

Ekokardiyografi Görüntülerinde Aort Kapak Kalsifikasyon Segmentasyonu için Veri Artırma Yöntemlerinin İrdelenmesi

Elif BAYKAL KABLAN^{1*} 

Öz

Aort kapak kalsiyum skoru, aort darlığı tanısında, tedavisinde, takibinde ve koroner arter hastalığı riskinin belirlenmesinde oldukça önemlidir. Güncel kılavuzlar, düşük akım ve düşük gradyanlı aort darlığı tanısında aort kapak kalsiyum skorlarının dikkate alınmasını önermektedir. Aort kapak kalsiyumunun ölçümünde altın standart yöntem bilgisayarlı tomografidir (BT). Agatston skoru, kalsiyum alanı ile BT dansitesinin çarpılmasıyla hesaplanan yarı otomatik bir yöntem olmakla birlikte BT pahalı ve radyasyon riski taşımaktadır. Alternatif olarak, ekokardiyografi, daha ucuz ve radyasyon içermeyen bir yöntem olup bu görüntüleme üzerinde yapılan çalışmalar gözleme dayalı ve yarı kantitatif olup, objektif sonuçlar vermekte zorlanmaktadır. Bu çalışmada, aort kapak kalsifikasyon ölçümü için gerekli olan kalsifikasyon bölgelerini belirlemek üzere derin öğrenme tabanlı U-Net modeli çeşitli veri artırma teknikleri ile değerlendirilmiştir. Bu amaçla yeni bir veri seti oluşturulmuş ve renk, rijid ve rijid olmayan geometrik dönüşümler gibi farklı artırma yöntemlerinin etkinliği analiz edilmiştir. Elde edilen sonuçlar değerlendirildiğinde, rijid olmayan geometrik dönüşümlerin segmentasyon performansını en anlamlı şekilde artırdığı gözlemlenmiştir.

Anahtar Kelimeler: Aort kapak, Kalsifikasyon, Kalsiyum skora, Ekokardiyografi, Veri artırma, Derin öğrenme, U-Net.

Analysis of Data Augmentation Methods for Aortic Valve Calcification Segmentation in Echocardiographic Images

Abstract

Aortic valve calcium scoring is crucial for diagnosing, treating, monitoring aortic stenosis, and assessing coronary artery disease risk. Current guidelines recommend incorporating aortic valve calcium scores in the diagnosis of low-flow and low-gradient aortic stenosis. The gold standard for measuring aortic valve calcium is computed tomography (CT). The Agatston score is a semi-automatic method for calculating calcium scores by multiplying the calcium area by CT density. However, CT is expensive and carries radiation risks. As an alternative, echocardiography, which is cheaper and radiation-free, has been explored. However, studies on echocardiography are observational and semi-quantitative, and they struggle to provide objective results. In this study, the deep learning-based U-Net model was evaluated for identifying calcification regions necessary for aortic valve calcification measurement using various data augmentation techniques. A new dataset was created for this purpose, and the effectiveness of different augmentation methods, including color adjustments, rigid transformations, and non-rigid geometric transformations, was analyzed. The results indicate that non-rigid geometric transformations significantly enhance segmentation performance.

Keywords: Aortic valve, Calcification, Calcium scoring, Echocardiography, Data augmentation, Deep learning, U-Net.

¹Karadeniz Teknik Üniversitesi, Mühendislik Fakültesi, Yazılım Mühendisliği Bölümü, Trabzon, Türkiye, ebaykal@ktu.edu.tr

*Sorumlu Yazar/Corresponding Author

Geliş/Received: 15.08.2024

Kabul/Accepted: 05.09.2024

Yayın/Published: 15.09.2024

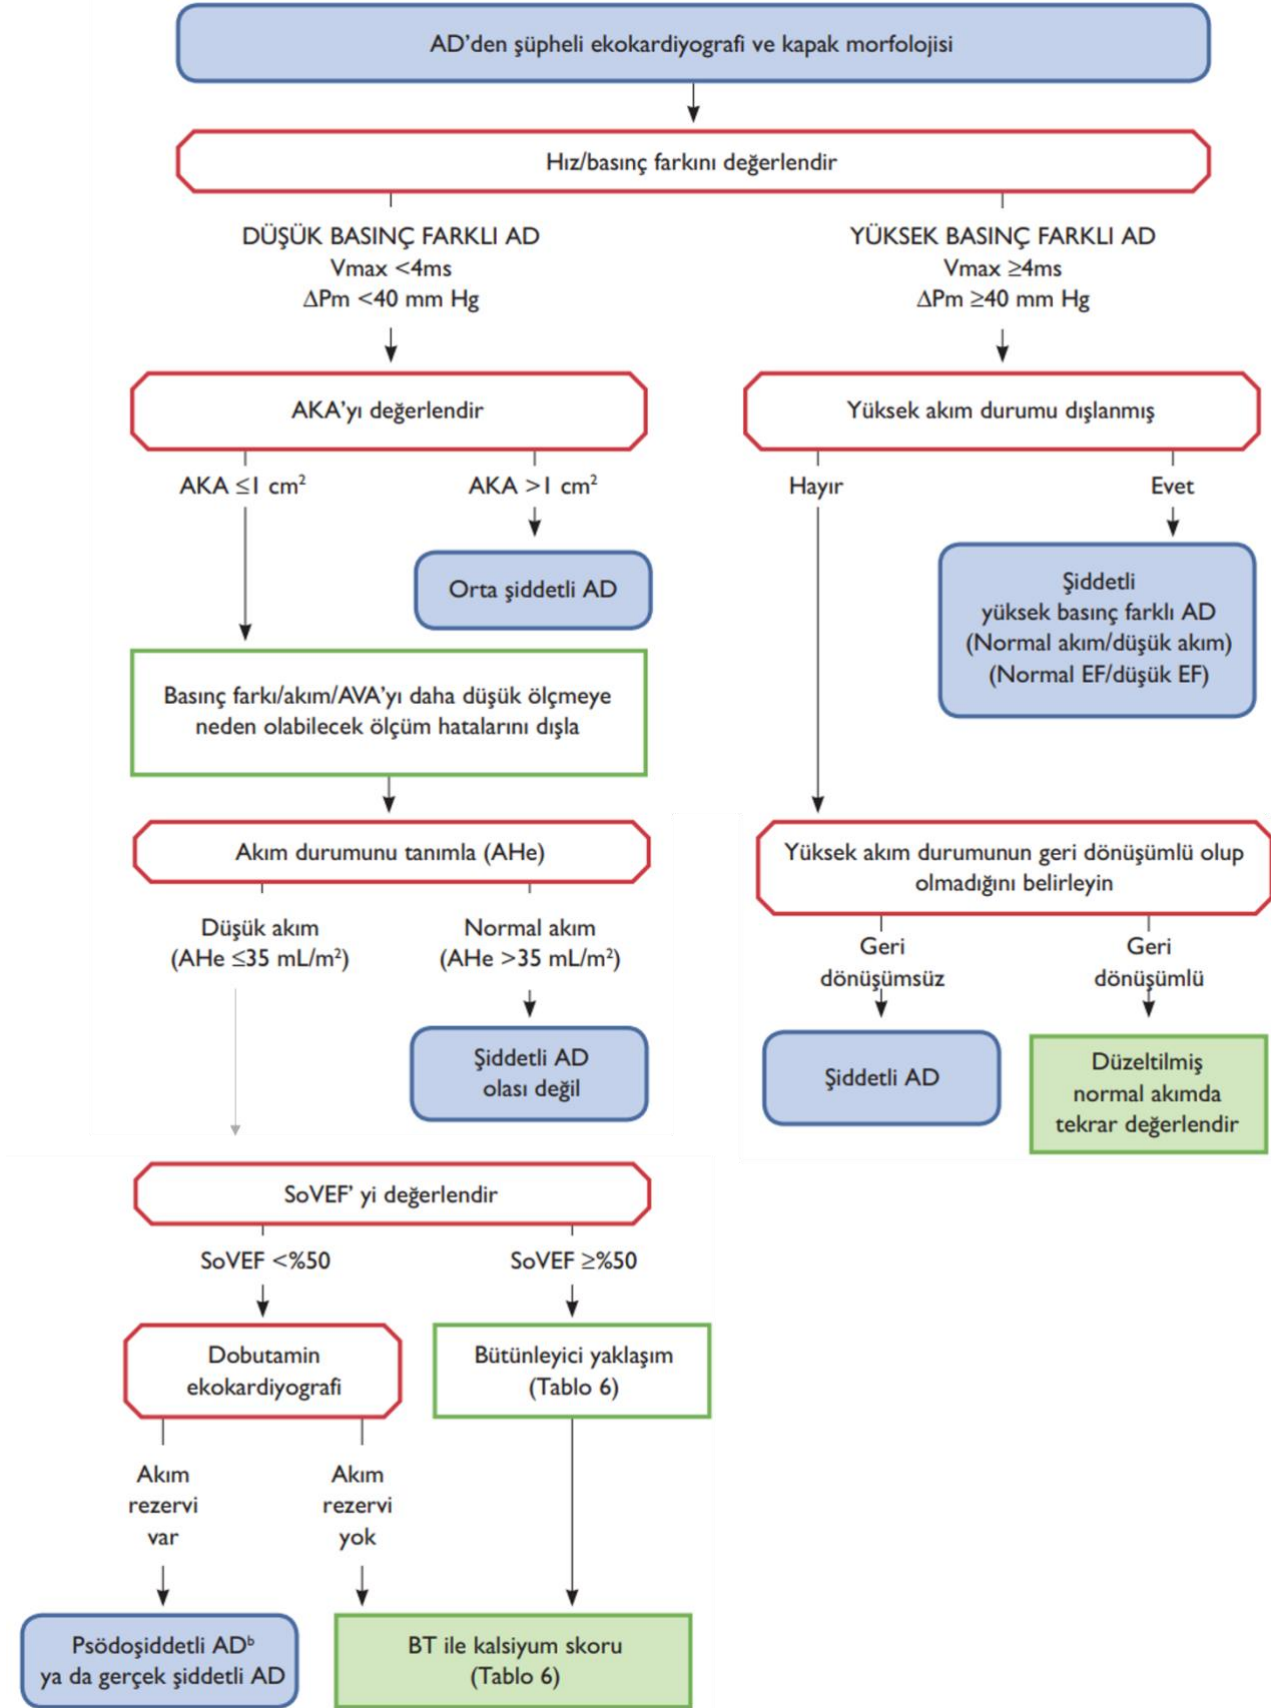
1. Giriş

Aort darlığı, gelişmiş ülkelerde, özellikle yaşlı nüfusta en sık karşılaşılan kalp kapak hastalığıdır (Lung, 2011; Osnabrugge, 2013). Aort darlığı tanısında ekokardiyografik inceleme ilk sıradadır. Ancak bazı hastalarda (yaklaşık %40 oranında) ekokardiyografik tanı da yetersiz olabilmektedir Clavel (2017). Özellikle düşük gradyanlı aort kapak hastalarında ek tanısal yöntemlere ihtiyaç duyulmaktadır. Kalsifikasyon aort darlığı gelişiminde en önemli faktördür. Kalsifikasyonun miktarı, yaygınlığı ve yoğunluğu aort kapak darlığı ciddiyeti (seviyesi) ile yakından ilişkilidir (Koos vd., 2004; Pawede vd., 2015). Ayrıca aort kapak kalsiyum skorunun olumsuz birçok klinik olayla da yakın ilişkili olduğu çeşitli çalışmalarda gösterilmiştir (Rosenhek vd., 2000; Pawede vd., 2018). Bu nedenle kardiyolojik tanı ve tedavide yol gösterici olarak yararlanılan kılavuzlar tarafından aort kapak kalsiyum skorunun değerlendirilmesi önerilmektedir Falk vd. (2017). Şekil 1’de Avrupa Kardiyoloji Derneği kılavuzlarının en güncel versiyonunda uygulanması önerilen iş-akış diyagramı verilmiştir. Aort kapak kalsiyum skoru ölçümünde altın standart yöntem olarak Şekil 1’de gösterildiği gibi bilgisayarlı tomografi (BT) görüntülemesi önerilmektedir.

BT görüntülemesi ile kalsiyum miktarının belirlenmesinde en sık kullanılan ölçüm yöntemi Agatston skorlamasıdır Agatston vd. (1990). Bu yöntem, kalsifiye plak alanı ile elde edilen en yüksek Hounsfield dansitesinin çarpımı sonucu kalsiyum skorlamasını vermektedir. Agatston skorlamasında, birbirine komşu 2–3 pikselde, 1 mm²’den geniş bir alanda, BT dansitesi 130 Hounsfield ünite (HU)’den fazla olan lezyonlar kalsifikasyon olarak yorumlanmaktadır. Uzman radyolog tarafından her bir kesitte segment edilen lezyonların alanı ve dansitesi cihaz yazılımı tarafından otomatik olarak ölçülmektedir. Ancak her bir kesitteki segmentasyon süreci fazla zaman kaybına neden olabilmektedir ve uzman tecrübesine ve becerisine göre sonuçların doğruluğu değişebilmektedir. Ayrıca, her bir BT kesitinde aort ilgi bölgesinin farklı şekil, boyut ve pozisyonunun (açık kapak-kapalı kapak) olması, elle segmentasyon işlemini daha da zorlaştırmaktadır. Lezyonların her biri için kalsiyum skoru saptanarak, o hasta için toplam kalsiyum skoru yarı-otomatik olarak hesaplanmaktadır. Bu ölçümde kısmi olarak operatör (uzman radyolog) deneyimi önem kazanmaktadır. Son yıllarda, BT’de operatör etkisini azaltmaya yönelik yalnızca BT görüntülerinin irdelenmesine dayalı aort kapak kalsiyum skorunun ölçülmesi ve sınıflandırması amacı ile birkaç çalışma yapılmıştır.

Önerilen çalışmalar genellikle derin öğrenme yöntemlerine dayansa da çoğu koroner arter kalsifikasyonlarının BT görüntülerinden ölçülmesi üzerine odaklanmaktadır (Wolterink vd., 2016; Lessmann vd., 2018; van Assen vd., 2021). Aort kapak kalsiyum skorunun derin öğrenme tabanlı tespiti ve nicelendirilmeleri üzerine yapılan çalışmaların sınırlı olması (Chang vd., 2021; Singh vd.,

2021), bu araştırma alanının literatürdeki yeniliğini göstermektedir. Ayrıca, aort darlığı tanısı için kalsifikasyon ölçümleri genellikle BT taramaları ile yapılmaktadır.



Şekil 1. Aort darlığı tanı ve tedavisinde yol gösterici kılavuz iş-akış diyagramı Esc vd. (2017). Bilgisayarlı tomografi ile kalsiyum skor ölçümünün önerildiği kısım kırmızı kesik oklar ile gösterilmiştir.

Ekokardiyografi görüntülerinden aort kalsiyum skorunu ölçmeye yönelik çeşitli çalışmalar yapılmıştır, ancak bu çalışmaların tümü gözleme dayalı ve yarı-kantitatif yöntemlere dayanmaktadır (Gaibazzi vd., 2014; Gaibazzi vd., 2015; Saha vd., 2015; Hardas vd., 2021). Elvas vd. (2021), bilgisayarlı görü kullanarak ekokardiyografi görüntülerinden kalsiyum piksellerinin tespit edilmesi ve nicelendirilmeleri için basit bir yöntem geliştirmiştir. Ekokardiyografi görüntülerindeki parlaklık farklılıklarından kaynaklanan değişkenliği gidermek için uyarlamalı görüntü ikiliği kullanılmıştır. İkiliğin ardından, ekokardiyograf, kalsiyum içeren ilgi alanını (ROI) etkileşimli olarak seçip çıkarmış ve kalsiyumun mekansal genişliğine karşılık gelen kalsiyum piksel sayısını hesaplamıştır. Ancak, bu sistem yalnızca yarı-otomatik kalsiyum tanımlamasını sağlamaktadır. Derin öğrenme, görüntü analizinde daha tutarlı ve objektif sonuçlar sağlayabilir ve ekokardiyografik tanıyı optimize etme potansiyeline sahiptir. Yapay zeka teknolojilerinin gelişmesiyle birlikte, sınıflandırma (Gao vd., 2017; Wegner vd., 2022), segmentasyon (Amer vd., 2021; Mortada vd., 2023) ve çeşitli hastalıkların tanısında derin öğrenme yöntemleri ile ultrason görüntülerinin birleştirildiği uygulamalar giderek artmaktadır. Ancak, derin öğrenme algoritmalarını otomatik kalsifikasyon ile aort darlığı tespiti için uygulayan sınırlı sayıda çalışma (Tang vd., 2024; Cakir vd., 2024) mevcuttur. Tang vd., (2024), 33 hastadan alınan 757 görüntü içeren bir veri seti oluşturmuş ve bunu %90 eğitim ve %10 test olarak böldükten sonra ekokardiyografi görüntülerinde aort darlığını tam otomatik olarak tanımlayabilen açıklanabilir derin öğrenme algoritmaları geliştirmişlerdir. Önce Faster R-CNN kullanarak aort kapak bölgesini tespit etmiş daha sonra ise U-Net ile yüksek ekojenik (kalsifik olmaya aday) bölgeleri segment etmişlerdir. Segmentasyon sonuçları (Dice skoru) doğrulama setinde 0.7488'e ulaşmıştır.

Bu bağlamda, ekokardiyografik değerlendirmenin sınırlamaları, tam otomatik ve kantitatif aort kapak görüntülerinin analizi için bilgisayar destekli derin öğrenme yaklaşımlarının geliştirilmesiyle potansiyel olarak aşılabilir. Tam otomatik derin öğrenme yöntemleri, kalsifikasyon bölgelerinin doğru ve objektif bir şekilde tespit edilmesini sağlayarak, mevcut yöntemlerin sınırlamalarını gidermede önemli bir adım olacaktır. Bu yöntemler tanı sürecinin doğruluğunu artıracak, uygulama kolaylığı sağlayacak ve BT'ye olan bağımlılığı azaltarak radyasyon maruziyetini ortadan kaldıracaktır.

Bu çalışmada, ekokardiyografi görüntülerinde aort kapak kalsifikasyon alanının tam otomatik segmentasyonu için tamamen konvolüsyonel sinir ağlarından biri olan U-Net (Ronneberger vd., 2015) mimarisinin çeşitli veri artırma teknikleriyle, özellikle renk değişimleri, rijid dönüşümler ve rijid olmayan geometrik dönüşümler gibi yöntemlerle karşılaştırmalı analizi gerçekleştirilmiştir. U-Net mimarisi 2015 yılında geliştirilmiş olup, tıbbi görüntü segmentasyonu alanında yüksek doğruluk oranları ve verimlilik sağlamasıyla tanınmaktadır (Ronneberger vd., 2015). U-Net'in özellikle sınırlı sayıda etiketli veri bulunan durumlarda başarılı sonuçlar vermesi, medikal görüntülerin düşük kontrast ve karmaşık yapısını etkili bir şekilde işleyebilmesi, bu mimariyi çalışmamız için ideal bir

seçim haline getirmiştir. Ayrıca, U-Net'in simetrik encoder-decoder yapısı, detaylı doku bilgilerini koruyarak segmentasyon performansını artırmaktadır (Ronneberger vd., 2015). U-Net'in bu güçlü yönleri, mimarinin hala güncel tıbbi görüntüleme uygulamalarında yaygın olarak kullanılmasına olanak tanımaktadır (Azad vd., 2024). Bu çalışma, kalsifikasyon alanı segmentasyonunu tamamen otomatik bir şekilde gerçekleştiren önceki çalışmadan (Cakir vd., 2024a) farklı olarak, veri artırma yöntemlerinin etkilerini detaylı bir şekilde incelemektedir. Ayrıca önerilen yöntem Tang vd., (2024) çalışmasından farklı olarak aort kapak bölgesini önceki çalışmamızda (Cakir vd., 2024b) önerdiğimiz gibi YOLOv5-x modelini kullanarak tespit etmektedir. YOLOv5'in, Faster R-CNN'e kıyasla daha hızlı ve verimli bir tek aşamalı model sunarak gerçek zamanlı nesne tespiti için daha uygun bir seçenek sağladığı bilinmektedir. Son olarak, kalsifikasyon alanı segmentasyonu için özel olarak geliştirilmiş yeni bir aort kapak kalsifikasyon veri seti oluşturulmuştur.


2. Materyal ve Metot

Önerilen sistemin iş akışı eğitim (eğitim ve validasyon) ve test olmak üzere iki aşamadan oluşmaktadır. Tüm deneyler, Intel(R) Core(TM) i9-11900K 3.50 GHz CPU ve NVIDIA GeForce RTX 3080 12GB GPU donanımlı bir bilgisayarda gerçekleştirilmiştir. Çalışmada oluşturulan aort kapak kalsifikasyon veri seti, önerilen U-Net modeli ve veri artırma yöntemleri ve performans değerlendirmesinde kullanılan ölçütler alt başlıklarda sunulmaktadır.


2.1. Aort Kapak Kalsifikasyon Veri Seti

Bu çalışmada, aort kapak kalsifikasyon alanı segmentasyonu için özgün bir veri seti oluşturulmuştur. Bu veri seti, Karadeniz Teknik Üniversitesi Tıp Fakültesi Kardiyoloji Anabilim Dalı'ndan 109 benzersiz hastadan alınmış 126 ekokardiyografi görüntüsünden oluşmaktadır. Görüntüler, uzman kardiyolog tarafından etiketleme işlemiyle oluşturulmuş karşılık gelen binary maskelerle birlikte sunulmuştur. Görüntüler, 1024x768 piksel boyutlarında JPG formatında kaydedilmiştir. Ekokardiyografi görüntülerini tüm hastalar arasında standart hale getirmek için, iki uzman kardiyolog parasternal kısa aks görüntüsünde tüm üç aort kapakçığının en net bir şekilde aynı anda görülebildiği bölgeyi belirlemiştir. Etiketleme işlemi, MATLAB 2022a Image Labeler aracı kullanılarak uzman kardiyologlar tarafından Şekil 2'deki gibi ekokardiyografi görüntülerindeki aort kapak kalsifikasyon sınırlarının çizilmesi ile gerçekleştirilmiştir. Etiketleme sonrasında, tutarlı etiketleme ile bölge maskeleri PNG formatında dosyalar halinde kaydedilmiştir; siyah arka planı ve beyaz önyüzü temsil etmektedir.

Veri seti iki alt kümeye ayrılmıştır: %80'i eğitim ve %20'si test için kullanılmaktadır. Eğitim seti içinde, %10'u doğrulama için ayrılmıştır ve geri kalanı eğitim için kullanılmaktadır. Optimal ağ mimarisi, doğrulama sırasında elde edilen doğruluk ve hata metriklerine dayanarak belirlenmiş ve test seti üzerinde değerlendirilmiştir. Veri kümesine ait örnek görüntüler ve karşılık gelen maske görüntüleri Şekil 3'te verilmiştir.



Şekil 2. Ekokardiyografi görüntülerinde aort kapak kalsifikasyon bölgelerinin etiketlenmesi



Şekil 3. Veri kümesine ait örnek görüntüler ve karşılık gelen maske görüntüleri

2.2. U-Net

Derin öğrenmeye dayalı yöntemlerden Konvolüsyonel Sinir Ağları (CNN), görüntü sınıflandırma problemlerindeki başarısıyla birlikte segmentasyon alanına da yönelmeye başlamıştır. 2014 yılında ilk olarak Tam Konvolüsyonel Ağ (Fully Convolutional Network, FCN) mimarisinin önerilmesiyle birlikte segmentasyon problemine etkili bir çözüm getirilmiştir. Daha sonra, segmentasyon için SegNet ve U-Net gibi birçok CNN varyasyonu geliştirilerek medikal alandaki

birçok probleme başarılı bir şekilde uygulanmıştır. U-Net modeli, simetrik bir "U" şeklinde yapılandırılmış olup, aşağı ve yukarı örnekleme yollarında eşit sayıda konvolüsyonel katman içerir.

Aşağı örnekleme yolu, görüntü özelliklerini giderek daha soyut ve küçük çözünürlükteki temsillere dönüştüren dört aşamalı bir konvolüsyonel ağdan oluşur. Her aşamada iki 3x3 konvolüsyon katmanı ve ardından bir 2x2 maksimum havuzlama katmanı bulunur. Bu yapı, özelliklerin derinlemesine öğrenilmesini sağlar. Yukarı örnekleme yolu, aşağı örnekleme yolundan elde edilen özellikleri tekrar yüksek çözünürlükteki çıktı haritalarına dönüştüren dört aşamalı bir konvolüsyonel ağ içerir. Her aşamada, 2x2 transpoze konvolüsyon (upsampling) ve ardından iki 3x3 konvolüsyon katmanı kullanılır. Ayrıca, yukarı örnekleme aşamalarında, ilgili aşağı örnekleme aşamasından gelen özelliklerle birleşme (concatenation) yapılır, bu da yerel detayların korunmasını sağlar. Model, son aşamada 1x1 konvolüsyon katmanı kullanarak her piksel için sınıf olasılıklarını tahmin eder. Sigmoid aktivasyon fonksiyonu kullanılarak sonuçların $[0,1]$ aralığında olmasını sağlar.

Orijinal U-Net modelinde, aşağı örnekleme yolunda 64 özellik kanalı ile başlayan model, bu çalışmada 32 kanala düşürülmüştür. Ayrıca, konvolüsyonel katmanlarda maksimum özellik kanalı sayısı 1024'ten 512'ye azaltılmıştır. U-Net model mimarisi Şekil 4'te verilmiştir.



Şekil 4. U-Net model mimarisi

2.3. Veri Artırma Yöntemleri

Ultrason çekimi sırasında, sonografinin hastanın cildine uyguladığı baskı, transdüserin (ultrason probu) vücutla temasını etkiler ve bu da sinyalin kalitesini etkileyebilir. Çekim sırasında aşağıdaki değişkenler ortaya çıkabilir:

1. **Basınç Değişiklikleri:** Sonografin uyguladığı basınç, transdüserin ciltle temasını etkiler ve sinyalin gücünü değiştirebilir. Bu, görüntü kalitesinde farklılıklara yol açar. Yüksek basınç, daha net görüntüler sağlayabilirken, düşük basınç sinyalin zayıflamasına neden olabilir.

2. **Sinyal Gücü ve Kalitesi:** Ultrason sinyalinin gücü, uygulanan basınca bağlı olarak değişir. Basınç artışı, sinyalin güçlenmesini ve dolayısıyla görüntü kalitesinin artmasını sağlar, ancak aşırı basınç görüntüde distorsiyona yol açabilir.
3. **Açısal Değişiklikler:** Ultrason probunun cilt üzerinde farklı açılardan uygulanması, görüntülerin farklı yönlerden elde edilmesine neden olabilir. Bu, aynı anatomik yapının çeşitli açılardan görüntülenmesini sağlar ve görüntü kalitesinde farklılık yaratabilir.
4. **Cilt Üzerindeki Kayma:** Probu cilt üzerinde kayması, görüntüde bulanıklığa neden olabilir. Probu sabit tutulması önemlidir, aksi halde hareketler veya kaymalar görüntüde bozulmalara yol açabilir.
5. **Dokuların Elastik Özellikleri:** Ultrason, yumuşak dokuları görüntülerken bu dokuların elastik özelliklerinden etkilenir. Dokuların sıkışması veya genişlemesi, görüntüde değişiklikler yaratır ve bu da görüntü analizini zorlaştırabilir.

Bu faktörler, ultrason görüntülerinde doğal değişkenliklere neden olabilir ve derin öğrenme modelinin bu varyasyonları öğrenmesi ve genellemesi için veri artırma tekniklerinin uygulanması gereklidir. Veri artırma, derin öğrenme modelini eğitmek için kullanılan veri kümesinde yetersiz sayıda görüntü olduğunda veri kümesinin boyutunu artırmak için kullanılan ve yöntem performansında önemli iyileştirmeler sağlayan bir tekniktir. Ancak, hangi dönüşümün hangi veri kümesi için daha uygun olduğunu belirlemek genellikle zor olabilir. Bu çalışmada, üç temel veri artırma yöntemine odaklanmaktadır: renk dönüşümleri, rijid ve rijid olmayan geometrik dönüşümler.

Renk dönüşümleri, parlaklık, kontrast ve jitter gibi işlemler, tarama özelliklerini etkileyebilecek farklı ultrason görüntüleme koşullarını simüle etmektedir. Örneğin, bir sonografinin hastanın cildine uyguladığı basınç değişiklikleri, transdüserin ciltle temasını ve dolayısıyla sinyalin gücünü de etkiler.

Geometrik rijid dönüşümler, döndürme, çevirme ve kaydırma gibi işlemler, sonografinin belirli bir anatomi yapısını görüntülemek için uzman kişinin probu hastanın vücuduna farklı açılardan yerleştirebileceği veya vücut üzerinde kayması farklı görüntü görünümünü temsil eder.

Rijid olmayan dönüşümler, elastik dönüşüm ve ızgara distorsiyonu gibi yöntemler kullanılarak iç yapıların şekli ve göreceli konumu değiştirilir. Ultrason görüntüleme genellikle yumuşak dokuları görüntülemek için kullanıldığından, bu dokular rijid olmayan yapılar olup sıkışma, genişleme ve elastik hareket etme özellikleri taşır. Bu çalışmada, farklı artırma yöntemlerini uygulamak için Albumentations kütüphanesi (Buslaev vd., 2020), derin öğrenme modellerini oluşturmak ve test etmek için ise Pytorch (Paszke vd., 2019) kullanılmıştır.

2.4. Performans Değerlendirme Ölçütleri

Bu çalışmada, aort kapak kalsifikasyon alanının segmentasyonunda model performansını değerlendirmek için Dice skoru, Kesinlik ve Duyarlılık ölçütleri kullanılmıştır. Dice skoru, segmentasyon sonuçlarının doğruluğunu ölçmek için kullanılan bir benzerlik katsayısıdır ve genellikle iki set arasındaki örtüşme oranını ifade eder; bu sayede modelin hedef bölgeyi ne kadar doğru bir şekilde tespit ettiğini gösterir. Kesinlik, modelin pozitif olarak sınıflandırdığı piksellerin gerçek pozitif piksellerle olan oranını ölçer, yani modelin ne kadar doğru tahmin yaptığını değerlendirir. Duyarlılık ise, gerçek pozitif piksellerin ne kadarının model tarafından doğru bir şekilde tespit edildiğini gösterir, yani modelin kaçırdığı pozitif pikselleri belirler. Bu üç ölçüt, segmentasyon modelinin hem doğruluğunu hem de hassasiyetini kapsamlı bir şekilde değerlendirmek için bir arada kullanılarak model performansının objektif bir şekilde analiz edilmesini sağlar. Bu ölçütler (1-3) eşitlikleri kullanılarak hesaplanmaktadır. Eşitliklerde DP, DN, YP ve YN sırasıyla, doğru pozitif, doğru negatif, yanlış pozitif ve yanlış negatif sayısını ifade etmektedir.

$$Dice\ skoru = \frac{2 \times TP}{2 \times TP + FP + FN} \quad (1)$$

$$Kesinlik = \frac{TP}{TP + FP} \quad (2)$$

$$Duyarlılık = \frac{TP}{TP + FN} \quad (3)$$

3. Bulgular ve Tartışma

Bu uygulamada, tüm modellerin optimizasyonu için ADAM yöntemi kullanılmıştır ve ağırlık bozulma parametresinin değeri 0.0001 olarak ayarlanmıştır. Kayıp değerini belirlemek için modelin çıktısına sigmoid fonksiyonu uygulanmış ve ardından focal kayıp fonksiyonu kullanılmıştır. Focal kayıp fonksiyonu, sınıflar arasındaki dengesizliği ele almak için geliştirilmiş bir kayıp fonksiyonudur ve özellikle zor örnekleri daha iyi öğrenmeye yardımcı olur. Bu, segmentasyon sonuçlarının iyileştirilmesine katkı sağlar, çünkü nadir veya zor sınıflar üzerinde daha fazla odaklanır ve genel performansı artırır.


U-Net modelinin kodlayıcı katman mimarisi, veri setinin boyutları ve özellikleriyle uyumlu olacak şekilde $16 \rightarrow 32 \rightarrow 64 \rightarrow 128 \rightarrow 256 \rightarrow 512$ olarak belirlenmiş ve decoder katmanları modele göre ayarlanmıştır. Eğitim süreci modelde aşırı uyum olmaması amacıyla 100 epoch olarak

belirlenmiştir. Veri artırma uygulanmadan önce elde edilen sonuçlar (U-Net) ile renk (aug1), rijid (aug2) ve rijid olmayan (aug3) veri artırma yöntemleri kullanılarak elde edilen sonuçların karşılaştırmalı analizi Tablo 1'de sunulmuştur. Tablo incelendiğinde, tüm veri artırma yöntemlerinin U-Net modelinin performansını iyileştirdiği görülmektedir. Özellikle, rijid-olmayan veri artırma yöntemi (aug3), modelin performansını Dice skoru açısından %4, kesinlik açısından %2 ve duyarlılık açısından %4 oranında en yüksek iyileştirmeyi sağlamıştır. Bu sonuç, rijid-olmayan veri artırma yöntemlerinin, aort kapak kalsifikasyon segmentasyonunda diğer veri artırma tekniklerine göre daha etkili olduğunu göstermektedir.

Tablo 1. U-Net modelinin veri artırma uygulanmadan önce ve renk, rijid ve rijid olmayan veri artırma yöntemleri uygulandıktan sonra elde edilen performans sonuçlarının karşılaştırmalı analizi.

Metrik	U-Net	U-Net + aug1	U-Net + aug2	U-Net + aug3
Dice skoru	0.73	0.75	0.75	0.77
Kesinlik	0.72	0.72	0.74	0.74
Duyarlılık	0.78	0.80	0.80	0.82

Ayrıca, segmentasyon sonuçlarının görsel incelenmesi, U-Net + aug3 modelinin etkinliğini daha da doğrulamaktadır. Şekil 5'te gösterildiği gibi, elde edilen segmentasyon sonuçları kesin referans maske görüntülerine çok yakın bir uyum göstermektedir. Bu, modelin aort kapak kalsifikasyon bölgelerini hassas bir şekilde belirleme yeteneğini vurgulamakla birlikte semantik segmentasyon görevlerinde etkinliğini ortaya koyar. Bu araştırma, tıbbi görüntüleme alanında önemli bir ilerlemeyi temsil ederek kardiyologlara aort kapak kalsifikasyonlarının otomatik ve doğru değerlendirilmesi için güvenilir bir araç sunmaktadır.



Şekil 5. Soldan sağa: Orijinal giriş görüntüsü, kesin referans maske görüntüsü ve U-Net + aug3 ile model eğitimi sonrası üretilen tahmin maskesi

4. Sonuçlar ve Öneriler

Bu çalışmada, ekokardiyografi görüntülerinde aort kapak kalsifikasyon alanının tam otomatik segmentasyonu için U-Net modelinin performansı çeşitli veri artırma teknikleriyle değerlendirilmiştir. Elde edilen sonuçlar, U-Net modelinin aort kapak kalsifikasyon bölgelerini belirlemede yüksek doğruluk ve hassasiyet sağladığını göstermektedir. Modelin performansı, Dice skoru, kesinlik ve duyarlılık metrikleri kullanılarak değerlendirilmiştir. Veri artırma tekniklerinin uygulanması, modelin genel performansını olumlu yönde etkilemiştir. Üç farklı veri artırma yöntemi (renk/değişimleri, rijid geometrik dönüşümler ve rijid olmayan dönüşümler) karşılaştırıldığında, rijid olmayan dönüşümlerin segmentasyon performansını en fazla iyileştirdiği gözlemlenmiştir. Özellikle, rijid olmayan dönüşümler kullanılarak Dice skoru %4, kesinlik skoru %2 ve duyarlılık skoru %4 oranında iyileştirilmiştir. Görsel analizler, U-Net + aug3 modelinin aort kapak kalsifikasyon alanlarını başarılı bir şekilde belirlediğini ortaya koymuştur. U-Net'in segmentasyon sonuçları, kesin referans maskeleri ile yüksek uyum göstermiştir, bu da modelin segmentasyon görevlerindeki etkinliğini vurgulamaktadır.

Bu çalışmanın belirli kısıtları vardır. İlk olarak, çalışma sadece sınırlı bir veri seti üzerinde test edilmiştir, bu da sonuçların genelleştirilebilirliğini kısıtlamaktadır. Ayrıca, modelin performansı

yalnızca belirli veri artırma teknikleri ile değerlendirilmiş olup, diğer veri artırma ve düzenleme yöntemlerinin etkisi bu çalışmada ele alınmamıştır. Bunun yanı sıra, modelin klinik uygulamalara entegrasyonu henüz test edilmemiştir, bu da çalışmanın sonuçlarının gerçek dünya uygulamalarında ne kadar etkili olacağını belirsiz kılmaktadır. Bu limitler, çalışmanın gelecekteki araştırmalarda daha kapsamlı bir şekilde ele alınması gerektiğini ortaya koymaktadır.

Gelecek çalışmalarda U-Net modelinin performansını daha da artırmak için, daha derin ağ yapıları ve hibrit model yaklaşımları değerlendirilebilir. Özellikle, dikkat mekanizmalarının entegrasyonu, modelin segmentasyon yeteneklerini geliştirebilir. Rijid olmayan dönüşümler, bu çalışmada en iyi performansı sağladığından, bu tür tekniklerin daha geniş bir veri setinde ve farklı medikal görüntüleme uygulamalarında test edilmesi önerilmektedir. Ayrıca, kombinasyon teknikleri (örneğin, rijid ve rijid olmayan dönüşümlerin birleşimi) ile elde edilecek sonuçların araştırılması faydalı olabilir.

Son olarak elde edilen sonuçların klinik uygulamalarla entegre edilmesi, kardiyologlara aort kapak kalsifikasyonlarını daha hızlı ve doğru bir şekilde değerlendirme imkanı sunabilir. Makine öğrenimi ve derin öğrenme tabanlı sistemlerin klinik pratiğe entegrasyonu, teşhis süreçlerini iyileştirebilir ve hastaların tedavi süreçlerine katkıda bulunabilir.

Bu çalışma, aort kapak kalsifikasyonlarının otomatik segmentasyonu konusunda önemli bir ilerleme kaydetmiş olup, gelecekteki araştırmalara temel oluşturabilecek niteliktedir.

Teşekkür

Bu araştırma, Türkiye Bilimsel ve Teknolojik Araştırma Kurumu (TÜBİTAK) tarafından 222S110 proje numarası altında desteklenerek yürütülmüştür. KTÜ Farabi Hastanesi'nden (2022/190 nolu) etik kurul onayı alınmıştır.

Yazarların Katkısı

E. Baykal Kablan çalışmanın tamamından sorumludur.

Çıkar Çatışması Beyanı

Yazarlar arasında herhangi bir çıkar çatışması bulunmamaktadır.

Araştırma ve Yayın Etiği Beyanı

Yapılan çalışmada araştırma ve yayın etiğine uyulmuştur.

Kaynaklar

- Agatston, A. S., Janowitz, W. R., Hildner, F. J., Zusmer, N. R., Viamonte, M., & Detrano, R. 1990. "Quantification of coronary artery calcium using ultrafast computed tomography", *Journal of the American College of Cardiology*, 15(4), 827-832.
- Amer, A., Ye, X., & Janan, F. (2021). ResDUNet: A deep learning-based left ventricle segmentation method for echocardiography. *IEEE Access*, 9, 159755-159763.
- Azad, R., Aghdam, E. K., Rauland, A., Jia, Y., Avval, A. H., Bozorgpour, A., ... & Merhof, D. (2024). Medical image segmentation review: The success of u-net. *IEEE Transactions on Pattern Analysis and Machine Intelligence*.
- Buslaev, A., Igloukov, V. I., Khvedchenya, E., Parinov, A., Druzhinin, M., & Kalinin, A. A. (2020). Alumentations: fast and flexible image augmentations. *Information*, 11(2), 125.
- Cakir, M., Ekinci, M., Kablan, E. B., & Sahin, M. (2024, July). Automated Aortic Valve Calcific Area Segmentation in Echocardiography Images Using Fully Convolutional Neural Networks. In *2024 47th International Conference on Telecommunications and Signal Processing (TSP)* (pp. 96-100). IEEE.
- Cakir, M., Ekinci, M., Kablan, E. B., & Şahin, M. (2024). AVD-YOLOv5: a new lightweight network architecture for high-speed aortic valve detection from a new and large echocardiography dataset. *Medical & Biological Engineering & Computing*, 1-18.
- Chang S, Kim H, Suh YJ, Choi DM, Kim H, Kim DK, Kim JY, Yoo JY, Choi BW. 2021. "Development of a deep learning-based algorithm for the automatic detection and quantification of aortic valve calcium", *Eur J Radiol*. 137:109582.
- Clavel, M. A. 2017. "Cardiac imaging for assessing low-gradient severe aortic stenosis", *JACC Cardiovascular Imaging*, 10(2), 185-202.
- Elvas, L. B., Almeida, A. G., Rosario, L., Dias, M. S., & Ferreira, J. C. (2021). Calcium identification and scoring based on echocardiography. An exploratory study on aortic valve stenosis. *Journal of Personalized Medicine*, 11(7), 598.
- ESC, A. K. D., & Kardiyotorasik, A. 2017. "ESC/EACTS Kalp Kapak Hastalıkları Tedavi Kılavuzu".
- Falk, V., Baumgartner, H., Bax, J. J., De Bonis, M., Hamm, C., Holm, P. J., ... & Zamorano, J. L. 2017. "2017 ESC/EACTS Guidelines for the management of valvular heart disease", *European Journal of Cardio-Thoracic Surgery*, 52(4), 616-664.
- Gaibazzi, N., Baldari, C., Faggiano, P., Albertini, L., Faden, G., Pigazzani, F., ... & Reverberi, C. (2014). Cardiac calcium score on 2D echo: correlations with cardiac and coronary calcium at multi-detector computed tomography. *Cardiovascular ultrasound*, 12, 1-9.
- Gaibazzi, N., Porter, T. R., Agricola, E., Cioffi, G., Mazzone, C., Lorenzoni, V., ... & Faggiano, P. (2015). Prognostic value of echocardiographic calcium score in patients with a clinical indication for stress echocardiography. *JACC: Cardiovascular Imaging*, 8(4), 389-396.
- Gao, X., Li, W., Loomes, M., & Wang, L. (2017). A fused deep learning architecture for viewpoint classification of echocardiography. *Information Fusion*, 36, 103-113.
- Hardas, S., Titar, P., Zanzwar, I., & Phalgune, D. S. (2021). Correlation between echocardiographic calcium score and coronary artery lesion severity on invasive coronary angiography. *Indian Heart Journal*, 73(3), 307-312.
- Koos, R., Mahnken, A. H., Sinha, A. M., Wildberger, J. E., Hoffmann, R., & Köhl, H. P. 2004. "Aortic valve calcification as a marker for aortic stenosis severity: assessment on 16-MDCT", *American Journal of Roentgenology*, 183(6), 1813-1818.
- Lessmann, N., van Ginneken, B., Zreik, M., de Jong, P. A., de Vos, B. D., Viergever, M. A., & Išgum, I. 2017. "Automatic calcium scoring in low-dose chest CT using deep neural networks with dilated convolutions", *IEEE transactions on medical imaging*, 37(2), 615-625.
- Lung, B. 2011. "Epidemiology of valvular heart disease in the adult", *Nature Reviews Cardiology*, 8(3), 162-172.

- Mortada, M. J., Tomassini, S., Anbar, H., Morettini, M., Burattini, L., & Sbrollini, A. (2023). Segmentation of anatomical structures of the left heart from echocardiographic images using Deep Learning. *Diagnostics*, 13(10), 1683.
- Osnabrugge, R. L. 2013. "Aortic stenosis in the elderly: disease prevalence and number of candidates for transcatheter aortic valve replacement: a meta-analysis and modeling study", *Journal of the American College of Cardiology*, 62(11), 1002-1012.
- Paszke, A., Gross, S., Massa, F., Lerer, A., Bradbury, J., Chanan, G., ... & Chintala, S. (2019). Pytorch: An imperative style, high-performance deep learning library. *Advances in neural information processing systems*, 32.
- Pawade, T., Clavel, M. A., Tribouilloy, C., Dreyfus, J., Mathieu, T., Tastet, L., ... & Dweck, M. R. 2018. "Computed tomography aortic valve calcium scoring in patients with aortic stenosis", *Circulation: Cardiovascular Imaging*, 11(3), e007146.
- Saha, S. A., Beatty, A. L., Mishra, R. K., Whooley, M. A., & Schiller, N. B. (2015). Usefulness of an echocardiographic composite cardiac calcium score to predict death in patients with stable coronary artery disease (from the Heart and Soul Study). *The American journal of cardiology*, 116(1), 50-58.
- Singh, G., Al'Aref, S. J., Lee, B. C., Lee, J. K., Tan, S. Y., Lin, F. Y., ... & Credence And Iconic Investigators. 2021. "End-to-end, pixel-wise vessel-specific coronary and aortic calcium detection and scoring using deep learning", *Diagnostics*, 11(2), 215.
- Tang, L., Wang, X., Yang, J., Wang, Y., Qu, M., & Li, H. (2024). DLFFNet: A new dynamical local feature fusion network for automatic aortic valve calcification recognition using echocardiography. *Computer Methods and Programs in Biomedicine*, 243, 107882.
- van Assen, M., Martin, S. S., Varga-Szemes, A., Rapaka, S., Cimen, S., Sharma, P., ... & Schoepf, U. J. 2021. "Automatic coronary calcium scoring in chest CT using a deep neural network in direct comparison with non-contrast cardiac CT: A validation study", *European Journal of Radiology*, 134, 109428.
- Wegner, F. K., Benesch Vidal, M. L., Niehues, P., Willy, K., Radke, R. M., Garthe, P. D., ... & Orwat, S. (2022). Accuracy of deep learning echocardiographic view classification in patients with congenital or structural heart disease: importance of specific datasets. *Journal of Clinical Medicine*, 11(3), 690.
- Wolterink, J. M., Dinkla, A. M., Savenije, M. H., Seevinck, P. R., van den Berg, C. A., & Išgum, I. (2017, September). Deep MR to CT synthesis using unpaired data. In *International workshop on simulation and synthesis in medical imaging* (pp. 14-23). Springer, Cham.