



Ağırlıklandırılmış Evrişimsel Sinir Ağları Topluluğu ile Göğüs Radyografilerinden Kardiyomegali Tespiti

Ensemble of Weighted Convolutional Neural Networks for Detection of Cardiomegaly from Chest Radiographs

Enes Ayan^{1*}

^{1*}Kırıkkale Üniversitesi, Mühendislik ve Doğa Bilimleri Fakültesi, Bilgisayar Mühendisliği Bölümü, 71450, Kırıkkale, Türkiye

Başvuru/Received: 28/09/2023

Kabul/Accepted: 19/12/2023

Çevrimiçi Basım/Published Online: 31/01/2024

Son Versiyon/Final Version: 31/01/2024

Öz

Kardiyomegali bir hastalık olmamasına karşın birçok kalp rahatsızlığının belirtisi olarak ortaya çıkabilmektedir. Bu belirtinin erken teşhis edilip altında yatan sebeplerin araştırılması hasta için hayati bir önem arz etmektedir. Kardiyomegali teşhisi için en sık kullanılan yöntemlerden biri göğüs radyografisidir. Derin öğrenme yöntemleri ile radyografik görüntülerin analizi son yıllarda oldukça popüler bir çalışma alanıdır. Özellikle evrişimsel sinir ağları medikal görüntü analizinde başarılı sonuçlar elde etmiştir. Bu çalışmada hekimlerin göğüs radyografilerini analiz ederken ikinci bir görüş alabilecekleri, göğüs radyografilerini normal ve kardiyomegali olmak üzere sınıflandıracak ağırlıklandırılmış evrişimsel sinir ağı (ESA) topluluğu önerilmiştir. Bu bağlamda kardiyomegali tespit etmesi için eğitilen on ESA modeli arasından en başarılı üç model ağırlıklandırılmış topluluk yöntemi için seçilmiştir. Seçilen modellerin ağırlıkları parçacık sürü optimizasyon algoritması kullanılarak belirlenmiştir. Elde edilen ağırlıklar kullanılarak yapılan testler sonucunda önerilen yöntem %89,09 doğruluk %89,09 duyarlılık, %89,30 kesinlik ve %89,08 F1 skor değerleri elde etmiştir.

Anahtar Kelimeler

“Evrişimsel sinir Ağları, Parçacık sürü optimizasyonu, Kardiyomegali, Derin öğrenme”

Abstract

Cardiomegaly is not a disease. However, it can be a symptom of many heart conditions. Early diagnosis of this symptom and investigation of the underlying causes is of vital importance for the patient. One of the most commonly used methods for the diagnosis of cardiomegaly is chest radiography. Analyzing radiographic images with deep learning methods is a very popular study area in recent years. Especially convolutional neural networks (CNNs) have achieved successful results in medical image analysis. In this study, a weighted CNN ensemble is proposed to classify chest radiographs as normal and cardiomegaly so that physicians can get a second opinion when analyzing chest radiographs. In this context, the three most successful models among the ten CNN models trained to detect cardiomegaly were selected for the weighted ensemble method. The weights of the selected models were determined using particle swarm optimization algorithm. As a result of the tests performed using the obtained weights, the proposed method obtained 89.09% accuracy, 89.09% sensitivity, 89.30% precision and 89.08% F1 score values.

Key Words

“Convolutional neural networks, Particle swarm optimization, Cardiomegaly, Deep learning”

1. Giriş

Kardiyomegali, kalbin anormal şekilde büyümesi ile ortaya çıkan bir kardiyovasküler hastalık belirtisidir. Kalp hasarı veya kalp yetmezliği, tansiyon, hipertansiyon ve koroner arter rahatsızlığı gibi bazı kalp hastalıkları kalbin büyümesine neden olabilmektedir (Semsarian vd., 2015). Eğer gerekli önlemler alınmaz ise bu büyüme kalp krizine hatta ölüme yol açmaktadır. Kardiyomegali bir hastalıktan ziyade bir hastalık belirtisi olarak görülmektedir. Bu durum geçici veya kalıcı olabilir. Tahminlere göre Amerika'da her yıl 200.000'den fazla yeni kardiyomegali vakası ortaya çıkmaktadır. Bu durum orta yaşlı ve yaşlı nüfusu için önemli bir sağlık sorunudur (Zhou vd., 2019).

Kardiyomegali erken teşhis edildiğinde bu duruma yol açan etmenin tespiti ve tedavisi daha kolay olabilmektedir (Jamrozý vd., 2010). Kardiyomegalinin teşhis sürecinde tıbbi görüntüleme sık kullanılan yöntemlerden biridir. Tıbbi görüntüler, doktorlara teşhis ve tedavi kararları vermeleri için hayati bilgiler sağlar. Karar verme sürecinde, görüntülerin uzman tarafından manuel olarak yorumlanmasına dayanmaktadır. Kardiyomegali varlığının incelenmesi için kullanılan en basit metot göğüs radyografisi görüntüleme yöntemidir. Bu görüntüleme yöntemi düşük radyosun dozu içermesi ve uygun maliyetli olması bakımından kardiyomegaliyi hızlı bir şekilde incelemek için sıkça başvurulan bir yöntemdir. Ancak kardiyomegalinin göğüs radyografisi görüntülerinden tespiti deneyim gerektiren, zaman alıcı ve zor bir iştir. Bu nedenle uzmanlara yardımcı olacak, ikinci bir görüş sunacak bilgisayar destekli tanı sistemlerine ihtiyaç her geçen gün artmaktadır (Candemir ve Antani, 2019; Peng vd., 2019). Yapay zeka destekli bilgisayar tanı sistemleri zatürre, covid 19, kronik obstrüktif akciğer hastalığı, tüberküloz, ve akciğer kanseri gibi farklı hastalıkları göğüs röntgenleri üzerinden tespit etmekte kullanılmaktadır (Qin vd., 2018). Yapay zekadaki son birkaç yılda kaydedilen ilerlemeler sonucunda araştırmacılar, tıbbi görüntü analizi için çeşitli derin öğrenme algoritmaları geliştirmişlerdir (Abdelrahman vd., 2021; Dash vd., 2019; Qin vd., 2018). Özellikle memeli hayvanların görsel korteksinden ilham alınarak geliştirilen evrimsel sinir ağları medikal görüntü analizinde insan üstü başarılar göstermiştir (Li vd., 2021). Evrimsel sinir ağlarının başarısının altında yatan en temel etmenlerden biri de günümüzde erişime açık olarak sunulan büyük veri setleridir. Bu veri setlerinden biri olan 14 farklı göğüs hastalığını içeren CXR14 veri setidir (Wang vd., 2017). Söz konusu veri setleri kardiyomegali tespiti içinde birçok çalışmanın yapılmasına önyak olmuştur.

Literatürde kardiyomegali tespiti için yapılmış çeşitli çalışmalar bulunmaktadır. Ishida vd. (2005) göğüs röntgenlerinde kardiyotorasik oran (KO) adı verilen, kalbin büyüklüğü ile göğüs büyüklüğü arasındaki ilişkiyi gösteren ve kardiyomegaliyi tespit etmekte kullanılan oranı otomatik olarak belirlemek için, gri seviye histogram analizi ile bir kenar algılama algoritmasının birleştirilmesine dayanan bir yöntem önermişlerdir. Torres-Robles vd. (2014) çalışmalarında göğüs röntgenlerinden kardiyomegaliyi tespit etmek için nöro-bulanık bir sınıflandırıcı önermişlerdir. Çalışmada, nöro-bulanık sınıflandırıcı akciğerleri bölütleme amacıyla klasik morfoloji operasyonlarıyla kullanılmış ve böylece kalp genişlemesini ölçmek için özellik değerleri elde edilmiştir. Ilovar ve Şajn (2011) çeşitli görüntü işleme yöntemlerinden faydalanarak kalbin ve göğüs boşluğunun genişliğini ölçen için bir kenar dedektörü ile göğüs radyografi analizi ve kardiyomegali tespiti gerçekleştirmiştir. Candemir vd. (2018) faklı ESA mimarilerini aktarım öğrenme yöntemini kullanarak göğüs röntgenlerinden kardiyomegaliyi sınıflandırmak için eğitmişlerdir. Que vd. (2018) göğüs radyografilerinden kardiyomegaliyi teşhis etmek için CardioXNet'i adını verdikleri bir derin öğrenme modeli önermişlerdir. Çalışmada kardiyomegali tespiti için kardiyotorasik oran kriter olarak kullanılmıştır. Çalışmada KO değerinin 0.5'ten yüksek olması kardiyomegali varlığına bir işaret olarak gösterilmektedir. Önerdikleri bölütleme tabanlı derin öğrenme yönteminde DenseNet mimarisi ile U-Net mimarisini birleştirmişlerdir. Innat vd. (2023) Cardio-XAttentionNet ismini verdikleri bir derin öğrenme modeli ile göğüs radyografilerini normal ve kardiyomegali olmak üzere sınıflandırmışlardır. Çalışmada evrimsel dikkat haritalama modülü kullanılarak modelin radyografi içinde özellikle kardiyomegalinin tespitinin edileceği bölgeye odaklanması amaçlanmıştır. Chen vd. (2022) göğüs radyografilerinde kardiyomegaliyi sınıflandırmak için kanal dikkat modülü ve uzamsal dikkat modüllerini kullanarak geliştirdikleri CXRDANet isimli derin öğrenme mimarisini önermişlerdir. Bouslama vd. (2020) U-Net tabanlı bir derin öğrenme modeli kullanarak kardiyomegaliyi göğüs radyografilerinde segmentasyon yaparak tespit etmeyi başarmışlardır. Wu vd. (2022) çalışmalarında, göğüs radyografisi incelemelerine dayalı klinik uygulamalarda hızlı kardiyomegali taraması için 2D (iki boyutlu) ve 1D (tek boyutlu) evrimsel sinir ağı tabanlı bir sınıflandırıcı tasarlamışlardır. Sogancioglu vd. (2020) göğüs radyografilerinde kardiyomegali tespitini iki alternatif derin öğrenme yaklaşımı olan anatomik segmentasyon ve görüntü düzeyinde sınıflandırma yoluyla gerçekleştirmişler ve yöntemlerin performanslarını değerlendirmişlerdir.

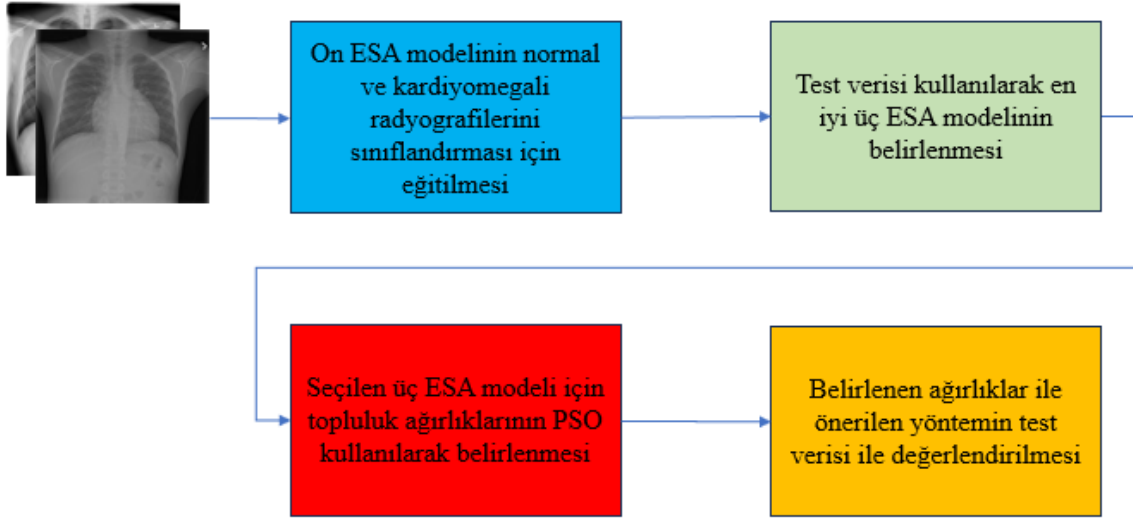
Literatürde yapılan çalışmalar incelendiğinde derin öğrenme yaklaşımlarının son yıllarda oldukça popüler olduğu görülmektedir. Bu yaklaşımlar içinde ise kardiyomegali tespitininin, sınıflandırma veya segmentasyon yöntemleriyle tespit edildiği çalışmalar öne çıkmaktadır. Ancak halen yüksek doğrulukta tespit yapabilen bir yöntem bulunmamaktadır. Bu bağlamda tespit performansının artırılması bir ihtiyaç olarak görülmektedir. Bu çalışmada göğüs radyografilerini kardiyomegali ve normal olmak üzere sınıflandırmak için evrimsel sinir ağlarının ağırlıklandırılmış topluluk yöntemine dayalı bir yaklaşım önerilmektedir. Daha önce ImageNet veri seti ile eğitilmiş on ESA modeli DenseNet-(121, 169, 201) (Huang vd., 2017), InceptionResNetV2 (Szegedy vd., 2017), NASNetMobile (Zoph vd., 2018), ResNet-(50,101,152) V2 (He vd., 2016), Xception (Chollet, 2017), VGG-16 (Simonyan ve Zisserman, 2014) göğüs radyografilerini kardiyomegali ve normal olmak üzere sınıflandırmak üzere tekrar eğitilmiştir. Eğitilen modeller arasından en başarılı VGG-16, DenseNet-121 ve ResNet-50V2 ESA modeli ağırlıklandırılmış topluluk yöntemiyle göğüs radyografilerini kardiyomegali ve normal olmak üzere sınıflandırmak üzere kullanılmıştır. Ağırlıklandırılmış topluluk yöntemi için gerekli olan ağırlık değerleri parçacık sürü optimizasyonu algoritması kullanılarak belirlenmiştir.

Çalışmanın ikinci bölümünde kullanılan veri seti, metotlar ve bu metotların değerlendirme kriterlerinden bahsedilmiştir. Üçüncü bölümünde elde edilen sonuçlar paylaşılmıştır. Dördüncü bölümde sonuçlar irdelenmiş literatürde yapılan diğer çalışmalar ile karşılaştırılmıştır. Makalenin son bölümü ise sonuç kısmını oluşturmaktadır.

2. Materyal ve Metot

2.1. Çalışma tasarımı

Bu çalışmada göğüs radyografilerini kardiyomegali ve normal olmak üzere sınıflandırmak üzere üç aşamadan oluşan bir yöntem önerilmiştir. Çalışmanın ilk aşamasında on farklı ESA mimarisi göğüs radyografilerini kardiyomegali ve normal olmak üzere sınıflandırmak üzere aktarım öğrenme yöntemleri kullanılarak eğitilmiştir. İki aşamada eğitilen modeller arasından en başarılı üçü test verisi ile değerlendirilerek seçilmiştir. Seçilen üç model doğrulama verisi kullanılarak PSO algoritması ile topluluk ağırlıkları belirlenmiştir. Belirlenen ağırlıklar kullanılarak önerilen yöntemin test verisi üzerinde göğüs radyografilerinden kardiyomegali tespitinde performansı değerlendirilmiştir. Önerilen yöntemin aşamalarını içeren bir görsel şekil 1’de verilmiştir.




Şekil 1. Önerilen yönteme ait akış şeması.

2.2. Veri Seti

Bu çalışmada Chest X-ray 14 (Wang vd., 2017; Summers vd., 2023) veri seti kullanılmıştır. Veri seti 30805 hastadan elde edilmiş toplam 112120 görüntüden göğüs radyografisinden meydana gelmektedir. Görüntüler içinde kardiyomegali ve normal vakalarının da yer aldığı 14 farklı göğüs hastalığını barındırmaktadır. Çalışmada yalnızca kardiyomegali ve normal örneklerin sınıflandırılmasına odaklanıldığı için veri seti içinden 1093 adet kardiyomegali içeren görüntü alınmıştır. Veri setinde dengeyi korumak adına normal yani herhangi bir hastalık içermeyen örnekler arasından 1093 tane rastgele normal radyografi seçilmiştir. Toplamda 2186 adet görüntü içeren bir alt veri seti oluşturulmuştur. Sonrasında veri seti 80:10:10 olacak şekilde eğitim, doğrulama ve test olarak ayrılmıştır. Tablo 1’de dağılım detaylı olarak verilmiştir. Ayrıca şekil 2’de veri setinden bazı örnekler yer verilmiştir.

Tablo 1. Veri Seti Örneklem Dağılımı

	Eğitim	Doğrulama	Test
Normal	874	109	110
Kardiyomegali	874	109	110
Toplam	1748	218	220
Genel Toplam	2186		



Şekil 2. Veri Setinden Örnekler (a) Normal Radyografi (b) Kardiyomegali İçeren Radyografi

2.3. Evrişimsel sinir ağları

Evrişimsel sinir ağları memeli hayvanların görsel algı sisteminden ilham alınarak geliştirilmiş bir tür yapay sinir ağıdır. Özellikle sınıflandırma, segmentasyon, nesne tespiti, nesne takibi gibi bilgisayarlı görü problemlerinin çözümünde insan üstü başarılar sergilemişlerdir (Krizhevsky vd., 2012). Temel bir ESA modeli iki özellik çıkarıcı ve sınıflandırıcı olmak üzere iki kısımdan meydana gelmektedir. Özellik çıkarıcı kısmında, peş peşe gelen evrişim katmaları (filtreler), aktivasyon fonksiyonu ve havuzlama katmanları bulunmaktadır. Sınıflandırıcı kısmı ise normal tam bağımlı bir yapay sinir ağından meydana gelmektedir. Farklı boyutlarda ve sayılardaki filtreler yardımı ile çeşitli ESA mimarileri geliştirilmektedir. Bu mimarilerin kullandıkları yöntemler ve derinlikleri düşünüldüğünde her birinin aynı problem üzerinde göstermiş oldukları sınıflandırma performansı farklı olabilmektedir. Bu bağlamda çalışmada on farklı ESA modeli kardiyomegali ve normal görüntüleri sınıflandırmak için eğitilmiştir. Bunlardan en başarılı üçü önerilen ağırlıklandırılmış oylama yöntemi için seçilmiştir. Seçilen modellere makalenin devamında kısaca değinilmiştir.

2.2.1. VGG

VGG mimarisi 2014 yılında Simonyan ve Zisserman tarafından geliştirilmiştir. Mimaride büyük evrişim filtreleri kullanmak yerine küçük (3x3) evrişim filtrelerini kullanarak daha derin modelleri oluşturmak hedeflenmiştir. Araştırmacılar 11, 13, 16 ve 19 katman derinliğe sahip modelleri görüntü sınıflandırma problemleri için kullanmışlardır. Literatürde en bilinen ve kullanılanları VGG-16 ve VGG-19 modelleridir. Geliştirdikleri VGG mimarisi ImageNet 2014 yarışmasında görüntü sınıflandırma kategorisinde ikinci olmuştur. Bu çalışmada VGG-16 mimarisi kullanılmıştır. Evrişimsel katmanların sonuna bir adet global ortalama havuzlama katmanı eklenmiş bu katman sonrasında ise tek nörondan oluşan bir çıkış katmanı kullanılmıştır.

2.2.2 DenseNet

DenseNet mimarisi 2016 yılında Huang ve arkadaşları tarafından geliştirilmiştir. Geleneksel ileri beslemeli ESA'da, girdi katmanı hariç her bir evrişimsel katman, bir önceki evrişimsel katmanın çıktısını alır ve daha sonra bir sonraki evrişimsel katmana aktarılan özellik haritalar üretir. Ancak, ESA'lardaki katman sayısı arttıkça, yani katmanlar derinleştikçe, kaybolan gradyan sorunu ortaya çıkar. Bu sorun ağırlık yayılımı esnasında özellikle çıkışa uzak katmanlarda bilgilerin kaybolmasına ve sonucunda ağırlık etkili bir şekilde öğrenme yeteneğinin azalmasına neden olmaktadır. DenseNet mimarisi bu sorunu standart ESA mimarisinde katmanlar arasında bağlantılar oluşturarak çözmektedir. DenseNet mimarisinde, her katman diğer tüm katmanlarla doğrudan bağlantılıdır. DenseNet-121,169,201 ve 264 olmak üzere modelin katman sayısı baz alınarak farklı mimariler tasarlanmıştır. Bu çalışmada DenseNet-121 mimarisi kullanılmıştır. Aynı VGG-16'da olduğu gibi evrişimsel katmanların sonuna bir adet global ortalama havuzlama katmanı eklenmiş bu katman sonrasında ise tek nörondan oluşan bir çıkış katmanı kullanılmıştır.

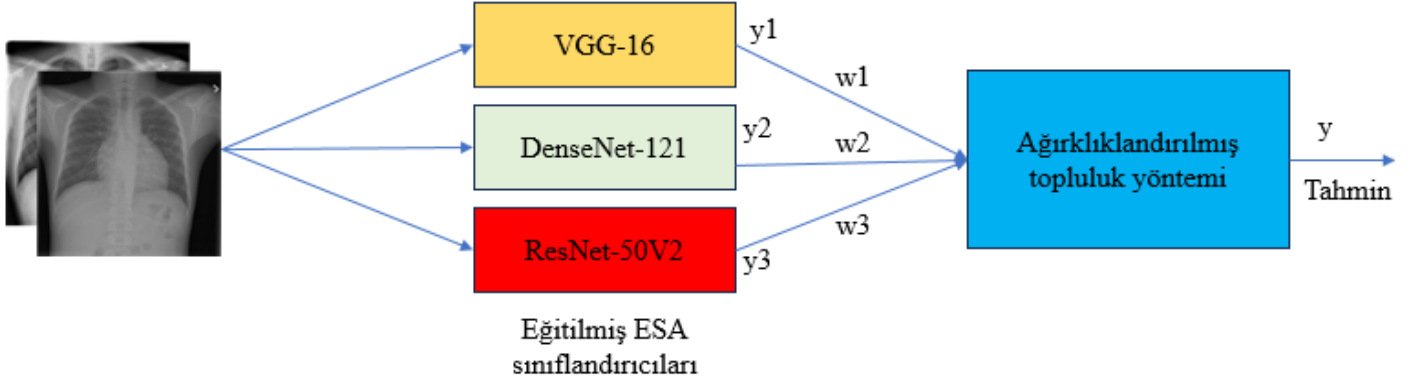
2.2.3 ResNet

ResNet mimarisi 2015 yılında He ve arkadaşları tarafından geliştirilmiştir. Mimaride artık bağlantılar fikri ile kaybolan gradyanlar problemini çözmüşlerdir. Bu fikir sayesinde daha derin mimariler ile başarılı sonuçlar elde edilmiştir. ResNet 2015 yılında ImageNet yarışmasında birinci olmuştur. Mimarinin ResNet-18, 34, 50, 101 ve 152 katmandan oluşan versiyonları bulunmaktadır. Çalışmada her evrişim işlemi uygulanmadan önce yığın normalizasyonu yapan ResNet-50V2 mimarisi kullanılmıştır. Aynı DenseNet-121'de olduğu gibi evrişimsel katmanların sonuna bir adet global ortalama havuzlama katmanı eklenmiş bu katman sonrasında ise tek nörondan oluşan bir çıkış katmanı kullanılmıştır.

2.3. Ağırlıklandırılmış ESA topluluğu

2012 yılında AlexNet (Krizhevsky vd., 2012) ESA mimarisinin ImageNet yarışmasını kazanması ile birlikte araştırmacıların dikkatini çeken ESA'lar birçok bilgisayarlı görü probleminin çözümünde kullanılmıştır (Ayan vd., 2020). 2012'den bu yana farklı derinlikte ve özellikte ESA mimarileri geliştirilmiştir. Geliştirilen bu mimarilerin derinlikleri, mimari yapıları ve çıkarmış oldukları

farklı özellikler dikkate alındığında aynı problem üzerinde farklı sınıflandırma başarıları elde ettikleri bilinmektedir (Ayan vd., 2020). Bu nedenle ESA'ların birleştirilmesi fikri ortaya çıkmıştır. ESA'larda birleştirme özelliklerinin birleştirilmesi ve tahminlerinin birleştirilmesi olmak üzere iki farklı şekilde uygulanabilmektedir. Tahminlerin birleştirilmesi yönteminde modellerin çıktı olarak verdikleri olasılıkların toplamının ortalaması alınarak nihai sonuç alınmaktadır. Bu yöntemde her modelin sonuca etki değeri eşittir. Ancak bu durum sınıflandırma performansını olumsuz etkileyebilmektedir. Modelin sınıflandırma başarısı oranında sonuca etki etmesi daha doğru bir yaklaşımdır. Ağırlıklandırılmış topluluk yöntemi birden fazla modelin, güvenleri veya tahmini performanslarıyla orantılı olarak bir tahmine katkıda bulunmasına olanak tanıyan bir yaklaşımdır. Bu bağlamda her bir modele w_1 , w_2 , w_3 olmak üzere ağırlık değerleri belirlenmiş ve modellerin tahminleri bu ağırlıklar ile çarpılarak nihai çıktı elde edilmiştir. Ağırlıklandırılmış ESA topluluğu yöntemine ait bir görsel şekil 3'te verilmiştir.



Şekil 3. Ağırlıklandırılmış ESA Topluluğu Yöntemi

2.4. Parçacık sürü optimizasyonu tabanlı ESA topluluğunun ağırlıklarının belirlenmesi

Parçacık sürü optimizasyonu algoritması (PSO) 1995 yılında Kennedy ve Eberhart (Eberhart ve Kennedy, 1995) tarafından önerilen güçlü bir meta sezgisel optimizasyon algoritmasıdır. Grup halinde hareket eden bir balık sürüsünün ya da kuş sürüsünün diğer tüm üyelerin deneyimlerinden faydalanabileceği prensibinden yola çıkılarak geliştirilmiştir. Örneğin bir kuş uçarken ve rastgele yiyecek ararken, sürüdeki tüm kuşlar keşiflerini paylaşabilir ve tüm sürünün en iyi avı elde etmesine yardımcı olabilir. Bu olaydan çıkan araştırmacılar parçacık sürüsü metodolojisi kullanarak doğrusal olmayan fonksiyonların optimizasyonu için yeni bir yöntem önermişlerdir. PSO algoritması yalnızca amaç fonksiyonuna ihtiyaç duyması ve hedefin eğitimine veya herhangi bir diferansiyel formuna bağlı olmaması açısından diğer optimizasyon algoritmalarından farklıdır. Aynı zamanda diğer optimizasyon algoritmalarına göre daha az sayıda hiper parametreye sahiptir.

PSO sürü tabanlı bir algoritmadır. Sürüyü oluşturan çoklu parçacıklar kullanır. Her parçacık problem için bir aday çözümü ifade eder. Aday çözümler kümesi aynı anda var olur ve iş birliği yaparlar. Sürüdeki her parçacık arama uzayında uçar ve inmek için en iyi çözümü arar. Dolayısıyla, arama uzayı olası çözümler kümesidir ve uçan parçacıklardan oluşan grup (sürü) probleme dair değişen olası çözümleri temsil eder. Her parçacığın ilişkili olduğu bir konumu, hızı ve problemin çözümüne dair sunduğu bir uygunluk değeri vardır. İterasyonlar boyunca, her parçacık kendi kişisel en iyi çözümünün (optimum) yanı sıra sürüdeki en iyi çözümü (optimum) takip eder. Ardından, iki parametreyi, uçuş hızını ve pozisyonunu değiştirir. Özellikle, her parçacık kendi uçuş deneyimine ve komşularınıninkine yanıt olarak uçuş hızını dinamik olarak ayarlar. Benzer şekilde, mevcut konumu, hızı, mevcut konumu ile kişisel optimum ve mevcut konumu ile sürü optimum arasındaki mesafe bilgilerini kullanarak konumunu değiştirmeye çalışır. Hız ve konum güncelleme formülleri aşağıda verilmiştir.

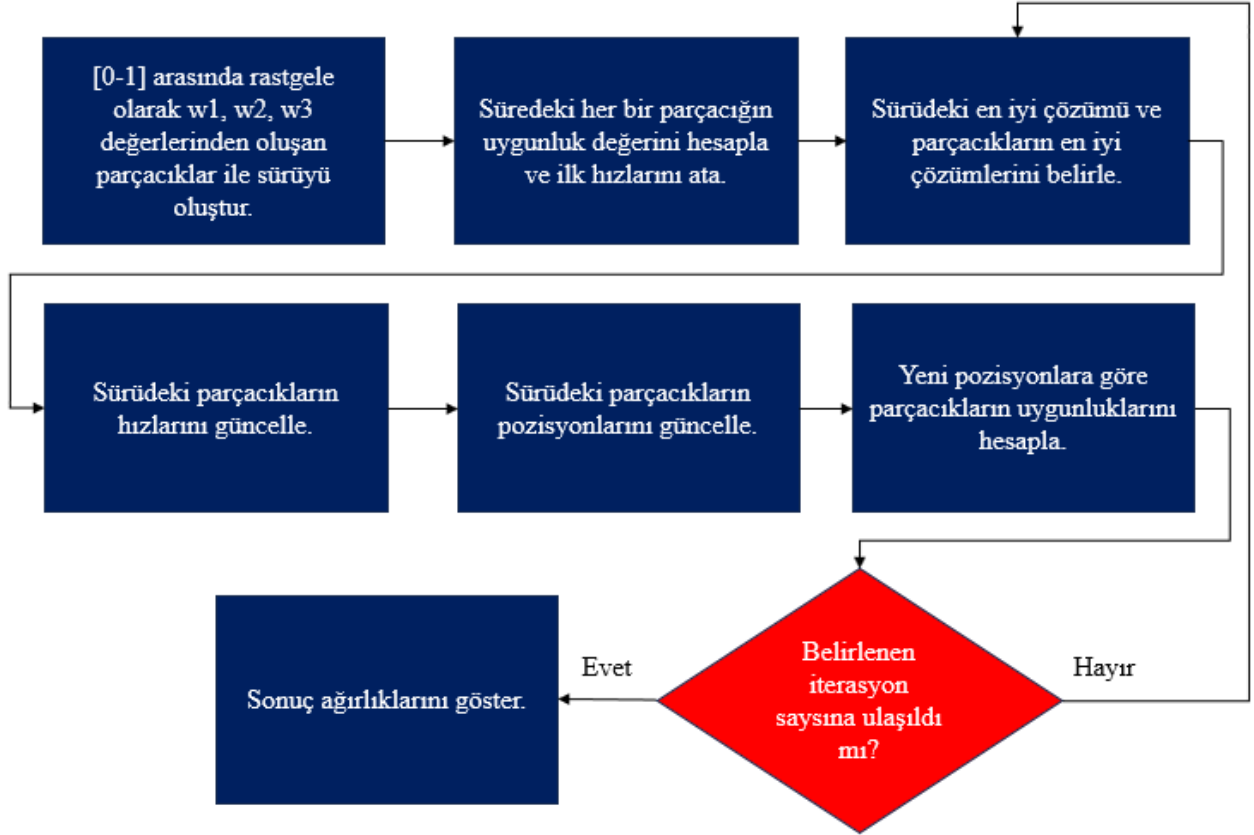
$$v_i^{t+1} = w * v_i^t + c1 * r1 (p_{eniyi_i}^t - p_i^t) + c2 * r2 (g_{eniyi}^t - p_i^t) \quad (1)$$

$$p_i^{t+1} = p_i^t + v_i^{t+1} \quad (2)$$

Formül 1'te v değeri hızı w , $c1$, $c2$, $r1$ ve $r2$ değerleri algoritma hiper parametrelerini $p_{en iyi}$ bir parçacığın o ana kadarki elde etmiş olduğu en iyi konumu $g_{en iyi}$ ise tüm parçacıklar arasında en iyi konumu ifade etmektedir. Formül 2'de ise p konum v hızı temsil etmektedir ve parçacıkların konumlarını güncellenmektedir. Formüllerde i parçacık numarasını t ise iterasyon numarasını temsil etmektedir. Bu çalışmada ESA için önerilmiş topluluk yönteminde her bir ESA'nın ağırlığını belirlemek için PSO algoritması kullanılmıştır. Üç adet ESA mimarisi seçildiği için problemin boyutu üç olarak belirlenmiştir. Her bir parçacık 0-1 arasında değişen w_1 , w_2 , w_3 değerlerinden oluşmaktadır. Toplamda 30 adet parçacık kullanılmıştır. Algoritma 30 iterasyon boyunca çalıştırılmış, w değeri 0.8, $r1$ ve $r2$ değeri [0-1] arasından rastgele seçilmiş, $c1$ ve $c2$ değerleri 0,5 olarak ayarlanmıştır. Algoritmada her bir parçacığın çözüme olan uygunluğu doğruluk, duyarlılık, kesinlik ve F1 skor değerlerinin ortalamasının bire olan oranı hesaplanmıştır. Bu sayede birden fazla ölçüt değerlendirme kriterine katılmış olası sınıf dengesizliklerinde bile algoritmanın doğru çalışması amaçlanmıştır. Uygunluk fonksiyonu formül 3'de verilmiştir.

$$Uygunluk = \frac{1}{\left(\frac{\text{Doğruluk} + \text{Duyarlılık} + \text{Kesinlik} + \text{F1 skor}}{4} \right)} \quad (3)$$

Ayrıca önerilen algoritmanın çalışma sistemine dair bir görsel şekil 4’te paylaşılmıştır. 30 iterasyon boyunca çalıştırılan algoritma ResNet-50V2, VGG-16, DenseNet-121 modelleri için sırası ile 0,2657, 0,46380, 0,1967 ağırlık değerlerini bulmuştur.



Şekil 4. PSO Algoritması Akış Şeması

2.5. Geliştirme ortamı ve hiper parametreler

Bu çalışmada gerçekleştirilen eğitimler ve testler Ubuntu işletim sisteminde, 32GB ram ve 1080Ti ekran kartına sahip bir bilgisayar üzerinde gerçekleştirilmiştir. ESA modellerinin eğitilmesinde Keras derin öğrenme kütüphanesinden faydalanılmıştır. Tüm modeller 32 yığın boyutunda (batch size) 30 iterasyon boyunca eğitilmiştir. Her bir modele girdi olarak 224x224x3 boyutunda göğüs radyografisi verilmiştir. Modellerin son katmanlarında sigmoid aktivasyon fonksiyonu kullanılmıştır. Hata fonksiyonu olarak binary cross entropy fonksiyonu, hatayı minimize etmek için ise Adam optimizasyon algoritması kullanılmıştır. Öğrenme katsayısı 0.001 olarak belirlenmiştir. Çalışmada ezberlemeyi önlemek için online veri çoğaltma ve erken durdurma yöntemlerinden faydalanılmıştır.

2.6 Değerlendirme kriterleri

Çalışmada önerilen yöntemin sınıflandırma performansını değerlendirmek için literatürde kabul görmüş sınıflandırma ölçütlerinden doğruluk, duyarlılık, kesinlik ve F1 skor kullanılmıştır. Bu ölçütleri hesaplamak için şekil 5’te görülen karmaşıklık matrisinden ve formüllerden faydalanılmıştır. Ölçütlerin hesaplamasında kullanılan doğru pozitif (DP) gerçekte kardiyomegali olup modelin de kardiyomegali dediği örnekleri doğru negatif gerçekte normal olup sisteminde normal dediği örnekleri, yanlış negatif (YN) gerçekte kardiyomegali olduğu halde sistemin normal dediği örnekleri, yanlış pozitif (YP) gerçekte normal olup sistemin kardiyomegali dediği örnekleri temsil etmektedir. Çalışmada normal görüntüler için 0 etiketi kardiyomegali görüntüler için ise 1 etiketi kullanılmıştır.

		Gerçek		
		Pozitif	Negatif	
Tahmin	Pozitif	Doğru Pozitif (DP)	Yanlış Pozitif (YP)	Kesinlik $\frac{DP}{(DP+YP)}$
	Negatif	Yanlış Negatif (YN)	Doğru Negatif (DN)	Doğruluk $\frac{DP+DN}{(DP+DN+YP+YN)}$
		Duyarlılık $\frac{DP}{(DP+DN)}$	F1 Score $2x \frac{(Kesinlik \times Duyarlılık)}{(Kesinlik+Duyarlılık)}$	

Şekil 5. Karmaşıklık Matrisi

3. Bulgular

Çalışmada on ESA modeli değerlendirilmiş, aralarında en başarılı üç model olan VGG-16, DenseNet-121 ve ResNet-50V2 önerilen ağırlıklandırılmış topluluk yöntemi için seçilmiştir. Seçilen modellerin bireysel olarak elde etmiş oldukları değerlendirme ölçütlerinin ortalaması alınarak elde edilen sınıflandırma performansları tablo 2’de verilmiştir.

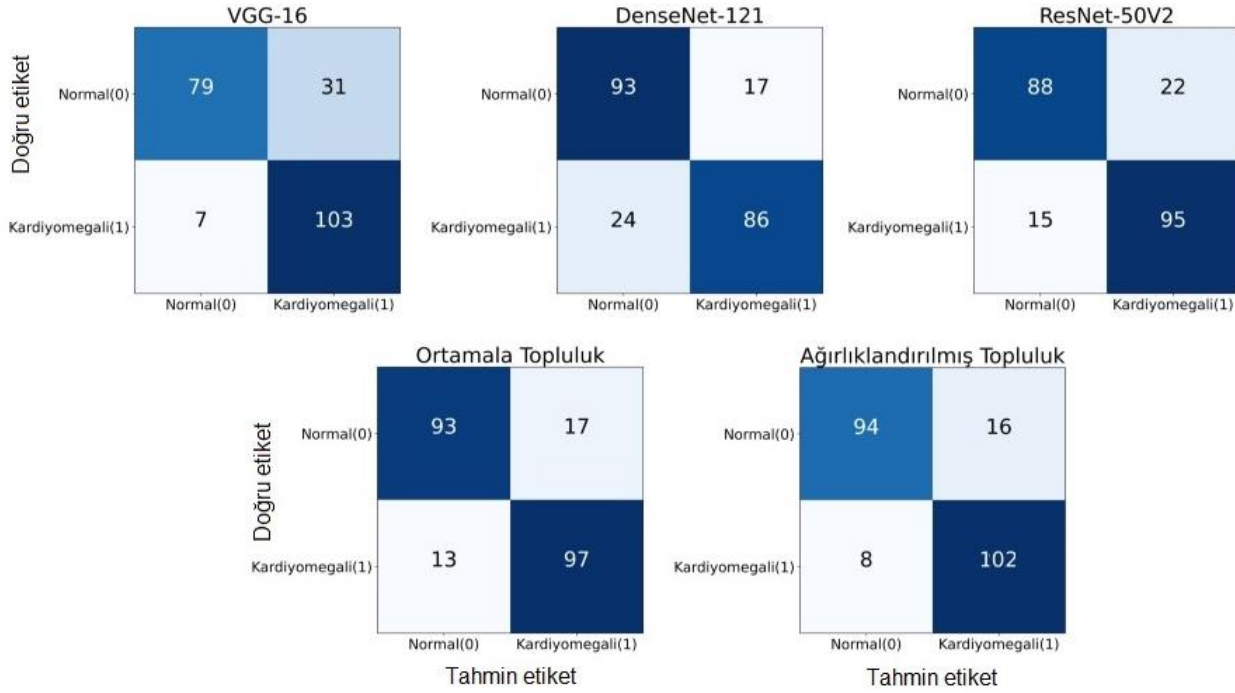
Tablo 2. Modellerin Ortalaması Alınmış Sınıflandırma Performansları (%)

Modeller	Doğruluk	Duyarlılık	Kesinlik	F1 Skor
VGG-16	82,73	82,73	84,36	82,52
DenseNet-121	81,36	81,36	81,49	81,34
ResNet-50V2	83,18	83,18	83,32	83,16
Ortalama Topluluk Yöntemi	86,36	86,36	86,41	86,36
Ağırlıklandırılmış Topluluk Yöntemi	89,09	89,09	89,30	89,08

Ayrıca modellerin sınıf bazında göstermiş oldukları sınıflandırma performansı Tablo 3’te yer almaktadır. Buna ek olarak modellerin elde etmiş olduğu karmaşıklık matrisleri şekil 6’da verilmiştir.

Tablo 3. Modellerin Sınıf Bazında Performansları (%)

Modeller	Sınıflar	Duyarlılık	Kesinlik	F1 Skor
VGG-16	Normal	71,82	91,86	80,61
	Kardiyomegali	93,64	76,87	84,43
DenseNet-121	Normal	84,55	79,49	81,94
	Kardiyomegali	78,18	83,50	80,75
ResNet-50V2	Normal	80	85,44	82,63
	Kardiyomegali	86,36	81,20	83,70
Ortalama	Normal	84,55	87,74	86,11
Topluluk Yöntemi	Kardiyomegali	88,18	85,09	86,61
Ağırlıklandırılmış	Normal	85,45	92,16	88,68
Topluluk Yöntemi	Kardiyomegali	92,73	86,44	89,47



Şekil 6. Karmaşıklık Matrisleri

4. Tartışma


Bu çalışmada farklı ESA mimarilerinin tahmin kabiliyetlerini birleştiren bir ağırlık tabanlı topluluk oylama yöntemi önerilmiştir. Bu bağlamda on farklı ESA modeli arasından seçilen üç ESA modeli PSO algoritması tarafından belirlenen ağırlıklar kullanılarak birleştirilmiş ve radyografik görüntüleri kardiyomegali ve normal olmak üzere sınıflandırmak için kullanılmıştır. Tablo 2 incelendiğinde önerilen yöntemin diğer bireysel modellerden ve ortalama topluluk yönteminden 89,09 doğruluk, 89,09 duyarlılık, 89,30 kesinlik ve 89,08 F1 skor değeri elde ederek daha başarılı olduğu görülmektedir. Çalışmada ağırlıklandırılmış topluluk yöntemi için seçilen üç ESA modelinin bireysel sınıflandırma performansları incelendiğinde ResNet-50V2 modelinin en başarılı model olduğu, sonrasında VGG-16 ve DenseNet-121 modelinin geldiği görülmektedir (Tablo 3). Modellerin sınıf bazında elde ettiği duyarlılık değerleri ve karmaşıklık matrisleri incelendiğinde VGG-16 modelinin kardiyomegali teşhisinde diğer iki modelden daha başarılı olduğu görülmektedir. Ancak modelin aynı zamanda normal görüntüleri tespit etme performansı ise düşüktür. Normal görüntülerde daha iyi sınıflandırma performansını ise DenseNet-121 modelinin elde ettiği görülmektedir. Herhangi bir ağırlıklandırma yapılmadan uygulanan ortalama topluluk yönteminin bireysel modellerden daha başarılı olduğu ancak ağırlıklandırılmış topluluk yönteminin en başarılı sonuçlar verdiği görülmektedir. Bunun yanında modellerin bireysel sınıflandırma başarıları en yüksekte düşüğe doğru ResNet-50V2, VGG-16, DenseNet-121 olmasına karşın PSO'nun bireysel için belirlediği ağırlıklar aynı sıra ile 0,2657, 0,4638, 0,1967'dir. Bu ağırlıklara bakıldığında ResNet-50V2 haricinde diğer modellere verilen ağırlık değerlerinin modellerin bireysel sınıflandırma performansı ile orantılı olduğu görülmektedir. Önerilen yöntemin performansını değerlendirmek adına makaledeki sonuçlar ile literatürde yapılmış çalışmaların karşılaştırması tablo 4'te verilmiştir.

Tablo 2. Önerilen Yöntemin Literatür ile Karşılaştırılması

Numara	Çalışma	Doğruluk	Duyarlılık	Kesinlik	F1 Skor
1	Innat vd. (2023)	85	85	87	86
2	Candemir vd. (2018)	88,24	92,58	-	88,73
3	Zhou vd. (2019)	86,36	93,90	-	85,08
4	Sogancioglu vd. (2020)	-	81	91	85
5	Bougias vd. (2021)	84,5	84	83	83,49
6	Ağırlıklandırılmış Topluluk Yöntemi	89,09	89,09	89,30	89,08

Tablo 4'te verilen çalışmalar incelendiğinde önerilen yöntemin doğruluk kriteri bakımında 1,2,3, ve 5 numaralı çalışmalardan daha iyi sonuçlar elde ettiği, duyarlılık bakımından,4, ve 5 numaralı çalışmalardan iyi olmasına karşın 2 ve 3 numaralı çalışmalardan geride olduğu, kesinlik bakımından 1 ve 5 numaralı daha iyi olduğu 4 numaralı çalışmanın ise gerisinde olduğu, F1 skorda ise tüm çalışmalardan daha iyi sonuçlar elde ettiği görülmüştür. Bu bağlamda önerilen yöntem umut verici performans göstermiştir. Öte yandan literatürde segmentasyon yaparak KO oranı ile kardiyomegali tespit eden daha başarılı çalışmalar olsa da bölütleme için veri hazırlamak zor ve zahmetli bir iştir. Çalışmanın limitasyonları arasında veri örnek sayısının azlığı gösterilebilir. Her ne kadar online veri çoğaltma yöntemleri kullanılsa da verinin çokluğu ve kalitesi sınıflandırma performansı üzerinde olumlu etkisi vardır. Şekil 7'de

modelin yanlış tahminde bulunduğu örnekler verilmiştir. Örnekler incelendiğinde olması gereken sınıftan ayrılmasının gerçekten zor olduğu örneklerin yer aldığı görülmektedir.



Şekil 7. (a) YP örnekler (b) YN örnekler

5. Sonuç

Bu çalışmada göğüs radyografilerinin normal ve kardiyomegali olarak sınıflandırılması için ağırlıklandırılmış ESA topluluğu yöntemi önerilmiştir. Çalışmada on farklı ESA modeli değerlendirilmiş sınıflandırma performansı en iyi olan üç model ağırlıklandırılmış topluluk yöntemi için seçilmiştir. Topluluktaki ESA modellerinin ağırlık değerleri ise PSO algoritması ile belirlenmiştir. Önerilen yöntem %89,09 doğruluk %89,09 duyarlılık, %89,30 kesinlik ve %89,08 F1 skor değerleri elde etmiştir. Elde edilen sonuçlara göre PSO tarafından bulunan ağırlıklar kullanılarak oluşturulan topluluk yöntemi, ağırlıksız topluluk yönteminden ve bireysel modellerden daha başarılı olmuştur. Önerilen yöntem kullanılarak klinik uygulamalarda hekimlere ikinci bir görüş sağlamak mümkün olacaktır. Gelecekteki çalışmalarda ağırlıkların belirlenmesinde farklı meta sezgisel algoritmaların etkisi üzerine bir çalışma yapılması planlanmaktadır.

Referanslar

- Abdelrahman, L., Al Ghamdi, M., Collado-Mesa, F., & Abdel-Mottaleb, M. (2021). Convolutional neural networks for breast cancer detection in mammography: A survey. *Computers in biology and medicine*, 131, 104248.
- Ayan, E., Erbay, H., & Varçın, F. (2020). Crop pest classification with a genetic algorithm-based weighted ensemble of deep convolutional neural networks. *Computers and Electronics in Agriculture*, 179, 105809.
- Bougias, H., Georgiadou, E., Malamateniou, C., & Stogiannos, N. (2021). Identifying cardiomegaly in chest X-rays: a cross-sectional study of evaluation and comparison between different transfer learning methods. *Acta Radiologica*, 62(12), 1601-1609.
- Boslama, A., Laaziz, Y., & Tali, A. (2020). Diagnosis and precise localization of cardiomegaly disease using U-NET. *Informatics in Medicine Unlocked*, 19, 100306.
- Candemir, S., & Antani, S. (2019). A review on lung boundary detection in chest X-rays. *International journal of computer assisted radiology and surgery*, 14, 563-576.
- Candemir, S., Rajaraman, S., Thoma, G., & Antani, S. (2018). Deep learning for grading cardiomegaly severity in chest x-rays: an investigation. Paper presented at the 2018 IEEE Life Sciences Conference (LSC).

- Chen, L., Mao, T., & Zhang, Q. (2022). Identifying cardiomegaly in chest x-rays using dual attention network. *Applied Intelligence*, 52(10), 11058-11067.
- Chollet, F. (2017). Xception: Deep learning with depthwise separable convolutions. Paper presented at the Proceedings of the IEEE conference on computer vision and pattern recognition.
- Dash, S., Shakyawar, S. K., Sharma, M., & Kaushik, S. (2019). Big data in healthcare: management, analysis and future prospects. *Journal of big data*, 6(1), 1-25.
- Eberhart, R., & Kennedy, J. (1995). Particle swarm optimization. Paper presented at the Proceedings of the IEEE international conference on neural networks.
- He, K., Zhang, X., Ren, S., & Sun, J. (2016). Deep residual learning for image recognition. Paper presented at the Proceedings of the IEEE conference on computer vision and pattern recognition.
- Huang, G., Liu, Z., Van Der Maaten, L., & Weinberger, K. Q. (2017). Densely connected convolutional networks. Paper presented at the Proceedings of the IEEE conference on computer vision and pattern recognition.
- Ilovar, M., & Šajin, L. (2011). Analysis of radiograph and detection of cardiomegaly. Paper presented at the 2011 Proceedings of the 34th International Convention MIPRO.
- Innat, M., Hossain, M. F., Mader, K., & Kouzani, A. Z. (2023). A convolutional attention mapping deep neural network for classification and localization of cardiomegaly on chest X-rays. *Scientific Reports*, 13(1), 6247.
- Ishida, T., Katsuragawa, S., Chida, K., MacMahon, H., & Doi, K. (2005). Computer-aided diagnosis for detection of cardiomegaly in digital chest radiographs. Paper presented at the Medical Imaging 2005: Image Processing.
- Jamroży, M., Leyko, T., & Lewenstein, K. (2010). Early detection of the cardiac insufficiency. In *Recent Advances in Mechatronics* (pp. 407-411): Springer.
- Krizhevsky, A., Sutskever, I., & Hinton, G. E. (2012). Imagenet classification with deep convolutional neural networks. *Advances in neural information processing systems*, 25.
- Li, Z., Liu, F., Yang, W., Peng, S., & Zhou, J. (2021). A survey of convolutional neural networks: analysis, applications, and prospects. *IEEE transactions on neural networks and learning systems*.
- Peng, T., Wang, Y., Xu, T. C., & Chen, X. (2019). Segmentation of lung in chest radiographs using hull and closed polygonal line method. *IEEE Access*, 7, 137794-137810.
- Qin, C., Yao, D., Shi, Y., & Song, Z. (2018). Computer-aided detection in chest radiography based on artificial intelligence: a survey. *Biomedical engineering online*, 17(1), 1-23.
- Que, Q., Tang, Z., Wang, R., Zeng, Z., Wang, J., Chua, M., . . . Veeravalli, B. (2018). CardioXNet: automated detection for cardiomegaly based on deep learning. Paper presented at the 2018 40th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC).
- Semsarian, C., Ingles, J., Maron, M. S., & Maron, B. J. (2015). New perspectives on the prevalence of hypertrophic cardiomyopathy. *Journal of the American College of Cardiology*, 65(12), 1249-1254.
- Simonyan, K., & Zisserman, A. (2014). Very deep convolutional networks for large-scale image recognition. arXiv preprint arXiv:1409.1556.
- Sogancioglu, E., Murphy, K., Calli, E., Scholten, E. T., Schalekamp, S., & Van Ginneken, B. (2020). Cardiomegaly detection on chest radiographs: Segmentation versus classification. *IEEE Access*, 8, 94631-94642.
- Summers RM. NIH Chest X-ray Dataset of 14 Cardiomegaly Disease Categories. <https://nihcc.app.box.com/v/ChestXray-NIHCC/file/220660789610>. Erişim Tarihi Eylül 2023
- Szegedy, C., Ioffe, S., Vanhoucke, V., & Alemi, A. (2017). Inception-v4, inception-resnet and the impact of residual connections on learning. Paper presented at the Proceedings of the AAAI conference on artificial intelligence.
- Torres-Robles, F., Rosales-Silva, A. J., Gallegos-Funes, F. J., & Bazán-Trujillo, I. (2014). A robust neuro-fuzzy classifier for the detection of cardiomegaly in digital chest radiographies. *Dyna*, 81(186), 35-41.
- 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. Paper presented at the Proceedings of the IEEE conference on computer vision and pattern recognition.

Wu, J.-X., Pai, C.-C., Kan, C.-D., Chen, P.-Y., Chen, W.-L., & Lin, C.-H. (2022). Chest X-ray image analysis with combining 2D and 1D convolutional neural network based classifier for rapid cardiomegaly screening. *IEEE Access*, 10, 47824-47836.

Zhou, S., Zhang, X., & Zhang, R. (2019). Identifying cardiomegaly in ChestX-ray8 using transfer learning. In *MEDINFO 2019: Health and Wellbeing e-Networks for All* (pp. 482-486): IOS Press.

Zoph, B., Vasudevan, V., Shlens, J., & Le, Q. V. (2018). Learning transferable architectures for scalable image recognition. Paper presented at the Proceedings of the IEEE conference on computer vision and pattern recognition.