınıflandırması için etkili bir derin öğrenme yaklaşımı geliştirmiştir. Önerdikleri yaklaşım, uzamsal ayrıntıları korumak için ESA'larda dilatasyon kullanarak benzer görünümlü görüntülerin ve poliplerin yanlış sınıflandırılmasını önlemektedir. Ayrıca, aşırı öğrenme ve gürültüyle mücadele etmek için DropBlock düzenlemesi getirmişlerdir. Önerdikleri yaklaşımları ile gerçekleştirilen deneysel çalışmalarda Kvasir veri seti için %88 ve Kolorektal veri seti için %93 F1 puanı elde ettiler.

Derin öğrenme, özellikle ESA tabanlı yöntemler kullanılarak endoskopi görüntülerinden GI hastalıklarının otomatik sınıflandırılması, literatürde yapılan çalışmalarda başarılı bir şekilde gerçekleştirilebileceğini göstermektedir. Ancak, incelenen çalışmalarda, Kvasirv2 veri seti üzerinde gerçekleştirilen deneysel çalışmalar sonucunda sınıflandırma doğruluk sonuçlarının düşük olduğu tespit edilmiştir. Bu nedenle, sınıflandırma doğruluğunu arttırmak için yeni ESA tabanlı yöntemlerin geliştirilmesi gerekmektedir.

Literatürde var olan birçok çalışmada VGG16, ResNet, DenseNet gibi ağ mimarilerine transfer öğrenme uygulanarak sınıflandırma çalışmaları yapılmıştır. Ayrıca bazı çalışmalarda bu mimarilerin son katmanlarında destek vektör makineleri gibi geleneksel yöntemler uygulanmıştır. Bu uygulamaların temel amacı, önceden eğitilmiş ağ mimarilerinden elde edilen güçlü öznitelikleri kullanmaktır. Fakat etkili bir ESA mimarisinin ara katmanlarında da önemli detayları içeren öznitelikler mevcuttur. Bu bakış açısıyla geliştirilen UNet ve özellik piramid ağı (feature pyramid network-FPN) modelleri etkili sonuçlar vermiştir. Buradan yola çıkarak, bu çalışmada önceden eğitilmiş mimarilerin ara katmanlarından elde edilen öznitelikleri birleştirerek sınıflandırma için yeni bir model önerilmiştir.

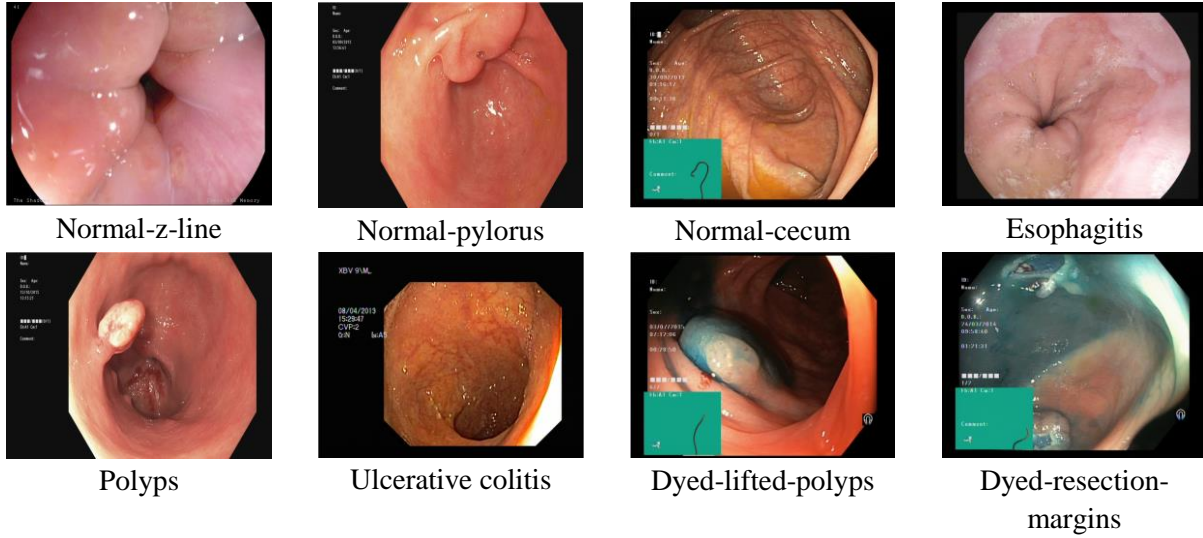
Öznitelik Entegrasyonuna dayalı Evrişimsel Sinir Ağ (ÖE-ESA) olarak adlandırılan bu mimaride, endoskopik görüntüleri sınıflandırmak için önceden eğitilmiş ağ mimarilerinin yüksek ve düşük seviyeli öznitelikleri birleştirilerek nihai öznitelik haritası elde edilmektedir. Daha sonra bu öznitelik haritası sınıflandırma için kullanılmaktadır. Kvasirv2 veri seti için ESA mimarisi kullanılarak kapsamlı deneysel çalışmalar yapılmıştır. Yapılan deneysel çalışmalarda, önceden eğitilmiş VGG, ResNet, DenseNet ve InceptionV3 modelleri uygulanmıştır. Deneysel çalışmaların sonucunda DenseNet201 modeli kullanılarak %94.25 doğruluk değeri elde edilmiştir. Son teknoloji modellerle karşılaştırıldığında, DenseNet201 modeliyle daha başarılı sınıflandırma sonuçların sağlandığı görülmüştür.

Bu çalışmanın geri kalanı şu şekilde düzenlenmiştir. Veri seti, önerilen yöntem ve önerilen yöntemin arka planında kullanılan yöntemler materyal ve metot bölümü olan Bölüm 2’de yer almaktadır. Kvasirv2 veri seti kullanılarak yapılan deneysel çalışmalar ve bu çalışmaların sonuçları Bölüm 3’te tartışılmıştır. Son olarak sonuç bölümü olan Bölüm 4’te çalışmanın genel bir özetine yer verilmiştir.

## MATERYAL VE METOT

### Veri Seti

Önerilen yöntem Kvasirv2 veri seti üzerinde değerlendirilmiştir (Pogorelov vd., 2017). Kvasirv2 veri setindeki görüntüler, çözünürlükleri 720x576 ile 1920x1072 piksel arasında değişen endoskopik görüntülerden oluşmaktadır. Veri setindeki her görüntü, endoskopik hastalıkların bilgisayar destekli tespit yöntemlerini değerlendirmek, yani endoskopik hastalık içeren kareleri normal olanlardan ayırt etmek için deneyimli endoskopistler tarafından görüntü düzeyinde açıklanmıştır. Kvasirv2, üç önemli anatomik işaret, üç tür sindirim sistemi hastalığı ve endoskopik polipektomi ile ilgili iki görüntü sınıfı dahil olmak üzere sekiz görüntü sınıfı içermektedir. Üç tip anatomik işaret Normal-z-çizgisi (Normal-z-line), Normal-pilor (Normal-pylorus), Normal-çekum (Normal-cecum)’ dur. Üç hastalık sınıfı Özofajit (Esophagitis), Ülseratif kolit (Ulcerative colitis) ve Polipleri (Polyps) içermektedir. Son sınıflar ise, Boyalı-rezeksiyon-kenarları (Dyed-resection-margins) ve Boyalı-kaldırılmış-polipler (Dyed-lifted-polyps)’ dir. Bu veri setinde her sınıftan 1000 adet görüntü olmak üzere toplam 8000 görüntü bulunmaktadır. Şekil 1, deneylerimizde kullanılan sekiz endoskopik görüntü sınıfının örnek görüntülerini göstermektedir.




Şekil 1. Kvasirv2 Veri Setindeki Örnek Görüntüler

### Önerilen Yöntem

Bu çalışmada endoskopik görüntülerin sınıflandırılması için Öznitelik Entegrasyonuna Dayalı Evrişimsel Sinir Ağı (ÖE-ESA) modeli önerilmiştir. Önerilen modelin temel amacı VGG16, InceptionV3, ResNet101, DenseNet121, DenseNet169 ve DenseNet201 gibi önceden eğitilmiş ağ mimarilerinden olabildiğince fazla özniteliklerin çıkarılmasıdır. Bu sayede geleneksel ESA mimarilerinden farklı olarak nihai öznitelik haritası için daha kapsamlı bir öznitelik haritası elde edilmiştir. Bu öznitelik haritası ile önceden eğitilmiş ağ mimarilerinden düşük ve yüksek seviyeli öznitelikleri bir araya getirerek nihai öznitelik haritası elde edilmiştir. UNet (Ronneberger vd., 2015) ve FPNet (Lin vd., 2017) modellerinde ele alındığı gibi bu öznitelik haritaları hem mekânsal hem de anlamsal detaylar içermektedir. Önerilen model Şekil 2’ de verilmiştir.





Şekil 2. Önerilen Öznitelik Entegrasyonuna Dayalı ESA Mimarisi

Şekil 2' de görüleceği üzere  $224 \times 224 \times 3$  boyutunda girdi görüntüsü önceden eğitilmiş ağ mimarilerinin girişine verilmiştir. Önceden eğitilmiş ağ mimarisi seçimi için deneysel çalışmalarda VGG16, InceptionV3, ResNet101, DenseNet121, DenseNet169 ve DenseNet201 gibi ağ mimarileri kullanılmıştır. Kullanılan herhangi bir önceden eğitilmiş ağ mimarisinden 5 farklı öznitelik haritası alınmıştır. Bu öznitelik haritaları önceden eğitilmiş ağ mimarilerinin ara katmanlarından elde edilmiştir. Bu öznitelik haritalarının yüksekliği ve genişliği  $224 \times 224$  boyutlu boyutlu bir girdi için sırası ile  $112 \times 112$ ,  $56 \times 56$ ,  $28 \times 28$ ,  $14 \times 14$  ve  $7 \times 7$ ' dir. Diğer bir ifadeyle, girdi görüntüsünün spektral boyutlarının yarıya düştüğü bölgelerden bir öznitelik haritası alınmıştır. Sonuç olarak nihai öznitelik haritası için 5 farklı boyutta mekânsal ve anlamsal detaylar içeren öznitelikler alınmıştır. Öznitelik haritasının elde edilme işlemi Algoritma 1' de verilmiştir.


#### Algoritma 1. Öznitelik Haritası Seçim Algoritması

Giriş: Önceden eğitilmiş ağ mimarilerin katmanlarının çıktı dizisi (L)

Çıkış: Seçilmiş Katman Çıktı Dizisi ( $SK = [A_1, A_2, A_3, A_4, A_5]$ )

1.  $IB = [112, 56, 28, 14, 7]$ ,  $IB$ : İstenilen Boyut
2. Katman çıktıları  $IB$  boyut dizisine göre Gruplandırılmış Katmanlar (GK) dizisine ata.  
 $GK(IB_i) = L[\text{size}(L) == IB_i]$ ,  $GK(.)$ :
3. Seçilen Katmanlar (SK) dizisi için  $IB$  dizindeki elemanlara göre  $GK(.)$  dizisinin son elemanını seç.  
 $SK(i) = GK(IB_i)[-1]$

Algoritma 1' deki birinci adımda istenilen boyut ( $IB$ ) vektörü ile tanımlanmıştır. Adım 2' de önceden eğitilmiş mimarinin tüm katman çıktıları  $L$  dizisinde toplanmıştır. Bu  $L$  dizisini gruplandırma için  $IB$  vektörü temel alınmıştır. Bu sayede  $L$  dizisi boyutlarına göre 5 gruba  $GK(i)$  ayrılmıştır. Adım 3' te elde edilen 5 grubun en etkili özniteliğini seçmek için  $GK(i)$  grupları arasındaki en yüksek dereceli (en yüksek indeksli) eleman alınmıştır. Bu sayede  $SK$  matrisinde  $[A_1, A_2, A_3, A_4, A_5]$  katman çıktısı elde edilmiştir. Örnek olarak, ResNet101 ve DenseNet201 mimarilerine Algoritma 1 uygulanarak elde edilen  $[A_1, A_2, A_3, A_4, A_5]$  katman çıktıları Şekil 3' te verilmiştir.



Şekil 3. (a) Resnet101 ve (b) Densenet201 Tabanlı Öznitelik Entegrasyonuna Dayalı ESA Mimarisinin Gösterimi

Şekil 2 ve Şekil 3' te önerilen modelin ikinci bölümde önceden eğitilmiş mimariden 5 farklı  $[A_1, A_2, A_3, A_4, A_5]$  seviyeden öznitelikler çıkartılmıştır. Geleneksel bir ESA mimarisinde düşük seviyeli öznitelik haritaları renk, şekil ve doku gibi mekânsal detaylar içerirken yüksek seviyeli öznitelik haritalarında anlamsal detaylar içermektedir. Önerilen ÖE-ESA mimarisinde farklı seviyedeki öznitelikleri bir araya getirerek zengin bir öznitelik haritası elde edilmiştir. Öznitelikleri birleştirmek için öncelikle Ortalama Havuzlama Katmanı (OHK) uygulanarak öznitelik haritaları vektörlere dönüştürülmüştür. Daha sonra bu öznitelik vektörleri birleştirilerek sınıflandırma için kullanılan nihai öznitelik vektörü elde edilmiştir. Önerilen modelin son katmanında elde edilen nihai öznitelik vektörüne ( $F$ ) Softmax sınıflandırıcısı uygulanarak sınıflandırma çıktısı elde edilmiştir. Bu işlem Denklem (1)' de gösterilmiştir.

$$P = softmax(PB^n(F))$$

$$softmax(x_i) = \frac{e^{x_i}}{\sum_{j=1}^n e^{x_j}} \quad (1)$$

Denklem (1)' de gösterilen  $P$  tahmin vektörünü ifade etmektedir.  $P$  tahmin vektörünü elde etmek için öncelikle nihai öznitelik haritasına 8 nöronlu bir Tam Bağlı ( $TB$ ) katman uygulanmıştır. Burada verilen  $n$  değeri sınıf sayısıdır.  $TB$  katmanının çıktısında 8 boyutlu bir vektör elde edilmiştir. Bu vektörden olasılıksal tahmin dağılımını ( $P$ ) elde etmek için softmax katmanı uygulanmıştır. Denklem (1)' in çıktısında elde edilen tahmin vektörünün en yüksek olasılık değerini temsil eden indeks sınıflandırma çıktısı olarak kabul edilmiştir. Önerilen ağ modelinin eğitiminde Kategorik Çapraz Entropi (Categorical Cross Entropy) kayıp fonksiyonu kullanılmıştır. Kategorik Çapraz Entropi kayıp fonksiyonu, sınıflandırma modellerinin eğitiminde ve değerlendirilmesinde kullanılan temel bir araçtır. Bu kayıp fonksiyonunun kullanım amacı, çok sınıflı bir sınıflandırma probleminde tahmin edilen sınıf olasılıkları ile gerçek sınıf etiketleri arasındaki farklılığı ölçmektir. Bu sayede modelin öğrenme sürecine rehberlik etmekte ve modelin daha iyi ve daha doğru tahminler yapmasına yardımcı olmaktadır. Bu kayıp fonksiyonu Denklem (2)' deki gibi tanımlanmaktadır.

$$L = -\frac{1}{n} \sum_i y_i \log(P_i) \quad (2)$$

Denklem (2)' de,  $y$  ve  $P$  değeri sırası ile beklenen çıktı ve tahmin çıktısı vektörlerini temsil etmektedir.  $i$  ise  $n$  (sınıf sayısı) boyutlu çıktı vektörlerin indeksidir.  $L$  değeri ise sınıflandırma çıktısının ortalama hata değerini göstermektedir.

## DENEYSEL ÇALIŞMALAR VE SONUÇLARI

Önerdiğimiz yöntemin sınıflandırma doğruluğunu detaylı olarak incelemek için birçok deneysel çalışma yapılmıştır. Bu bölümde, öncelikle parametre ayarları hakkında bilgi verilecektir. Daha sonra deneysel çalışmalarda kullanılan değerlendirme ölçütleri açıklanacaktır. Son olarak Kvasırv2 veri seti kullanılarak elde edilen sınıflandırma doğruluk sonuçları ve literatürden aynı veri setini kullanan son yıllarda yapılmış çalışmalar ile karşılaştırma sonuçları yer alacaktır.

### Parametre Ayarları ve Değerlendirme Ölçütleri

Deneysel çalışmalar intel i9 işlemci, 64GB ram RTX 3080 ti ekran kartına sahip bir bilgisayarda gerçekleştirilmiştir. Derin öğrenme modelinin tasarımında Python programlama dili ve keras-tensorflow kütüphanesi kullanılmıştır. Kullanılan hiperparametreler arasında batch size, görüntü boyutu, eğitim-test-doğrulama ayrımı, epoch sayısı yer almaktadır. Önerilen yöntemi eğitmek için batch size değeri olarak 16, 224x224x3' lük bir görüntü boyutu ve %80-%10-%10' luk bir eğitim-test-doğrulama ayrımı kullanılmıştır. 8000 görüntüden 6400 görüntü eğitim, 800 görüntü doğrulama ve 800 görüntü test için kullanılmıştır. Ek olarak, model 100 epoch için eğitilmiştir. Kayıp fonksiyonunu en aza indirmek ve modeli optimize etmek için Adam optimizier kullanılmıştır.

Önerilen yöntemin verimliliği, kesinlik (precision), F1-puanı (F1-score), duyarlılık (recall) ve sınıflandırma doğruluğu (accuracy) gibi değerlendirme ölçütleri kullanılarak belirlenmektedir. Değerlendirme ölçütleri, bir modelin tahminlerinin etkinliğinin niceliksel ve nesnel bir ölçüsünü sağlamaktadır. Ayrıca sınıflandırma performansını değerlendirmek için gereklidir. Bu ölçütler, her birinin kendine özgü güçlü yanları ve sınırlamaları olan, modelin performansı hakkında farklı bakış açıları sağlamaktadır. Bu ölçütlerin detaylı açıklaması şu şekildedir. Temel bir performans değerlendirme ölçütü olan doğruluk, yöntem tarafından üretilen doğru tahminlerin yüzdesini ölçer. Bu ölçüt, doğru tahmin sayısının yapılan toplam tahmin sayısına bölünmesiyle hesaplanmaktadır. Doğruluk değerinin hesaplanması Denklem (3)' teki gibidir. Önerilen yöntemle yapılan tüm pozitif tahminlerdeki gerçek pozitiflerin oranını ölçen bir ölçüm olan kesinlik, gerçek pozitif sayısının, gerçek pozitif ve yanlış pozitiflerin toplamına bölünmesiyle hesaplanmaktadır. Kesinlik değerinin hesaplanması Denklem (4)' teki gibidir. Veri setindeki tüm gerçek pozitif örnekler arasında gerçek pozitif oranını ölçen bir metrik olan duyarlılık, gerçek pozitif sayısının gerçek pozitif ve yanlış negatiflerin toplamına bölünmesiyle hesaplanmaktadır. Duyarlılık değeri Denklem (5)' teki gibi formülize edilmektedir. Duyarlılık ve kesinliğin harmonik ortalaması olan F1 puanı, özellikle sınıfların dengesiz olduğu durumlarda kesinlik ve duyarlılığı dengelemek için vazgeçilmez bir ölçüttür. Hem kesinliği hem de duyarlılığı yakalayan tek bir puan sağlayarak, onu genel model performans değerlendirmesi için güçlü bir ölçü haline getirir (Ha vd., 2022; Naseri vd., 2021; Shahin vd., 2019). F1 puanı Denklem (6)' daki gibi hesaplanmaktadır.

$$\text{Doğruluk} = \frac{TP + TN}{TP + FP + TN + FN} \quad (3)$$

$$\text{Kesinlik} = \frac{TP}{TP + FP} \quad (4)$$

$$\text{Duyarlılık} = \frac{TP}{TP + FN} \quad (5)$$

$$\text{F1 - puanı} = 2 * \frac{\text{Kesinlik} \times \text{Duyarlılık}}{\text{Kesinlik} + \text{Duyarlılık}} \quad (6)$$

Denklem (3), (4), (5) ve (6)' daki gerçek negatifler (TN), yanlış negatifler (FN), yanlış pozitifler (FP) ve gerçek pozitifler (TP) değerleri karışıklık matrisinden elde edilmektedir. Bu değerler şu şekildedir: TP, her sınıf için doğru sınıflandırılmış girdi görüntülerinin sayısını tanımlar. FP, sınıftaki yanlış sınıflandırılmış görüntülerin sayısını gösterir. TN, sınıfa ait olmadığı için doğru sınıflandırılan görüntülerin sayısını temsil eden gerçek negatiftir. FN yanlış negatiftir ve sınıftan yanlış sınıflandırılan görüntüleri temsil etmektedir.

### Sınıflandırma Performans Sonuçları

Deneysel çalışmalarda endoskopik görüntülerden GI hastalıklarının tespiti için Kvasirv2 veri seti kullanılmıştır. Çalışmalarda önceden eğitilmiş altı farklı mimari kullanılmıştır. Bu mimariler, VGG16, InceptionV3, ResNet101, DenseNet121, DenseNet169 ve DenseNet201' dir. Standart önceden eğitilmiş bu altı mimari ile önerilen ÖE-ESA mimarilerinin sınıflandırma sonuçları Tablo 1' de verilmiştir. Tablo 1 incelendiğinde, standart önceden eğitilmiş mimariler ile elde edilen sınıflandırma sonuçları şu şekildedir: VGG16 ile %86.68 doğruluk, %86.93 F1 skor, %88.18 kesinlik, %86.68 duyarlılık, InceptionV3 ile %92.68 doğruluk, %92.66 F1 skor, %92.78 kesinlik, %92.68 duyarlılık, ResNet101 ile %91.93 doğruluk, %91.90 F1 skor, %91.95 kesinlik, %91.93 duyarlılık, DenseNet121 ile %92 doğruluk, %91.95 F1 skor, %92.21 kesinlik, %92 duyarlılık, DenseNet169 ile %92.37 doğruluk, %92.35 F1 skor, %92.42 kesinlik, %92.37 duyarlılık, DenseNet201 ile %92.31 doğruluk, %92.30 F1 skor, %92.43 kesinlik ve %92.31 duyarlılık. Standart önceden eğitilmiş bu altı mimari karşılaştırıldığında en başarılı sonuçların InceptionV3 mimarisi ile elde edildiği görülmektedir. Önceden eğitilmiş bu altı mimariye dayalı önerilen ÖE ESA modeli kullanıldığında elde edilen sınıflandırma sonuçları şu şekildedir: VGG16 - ÖE ESA modeli ile %90.75 doğruluk, %90.68 F1 skor, %90.89 kesinlik, %90.75 duyarlılık, InceptionV3 - ÖE ESA modeli ile %92.37 doğruluk, %92.37 F1 skor, %92.50 kesinlik, %92.37 duyarlılık, ResNet101 - ÖE ESA modeli ile %93.12 doğruluk, %93.10 F1 skor, %93.18 kesinlik, %93.12 duyarlılık, DenseNet121 - ÖE ESA modeli ile %93.87 doğruluk, %93.86 F1 skor, %94.01 kesinlik, %93.87 duyarlılık, DenseNet169 - ÖE ESA modeli ile %93.62 doğruluk, %93.60 F1 skor, %93.75 kesinlik, %93.62 duyarlılık ve son olarak DenseNet201 mimarisine dayalı ÖE ESA modeli ile %94.25 doğruluk, %94.24 F1-skor, %94.28 kesinlik ve %94.24 duyarlılık değerlerinin elde edildiği görülmüştür. Tüm sonuçlar dikkate alındığında, standart önceden eğitilmiş ağ modellerinin bireysel kullanımları yerine bu modellere ÖE ESA' nın eklenmesi ile sınıflandırma doğruluk sonuçlarının arttığı gözlemlenmiştir. Özellikle ÖE ESA ile DenseNet modellerinin kullanımının daha başarılı sonuçlar elde ettiği görülmektedir. En başarılı sınıflandırma sonuçlarının ise DenseNet201 – ÖE ESA modeli ile elde edildiği açıkça görülmektedir. DenseNet201 – ÖE ESA modeli kendisine en yakın doğruluk sonucunu elde eden DenseNet121 – ÖE ESA modelinden %0.38, benzer şekilde DenseNet169-ÖE ESA modelinden %0.63 daha başarılı sonuçlar elde etmiştir. Hem bireysel model kullanımında hem de ÖE ESA ile birlikte kullanımda en düşük doğruluk sonuçları VGG16 modeli ile elde edilmiştir. Bunun yanı sıra DenseNet201-ÖE ESA modeli, ResNet101-ÖE ESA modelinden %1.13 ve InceptionV3 – ÖE ESA modelinden %1.88 daha başarılı doğruluk değeri elde etmiştir. Tüm sonuçlardan önerilen DenseNet201-ÖE ESA modelinin GI hastalık sınıflandırması için başarılı olduğu açıkça görülmektedir. Ayrıca, standart önceden eğitilmiş ESA modelleri ile ÖE ESA tabanlı modellerden bazılarının karışıklık matrisleri Şekil 4' te verilmiştir. Şekil 4 incelendiğinde önerilen ÖE ESA' nın kullanımının başarıyı arttırdığı görülmektedir. Önerilen DenseNet201-ÖE ESA modeli 2, 5 ve 6 nolu sınıflar haricinde diğer beş sınıfta en iyi doğruluk değerlerini elde etmiştir. 2,5 ve 6 nolu sınıflarda ise en iyi doğruluk değerleri DenseNet121-ÖE ESA modeli ile bulunmuştur.


**Tablo 1.** Önerilen Öznitelik Entegrasyonuna Dayalı ESA Modelleri ile Standart Önceden Eğitilmiş Modellerin Karşılaştırılması (%)

Model	Doğruluk	F1-skor	Kesinlik	Duyarlılık
VGG16	86,68	86,93	88,18	86,68
InceptionV3	92,68	92,66	92,78	92,68
ResNet101	91,93	91,90	91,95	91,93
DenseNet121	92,00	91,95	92,21	92,00
DenseNet169	92,37	92,35	92,42	92,37
DenseNet201	92,31	92,30	92,43	92,31
VGG16 – ÖE ESA	90,75	90,68	90,89	90,75
InceptionV3 – ÖE ESA	92,37	92,37	92,50	92,37
ResNet101 – ÖE ESA	93,12	93,10	93,18	93,12
DenseNet121 – ÖE ESA	93,87	93,86	94,01	93,87
DenseNet169 – ÖE ESA	93,62	93,60	93,75	93,62
<b>DenseNet201 – ÖE ESA</b>	<b>94,25</b>	<b>94,24</b>	<b>94,28</b>	<b>94,24</b>

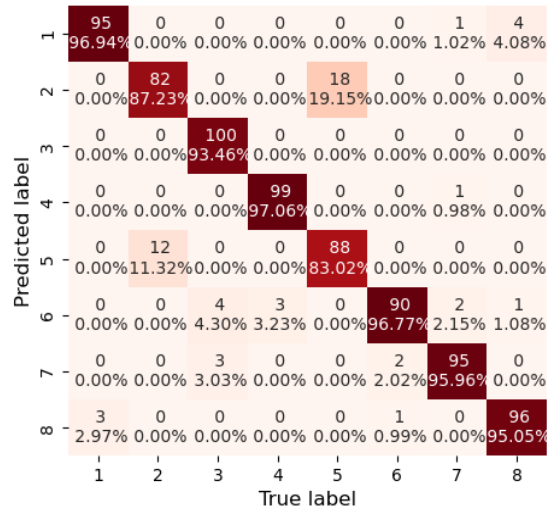


**Standart Önceden Eğitilmiş Modeller**

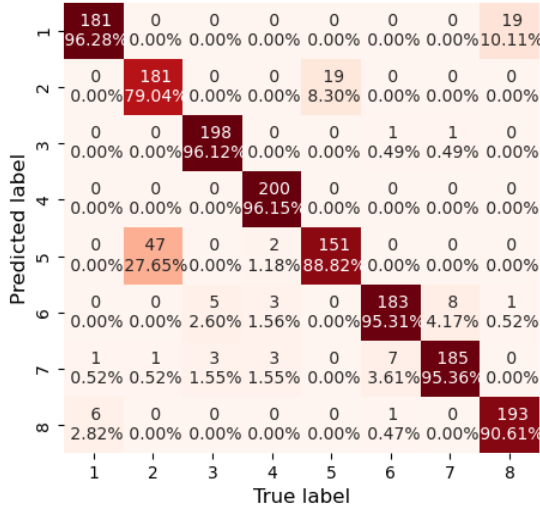
**Önerilen Öz nitelik Entegrasyonuna Dayalı  
 ESA Modelleri**




**ResNet101**



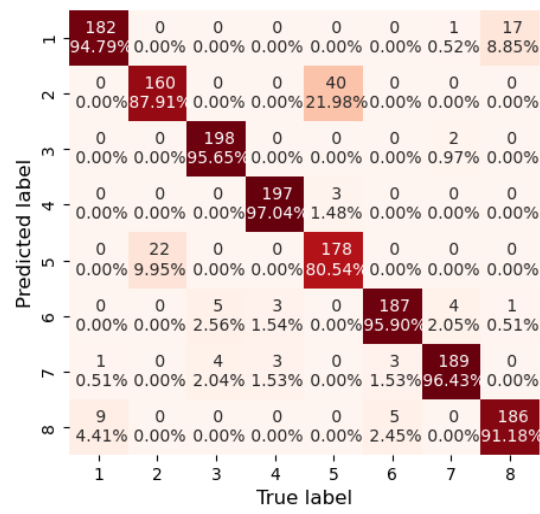
**ResNet101**




**DenseNet121**



**DenseNet121**



**DenseNet201**



**DenseNet201**

**Şekil 4. Karışıklık Matrisleri**

Tablo 1’ de, önerilen ÖE ESA modelinin DenseNet201 mimarisi ile birlikte kullanımının en başarılı sonuçları verdiği görülmüştür. DenseNet201 – ÖE ESA modelinin etkinliğini görmek için literatürden aynı veri setini kullanan son yıllarda yapılan çalışmaların karşılaştırılması Tablo 2’ de verilmiştir. Tablo 2’ ye göre, önerilen DenseNet201 – ÖE ESA modeli ile %94.25 sınıflandırma doğruluk değeri elde edilmiştir. Önerilen modele en yakın doğruluk değeri Lonseko vd. (2021) tarafından geliştirilen derin ESA tabanlı uzamsal dikkat mekanizması yöntemi ile bulunmuştur. Önerilen DenseNet201-ÖE ESA modeli, Lonseko vd. (2021) tarafından önerilen modelden %1.06 daha başarılı doğruluk değeri elde etmiştir. Bunun yanı sıra, önerilen DenseNet201- ÖE ESA modeli, Gunasekaran vd. (2023) tarafından geliştirilen topluluk modeli (DenseNet201, InceptionV3 ve ResNet50) yönteminden %1.29, Liu vd. (2017) tarafından geliştirilen çift yönlü marjinal fisher analizi + destek vektör makinesi yönteminden %1.65, Du vd. (2022) tarafından geliştirilen yeni yarı denetimli verimli karşılaştırmalı öğrenme yönteminden %1.68, Owais vd. (2019) tarafından geliştirilen ESA (ResNet) + LSTM yönteminden %1.68 daha başarılı doğruluk değeri elde etmiştir. Bu yöntemlerin yanı sıra, Du vd. (2020) tarafından geliştirilen ince ayar yapılmış ResNet152 modelinden %4.08, Xing vd. (2020) tarafından geliştirilen iki dallı yeni bir dikkat kılavuzlu deformasyon ağından %2.92, Pogorelov vd. (2017) tarafından önerilen altı katmanlı ESA modelinden %2.85, Pozdeev vd. (2019) tarafından önerilen ikili sınıflandırma ve ESA modelinden %6.25 daha başarılı doğruluk değeri elde edilmiştir. En düşük doğruluk değeri %83.8 ile Agrawa vd. (2017) tarafından geliştirilen VGG + InceptionV3 modelinde bulunmuştur. Daha sonra Kahsaygebreslassie vd. (2019) tarafından geliştirilen DenseNet121 ve ResNet50 modelleri ile %86.9 ve %87.8 doğruluk değerleri bulunmuştur. Tüm yöntemler göz önüne alındığında önerilen DenseNet201 – ÖE ESA modelinin diğer modellerden başarılı doğruluk değeri elde ettiği açıkça görülmektedir.

**Tablo 2.** Literatürde Kvasirv2 Veri Setini Kullanan Çalışmalarla Karşılaştırma Sonuçları (%)

Literatürdeki Çalışma	Yöntem	Doğruluk
(Gunasekaran vd., 2023)	Topluluk modeli (DenseNet201, InceptionV3 ve ResNet50)	92,96
(Lonseko vd., 2021)	Derin ESA tabanlı uzamsal dikkat mekanizması	93,19
(Xing vd., 2020)	İki dallı yeni bir dikkat kılavuzlu deformasyon ağı	91,33
(Pozdeev vd., 2019)	İkili sınıflandırma + ESA	88
(Agrawa vd., 2017)	VGG + InceptionV3	83,8
(Pogorelov vd., 2017)	Altı katmanlı ESA	91,4
(Kahsaygebreslassie vd., 2019)	DenseNet121 ve ResNet50	86,9 - 87,8
(Liu vd., 2017)	Çift yönlü marjinal Fisher analizi + Destek vektör makinesi	92,6
(Du vd., 2020)	İnce ayar yapılmış ResNet152	90,17
(Du vd., 2022)	Yeni yarı denetimli verimli karşılaştırmalı öğrenme	92,57
(Owais vd., 2019)	ESA (ResNet) + LSTM	92,57
<b>Önerilen Yöntem</b>	<b>DenseNet201 – ÖE ESA</b>	<b>94,25</b>

## SONUÇ

GI hastalıklar insan sindirim sisteminde yaygındır ve halk sağlığı için önemli bir tehdit oluşturmaktadır. GI hastalıklarının erken dönemde taranması çok önemlidir ve endoskopi görüntüleri GI hastalık tespitinde önemli rol oynamaktadır. Endoskopi şu anda GI sisteminin incelenmesi için tercih edilen yöntemdir; bununla birlikte, etkinliği, modellerin performansındaki farklılıklar nedeniyle ciddi şekilde sınırlıdır. Endoskopi ile ilgili sorunlardan biri, zaman alıcı olması ve büyük miktarda görüntü verisinin analizinin tıp uzmanları tarafından uzun vadeli çaba gerektirmesidir. Ayrıca, bazı hastalık belirtileri görüntü kalitesi nedeniyle net bir şekilde görülemez, bu nedenle tıp uzmanları bile kritik hastalık alanlarını gözden kaçırabilmektedir. GI sistem hastalığının endoskopik görüntülerden otomatik olarak teşhis edilmesi, yani bir çerçevenin hastalık içerip içermediğinin sınıflandırılması, klinik uygulamada etkinliğin ve doğruluğun artırılması açısından büyük önem taşımaktadır. Bu doğrultuda, son yıllarda derin öğrenme ve özellikle ESA tabanlı çalışmalar yapılmaya başlanmıştır. Bu çalışma, derin öğrenme tekniklerinin GI hastalıkları tespit etmeye yardımcı olma konusundaki büyük potansiyelini göstermeyi amaçlamaktadır. Bu amaç doğrultusunda, bu çalışmada önceden eğitilmiş mimarilerin ara katmanlarından elde edilen öznetelikleri birleştirerek sınıflandırma için yeni bir model önerilmiştir. Öznetelik Entegrasyonuna dayalı Evrişimsel Sinir Ağ (ÖE-ESA) olarak adlandırılan bu mimaride, endoskopik görüntüleri sınıflandırmak için önceden eğitilmiş ağ mimarilerinin yüksek ve düşük

seviyeli öznetelikleri birleştirilerek nihai öznetelik haritası elde edilmektedir. Önerilen yöntemin etkinliğini analiz etmek için Kvasirv2 veri seti üzerinde deneysel çalışmalar gerçekleştirilmiştir. Önerilen DenseNet201-ÖE ESA modeli, bu veri setinde, değerlendirme için kullanılan mevcut yöntemlerden daha başarılı olan %94.25' lik bir doğruluk oranına ulaşmıştır. Bu sonuçlar göz önüne alındığında, önerilen DenseNet201-ÖE ESA modeli, çeşitli GI hastalıklarının klinik teşhisine yardımcı olma potansiyeline sahiptir. Aynı zamanda, bu çalışmanın sonuçları, evrişimli sinir ağlarına ve entegre çerçevemize dayalı bilgisayar görme modellerinin, GI hastalıkları tespit etmek için tıp alanında pratik olarak uygulanabileceğini doğrulamaktadır. Gelecek çalışmalarda, (i) GI hastalıkların sınıflandırmasında doğruluğu arttırmak için yeni derin ESA modellerinin tasarlanması ve (ii) modelin performansını arttırmak ve hastalık yerinin tespiti için derin öğrenmede segmentasyon modellerinin kullanılması planlanmaktadır.

## KAYNAKLAR

- Agrawa, T., Gupta, R., Sahu, S., & Wilson, C. E. (2017). SCL-UMD at the medico task-mediaeval 2017: Transfer learning based classification of medical images. *CEUR Workshop Proceedings, 1984*, 3–5.
- Borgli, H., Thambawita, V., Smedsrud, P. H., Hicks, S., Jha, D., Eskeland, S. L., ... de Lange, T. (2020). HyperKvasir, a comprehensive multi-class image and video dataset for gastrointestinal endoscopy. *Scientific Data, 7*(1), 1–14. <https://doi.org/10.1038/s41597-020-00622-y>
- Du, W., Rao, N., Wang, Y., Hu, D., & Yong, J. (2020). Efficient Transfer Learning Used in the Classification of Gastroscopic Images with Small Dataset. *2020 17th International Computer Conference on Wavelet Active Media Technology and Information Processing, ICCWAMTIP 2020*, 73–76. <https://doi.org/10.1109/ICCWAMTIP51612.2020.9317450>
- Du, W., Rao, N., Yong, J., Wang, Y., Hu, D., Gan, T., ... Zeng, B. (2022). Improving the Classification Performance of Esophageal Disease on Small Dataset by Semi-supervised Efficient Contrastive Learning. *Journal of Medical Systems, 46*(1). <https://doi.org/10.1007/s10916-021-01782-z>
- Gunasekaran, H., Ramalakshmi, K., & Swaminathan, D. K. (2023). GIT-Net : An Ensemble Deep Learning-Based GI Tract Classification of Endoscopic Images. *Bioengineering, 10*(809).
- Ha, Y., Du, Z., & Tian, J. (2022). Fine-grained interactive attention learning for semi-supervised white blood cell classification. *Biomedical Signal Processing and Control, 75*(September 2021), 103611. <https://doi.org/10.1016/j.bspc.2022.103611>
- Haile, M. B., Salau, A. O., Enyew, B., Belay, A. J., & Jin, Z. (2022). Detection and classification of gastrointestinal disease using convolutional neural network and SVM Detection and classification of gastrointestinal disease using convolutional neural network and. *Cogent Engineering, 9*(1). <https://doi.org/10.1080/23311916.2022.2084878>
- Iqbal, I., Walayat, K., Kakar, M. U., & Ma, J. (2022). Automated identification of human gastrointestinal tract abnormalities based on deep convolutional neural network with endoscopic images. *Intelligent Systems with Applications, 16*(November), 200149. <https://doi.org/10.1016/j.iswa.2022.200149>
- Kahsaygebressie, A., Yaacobgirmaygezahegn, Hagos, M. T., Achimibenthal, & Pooja. (2019). Automated Gastrointestinal Disease Recognition for Endoscopic Images. *Proceedings - 2019 International Conference on Computing, Communication, and Intelligent Systems, ICCIS 2019, 2019-Janua*, 312–316. <https://doi.org/10.1109/ICCIS48478.2019.8974458>
- Kaminski, M. F., Regula, J., Kraszewska, E., Polkowski, M., Wojciechowska, U., Didkowska, J., ... Butruk, E. (2010). Quality indicators for colonoscopy and the risk of interval cancer. *The New England Journal of Medicine, 362*(19), 1795–1803. <https://doi.org/10.1056/NEJMoa0907667>
- Khan, M. A., Sarfraz, M. S., Alhaisoni, M., Albeshier, A. A., Wang, S., & Ashraf, I. (2020). StomachNet: Optimal deep learning features fusion for stomach abnormalities classification. *IEEE Access, 8*, 197969–197981. <https://doi.org/10.1109/ACCESS.2020.3034217>
- Lin, T., Doll, P., Girshick, R., He, K., Hariharan, B., Belongie, S., & Ai, F. (2017). Feature Pyramid Networks for Object Detection.
- Liu, Y., Gu, Z., & Cheung, W. K. (2017). HKBU at mediaeval 2017 medico: Medical multimedia task. *CEUR Workshop Proceedings, 1984*, 1–3.
- Lonseko, Z. M., Adjei, P. E., Du, W., Luo, C., Hu, D., Zhu, L., ... Rao, N. (2021). Gastrointestinal disease

- classification in endoscopic images using attention-guided convolutional neural networks. *Applied Sciences (Switzerland)*, 11(23). <https://doi.org/10.3390/app112311136>
- Majid, A., Khan, M. A., Yasmin, M., Rehman, A., Yousafzai, A., & Tariq, U. (2020). Classification of stomach infections: A paradigm of convolutional neural network along with classical features fusion and selection. *Microscopy Research and Technique*, 83(5), 562–576. <https://doi.org/10.1002/jemt.23447>
- Mohapatra, S., Kumar Pati, G., Mishra, M., & Swarnkar, T. (2023). Gastrointestinal abnormality detection and classification using empirical wavelet transform and deep convolutional neural network from endoscopic images. *Ain Shams Engineering Journal*, 14(4), 101942. <https://doi.org/10.1016/j.asej.2022.101942>
- Naz, J., Sharif, M., Yasmin, M., Raza, M., & Khan, M. A. (2021). Detection and Classification of Gastrointestinal Diseases using Machine Learning. *Current Medical Imaging*, 17(4), 479–490. <https://doi.org/10.2174/1573405616666200928144626>
- Owais, M., Arsalan, M., Choi, J., Mahmood, T., & Park, K. R. (2019). Artificial intelligence-based classification of multiple gastrointestinal diseases using endoscopy videos for clinical diagnosis. *Journal of Clinical Medicine*, 8(7). <https://doi.org/10.3390/jcm8070986>
- Pogorelov, K., Randel, K. R., Griwodz, C., Eskeland, S. L., De Lange, T., Johansen, D., ... Halvorsen, P. (2017). Kvasir: A multi-class image dataset for computer aided gastrointestinal disease detection. *Proceedings of the 8th ACM Multimedia Systems Conference, MMSys 2017*, 164–169. <https://doi.org/10.1145/3083187.3083212>
- Poudel, S., Kim, Y. J., Vo, D. M., & Lee, S. W. (2020). Colorectal Disease Classification Using Efficiently Scaled Dilation in Convolutional Neural Network. *IEEE Access*, 8, 99227–99238. <https://doi.org/10.1109/ACCESS.2020.2996770>
- Pozdeev, A. A., Obukhova, N. A., & Motyko, A. A. (2019). Automatic Analysis of Endoscopic Images for Polyps Detection and Segmentation. In *2019 IEEE Conference of Russian Young Researchers in Electrical and Electronic Engineering (EIConRus)* (pp. 1216–1220). <https://doi.org/10.1109/EIConRus.2019.8657018>
- Ronneberger, O., Fischer, P., & Brox, T. (2015). U-Net: Convolutional Networks for Biomedical Image Segmentation. In N. Navab, J. Hornegger, W. M. Wells, & A. F. Frangi (Eds.), *Medical Image Computing and Computer-Assisted Intervention -- MICCAI 2015* (pp. 234–241). Cham: Springer International Publishing.
- Shahin, A. I., Guo, Y., Amin, K. M., & Sharawi, A. A. (2019). White blood cells identification system based on convolutional deep neural learning networks. *Computer Methods and Programs in Biomedicine*, 168, 69–80. <https://doi.org/10.1016/j.cmpb.2017.11.015>
- Soffer, S., Klang, E., Shimon, O., Nachmias, N., Eliakim, R., Ben-Horin, S., ... Barash, Y. (2020). Deep learning for wireless capsule endoscopy: a systematic review and meta-analysis. *Gastrointestinal Endoscopy*, 92(4), 831-839.e8. <https://doi.org/10.1016/j.gie.2020.04.039>
- Su, Q., Wang, F., Chen, D., Chen, G., Li, C., & Wei, L. (2022). Deep convolutional neural networks with ensemble learning and transfer learning for automated detection of gastrointestinal diseases. *Computers in Biology and Medicine*, 150(July), 106054. <https://doi.org/10.1016/j.compbimed.2022.106054>
- Ucan, M., Kaya, B., & Kaya, M. (2022). Multi-Class Gastrointestinal Images Classification Using EfficientNet-B0 CNN Model. *2022 International Conference on Data Analytics for Business and Industry, ICDABI 2022*, 146–150. <https://doi.org/10.1109/ICDABI56818.2022.10041447>
- Xing, X., Yuan, Y., & Meng, M. Q. H. (2020). Zoom in Lesions for Better Diagnosis: Attention Guided Deformation Network for WCE Image Classification. *IEEE Transactions on Medical Imaging*, 39(12), 4047–4059. <https://doi.org/10.1109/TMI.2020.3010102>