



Usability analysis of developmental hip dysplasia ultrasound images with a two-stage deep learning approach

M. Cihad Özdemir^{1*}, Sadettin Çiftçi², Bahattin Kerem Aydın², Murat Ceylan³

¹Konel Elektronik AŞ, Fevziçakmak Neighborhood Hüdayi Street Kottim OSB, 42050 Karatay, Konya, Türkiye

²Department of Orthopedics and Traumatology, Faculty of Medicine, Selcuk University, Alaeddin Keykubat Campus, Konya, 42100, Türkiye

³Department of Electrical and Electronics Engineering, Faculty of Engineering and Natural Sciences, Konya Technical University, Konya, Türkiye

Highlights:

- Determination of analyzability of developmental hip dysplasia US images
- Semantic segmentation with U-NET architecture
- Sample segmentation with masked region-based convolutional neural network

Keywords:

- Deep learning
- Developmental hip dysplasia
- Convolutional neural networks
- Masked region-based convolutional neural network

Article Info:

Research Article

Received: 26.06.2023

Accepted: 26.11.2023

DOI:

10.17341/gazimmfd.1318983

Correspondence:

Author: Muhammed Cihad Özdemir

Özdemir

e-mail: ozdemircihad@gmail.com

phone: +90 507 211 5949

Graphical/Tabular Abstract

Figure A shows the flow diagram of the proposed system. In the proposed system, the Ultrasound (US) image is subjected to a two-stage segmentation process to determine its analyzability.

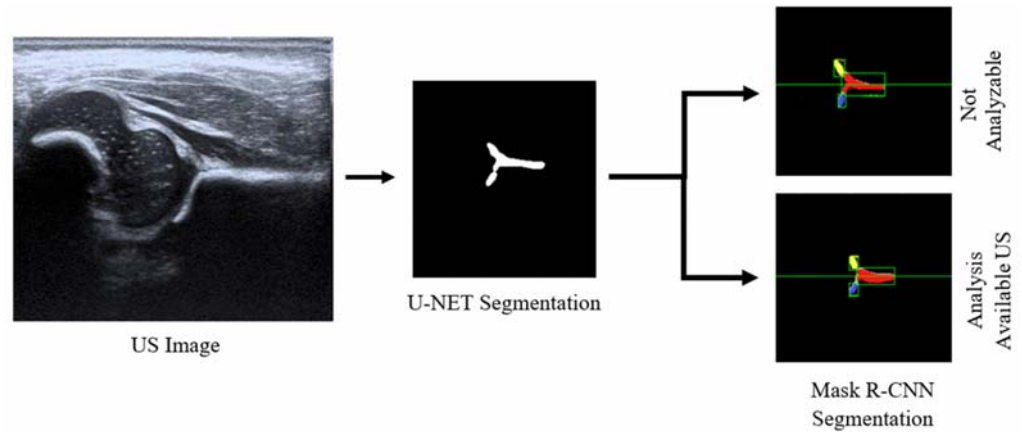


Figure A. Operation of the system

Purpose:

The aim of this study is to determine the analyzability of neonatal ultrasound images using artificial intelligence algorithms. It is aimed to prevent experts from wasting time with unanalyzable US images.

Theory and Methods:

The research proposes a two-stage artificial intelligence system for the analysis of hip ultrasound images. In the first stage, the anatomical structures to be detected are determined by semantic segmentation using U-NET architecture, and in the second stage, the boundaries of the segmented regions are determined using Mask R-CNN and the parallelism of the ilium to the baseline is checked. The proposed system is tested on real US images.

Results:

The 2-stage artificial intelligence system analyzed a total of 840 hip US images. It determined the analyzability of the hip US image with 96% accuracy. It is aimed to eliminate the possibility of physicians wasting time with unanalyzable US images and making a wrong diagnosis.

Conclusion:

Early diagnosis of developmental dysplasia of the hip is very important. If diagnosis is delayed, treatment becomes more difficult. The proposed system aims to reduce inter-observer variability in developmental hip dysplasia and will be a useful tool for inexperienced physicians. In this thesis, a two-stage artificial intelligence model was developed to determine the analyzability of hip US images taken for the detection of developmental hip dysplasia. The performance of the system shows that it can also be used for real-time applications.



Gelişimsel kalça displazisi ultrason görüntülerinin iki aşamalı derin öğrenme yaklaşımı ile kullanılabilirlik analizinin yapılması

M. Cihad Özdemir^{1*}, Sadettin Çiftçi², Bahattin Kerem Aydın², Murat Ceylan³

¹Konel Elektronik AŞ, Fevziçakmak Mah. Hüdayi Caddesi Kottim OSB, 42050 Karatay, Konya, Türkiye

²Selçuk Üniversitesi, Tıp Fakültesi, Alaeddin Keykubat Kampüsü, Ortopedi ve Travmatoloji Anabilim Dalı, Konya, 42100, Türkiye

³Konya Teknik Üniversitesi, Mühendislik ve Doğa Bilimleri Fakültesi, Elektrik ve Elektronik Mühendisliği Bölümü, Konya, Türkiye

Ö N E Ç İ K A N L A R

- Gelişimsel kalça displazisi US görüntülerinin analiz edilebilirliğinin tespiti
- U-NET mimarisi ile anlamsal bölütleme
- Maskeli bölge tabanlı evrişimli sinir ağı ile örnek bölütleme

Makale Bilgileri

Araştırma Makalesi

Geliş: 26.06.2023

Kabul: 26.11.2023

DOI:

10.17341/gazimmfd.1318983

Anahtar Kelimeler:

Derin öğrenme, gelişimsel kalça displazisi, konvüsyonel sinir ağları, maskeli bölge tabanlı evrişimli sinir ağı, U-NET

ÖZ

Gelişimsel kalça displazisi (GKD), doğum öncesi, doğum sırası ya da doğum sonrası çeşitli nedenlere bağlı olarak kalça eklemının normal gelişmemesi sonucu oluşan bir hastalıktır. GKD'nin tespiti için kullanılan en önemli yöntem ise kalça ultrasonografisidir. Kalça US görüntüsünün elde edilme aşaması operatöre ve dış etkilere bağlı olduğu için değişkenlik göstermektedir. Gerçekleştirilen çalışma ile bu değişkenliği ortadan kaldırmak için yapay zekâ tabanlı bir sistem geliştirilmiştir. Geliştirilen sistem 2 aşamalı bir derin öğrenme modelini kapsamaktadır. Sistemin temel amacı hekimler tarafından elde edilen US görüntülerinin, teşhis için gerekli olan alfa ve beta açıları hesabı için uygun olup olmadığının otomatik olarak tespit etmektir. Sistem ilk aşamada U-NET mimarisini ikinci aşamada da maske ile bölge tabanlı evrişimli sinir ağı (MBT-ESA) mimarisini kullanmaktadır. Eğitim için Selçuk Üniversitesi Tıp Fakültesi hastanesinden etik kurulu onayı ile 540 adet görüntü alınmıştır. Veri artırma işlemleri ile eğitim için toplam 840 görüntü elde edilmiştir. U-NET mimarisi eğitimi sonucunda 0.93 doğruluk, maske ile bölge tabanlı evrişimli sinir ağı eğitimi sonucunda ise 0.96 doğruluk elde edilmiştir. Genel sistem doğruluğu ise 0,96 olarak hesaplanmıştır. Gerçekleştirilen çalışma ile elde edilen sonuçlar, gerçek zamanlı testler ve görüntü sayısı artırılarak, GKD tanısında operatörler arası değişkenliği ortadan kaldırarak, yapılacak olan teşhisin doğruluğunu arttıracak ve uzmanlara yardımcı olacağını göstermektedir.

Usability analysis of developmental hip dysplasia ultrasound images with a two-stage deep learning approach

H I G H L I G H T S

- Determination of analyzability of developmental hip dysplasia
- US images Semantic segmentation with U-NET architecture
- Sample segmentation with masked region-based convolutional neural network

Article Info

Research Article

Received: 26.06.2023

Accepted: 26.11.2023

DOI:

10.17341/gazimmfd.1318983

Keywords:

Deep learning, Developmental hip dysplasia, Convolutional neural networks, Masked region-based convolutional neural network, U-NET

ABSTRACT

Developmental hip dysplasia (DDH) is a disease in which the hip joint fails to develop normally due to various causes before, during or after birth. The most important method used for the detection of DDH is hip ultrasonography. The stage of obtaining the hip US image varies because it depends on the operator and external influences. In this study, an artificial intelligence-based system has been developed to eliminate this variability. The developed system includes a 2-stage deep learning model. The main purpose of the system is to automatically determine whether the US images obtained by physicians are suitable for the calculation of alpha and beta angles required for diagnosis. The system uses the U-NET architecture in the first stage and the masked region-based convolutional neural network (MBT-ESA) architecture in the second stage. For the training, 540 images were taken from Selçuk University Faculty of Medicine hospital with the approval of the ethics committee. A total of 840 images were obtained for training with data augmentation. U-NET architecture training resulted in an accuracy of 0.93 and region-based convolutional neural network training with mask resulted in an accuracy of 0.96. The overall system accuracy was calculated as 0.96. The results obtained in this study suggest that by increasing the number of real-time tests and images, the inter-operator variability in the diagnosis of DDH can be eliminated. Translated with DeepL.com (free version)

*Sorumlu Yazar/Yazarlar / Corresponding Author/Authors : *ozdemirmcihad@gmail.com, dr.sadettinciftci@gmail.com , bkaydin@yahoo.com, mceylan@ktun.edu.tr / Tel: +90 507 211 5949

1. Giriş (Introduction)

Gelişimsel kalça displazisi (GKD) genetik, kültürel ve intrauterin faktörlerden kaynaklanabilen bir kalça eklemi rahatsızlığıdır. GKD bebekler stabil olmayan gevşek bir kalça eklemi ile doğduğunda ortaya çıkmaktadır. GKD oranının dünyadaki birçok gelişmiş ülkede her 1000 bebekte 1 ila 20 vaka arasında olduğu tahmin edilmektedir [1, 2]. GKD kapsüller laksite, asetabular laksite ve kalça çıkığı gibi birçok bozukluğa neden olabilir. Bu bozukluklar yaşla birlikte daha şiddetli hale gelebilir. GKD erken evrede teşhis edilirse, korse ve atel gibi basit tedavi yöntemleriyle tedavi edilebilir [3]. Tedavinin gecikmesi durumunda cerrahi müdahale ihtiyacı doğabilmektedir. Kalça protezi gerektiren, erken başlangıçlı artrit önemli nedenlerinden biridir [4]. Bu nedenle GKD'nin erken dönemde tespit edilmesi büyük önem arz etmektedir [5]. GKD coğrafi bölge veya etnik kökene bağlı olarak farklılık göstermekle birlikte Türkiye'de görülme sıklığı %2,5 olarak gösterilmiştir [6].

GKD tanısı radyografi, fizik muayene ve ultrasonografik (US) görüntüleme yoluyla yapılır. Yenidoğan döneminde teşhis için kullanılan fiziki muayene yöntemleri Barlow testi ve Ortoloni testidir. Ortolani ve Barlow testlerinin duyarlılığı, uygulayan hekimin tecrübesine bağlı olarak değişebilir ve yüksek özgünlüğe sahiptir. Ancak, yumuşak doku kontraktürü nedeniyle 3. aydan sonra Ortolani ve Barlow testlerinin pozitiflik oranı azalmaktadır [7]. Radyografi yönteminde ise yenidoğanın kalçasında kıkırdak yapı ağırlıklı olması nedeniyle değerlendirmek zor olmaktadır. Yeni doğan döneminde ve ilk 6 ayda asetebulum ile femur başının ilişkisini en iyi ortaya koyan yöntem kalça ultrasonografisi'dir [8]. Ultrasonografi, radyasyon riski olmadan kıkırdak ve yumuşak doku üzerinde kolayca yapılabilen düşük maliyetli bir radyografik incelemedir. Doğru yapılmış kalça ultrasonografisi, tanının koyulabilmesi için en önemli kriterdir. Bu kriter GKD'nin çıkık dışındaki daha hafif formlarını teşhis etmek için kullanılabilir [8].

GKD tespitinde kullanılan en yaygın yöntem ise Graf yöntemidir. Graf yöntemi ilk olarak Graf tarafından 1978 yılında tanımlanmıştır [9]. Graf yöntemi statik ultrasonografi temeline dayanan bir yöntemdir. Statik yöntemde asetabulumun morfolojik yapısı ve açılabilirliği ölçülüp femur başının yerleşimi değerlendirilerek tanı koyulmaktadır. Kullanılan statik yöntem uygulayıcılar arası yüksek


değişkenliğe sahiptir [10]. Yapılan çalışmalarda statik yöntem kullanılarak gerçekleştirilen analizlerde bebek taramalarının yaklaşık yarısı ve yenidoğan taramalarında dörtte üçüne kadar GKD nin tespitinde yanlış sonuçlar oluşabildiği saptanmıştır [11]. Bunun temel nedeni GKD teşhisinde açılmanın hesaplanması için gerekli anatomik noktaların (asetabular kemik kenarı, iliak kemik alt kenarı) manuel olarak seçilmesidir. Bu çalışma ile yanlış teşhis ve zaman kaybının önüne geçilerek GKD teşhisinin doğruluğunu ve nesnellliğini iyileştirilmesi hedeflenmiştir.

Şekil 1'de standart bir kalçanın ultrason taramasında görülmesi gereken 3 temel anatomik yapı gösterilmektedir.

LeCun vd., biyolojik sinir ağlarının yapısını ve işlevini simüle eden evrimsel sinir ağı (ESA) çerçevesinin ana hatlarını çizerek günümüz derin öğrenmesinin temelini atmışlardır [12]. Teknolojik gelişmelerin bir sonucu olarak grafik işleme birimleri geliştirilmesiyle birlikte ESA kullanımı tıbbi görüntüleme ve genetik analiz gibi birçok alanda yaygınlaşmıştır. Endoskopik görüntüler ve manyetik rezonans görüntüleme tabanlı uygulamalarda mükemmel teşhis performansı göstermiştir. Bu çalışmalara dayanarak, kalça ultrasonuna dayalı GKD tanısı üzerine çalışmalar başlanmıştır [13, 14].

Den vd., radyografi görüntülerinde gelişimsel kalça displazisini tespit etmek için YOLOv5 kullanan derin öğrenme modeli üzerinde çalışma gerçekleştirmişlerdir. Çalışmada 205 adet normal 100 adette GKD bulunan görüntü kullanılmıştır. Çalışma duyarlılığı 0.94, özgüllüğü ise 0.96 olarak performans göstermiştir. Sistemin yararlı bir teşhis yardımcı aracı olarak kullanılabilirliği bildirilmiştir [15].

Lee vd. Ultrasonografik Gelişimsel Kalça Displazisi (GKD) Taramasında Yeni Derin Öğrenme Modeline Dayalı Segmentasyon ve Anahtar Noktalı Çoklu Tespit Yönteminin Doğruluğu adlı çalışmada maske ile bölge tabanlı evrimsel sinir ağı modeli kullanarak üç temel anatomik yapıyı bölümlere ayırmak ve ilgili önemli noktaları çıkarmak için iki aşamalı bir sistem önerilmiştir. Gerçekleştirilen çalışmada 921 adet görüntü kullanılmıştır. 921 görüntüden 320 si hem sistem hem de operatörler tarafından taranmaya uygun görüldü. Uygun grubun kontrol açılarında 0.809 başarı oranı elde edilmiştir [16]. Kinugasa vd. Derin Öğrenme Kullanarak Ultrason Görüntüleme ile Gelişimsel Kalça Displazisinin Tanısı adlı çalışmada Matlab derin



Şekil 1. Standart bir kalça US görüntüsündeki 3 temel anatomik yapı.
(The 3 basic anatomical structures in a standard hip US image) (1).Labrum (2). İlium (3) İskium

öğrenme araç kutusu kullanılarak 262 görüntüden oluşan bir veri seti kullanıldı. Çalışmada transfer öğrenimi olarak önceden eğitilmiş modeller (SqueezeNet, MobileNet_v2 ve EfficientNet) kullanıldı [17].

Hareendranathan vd. gerçekleştirdiği çalışmada US görüntülerinin tarama kalitesinin teşhis doğruluğu üzerindeki etkisini araştırmıştır. Çalışma tarama kalitesini değerlendirmek için 10 puanlık bir puanlama sistemi geliştirmiştir. Panlama sistemi iliak kemiğin görünürlüğü ve düzlüğü, labrum ve iskiumun görünürlüğü baz alınarak oluşturulmuştur. Çalışmada 7 puan ve altında olan US görüntülerinde teşhis doğruluğunun 0.57 olduğu, 7 üzerinde puana sahip US görüntülerinde ise teşhis doğruluğunun 0.89 olduğu saptanmıştır [18].

Si-Cheng Zhang vd. ResNet-50 mimarisi kullanarak 1753 eğitim ve 268 test verisi kullanarak bir yapay zekâ sistemi geliştirdiler. Sistem kalça eklemi olgunluğunun tespitinde 0.941 doğruluk, graf sınıflandırmasında ise 0.68 doğruluk elde etmiştir [19].

Bölge tabanlı evrişimli sinir ağı (BT-ESA) mimarisi, görüntülerde bulunan objelere ait sınıfları ve bu objelere ait sınırlayıcı kutuları tespit etmek için kullanılır. Sadece CNN mimarisi kullanılmamasının nedeni, ilgilenilen nesnelerin görüntü içinde farklı uzamsal konumlara ve farklı en-boy oranlarına sahip olabilmesidir. Bu nedenle, çok sayıda bölge seçimi gerekmektedir ve bu işlem hesaplama açısından büyük bir yükü sebep olmaktadır. Çoklu objeye sahip görsellerde bu dezavantajı ortadan kaldırmak için BT-ESA mimarisi geliştirilmiştir [20]. BT-ESA'da ana fikir iki adımdan oluşmaktadır. İlk olarak seçici arama ile görselde obje olmaya aday karakterler belirlenir. Bölge belirlendikten sonra, her biri ayrı ayrı bir ESA modeline girer olarak verilir. Burada sınıflar ve sınırlayıcı kutular tahmin edilir. Bu işlem büyük zaman kayıplarına yol açtığı için daha hızlı bölge tabanlı evrişimli sinir ağı (DHBT-ESA) modeli önerilmiştir [21].

Bu yöntemin BT-ESA'dan en büyük farkı, görüntüyü ilk olarak bölge önerilerine bölmeyip, ESA'yı uygulayıp daha sonra oluşan konvolüsyon özellik haritası üzerinde bölge önerilerine ayırmasıdır. Ayrıca sınıflandırma kısmında aktivasyon fonksiyonu o olarak destek vektör makinesini (DVM) kullanmayıp, çok sınıflı sınıflandırma problemlerinde sıkça kullanılan

softmax aktivasyon fonksiyonunu kullanmasıdır. Softmax fonksiyonu, her bir çıktı sınıfının olasılığını temsil etmek için kullanılır. Bu fonksiyon, çıktı değerlerini [0, 1] aralığına sıkıştırır ve toplam çıktıların toplamı 1 olacak şekilde normalize eder. Böylece, her bir sınıfın olasılığına karşılık gelen çıktı değerlerini elde edilir.

Kadiroğlu vd. gerçekleştirdiği çalışmada pnmoni ve sağlıklı göğüs röntgeni görüntülerini sınıflandırmak için 10 farklı derin öğrenme modelini kullanmıştır. Çalışma derin özniteliklerin sınıflandırılması için Destek Vektör Makineleri (DVM) ve, k- En Yakın Komşu (kNN) ve Rastgele Orman (RO) sınıflandırıcıları kullanılmıştır. Parametreleri ayarlanmış olan AlexNet mimarisi diğer 9 mimariden daha yüksek bir performans göstermiş ve 0.98 doğruluk elde etmişlerdir [22].

Üzülmez ve Çiftçi derin öğrenme ve belirsizlik ölçeği tekniği birleştirilerek akciğer tomografilerinde hastaların kanser olup olmadığının teşhisinin yapıldığı çalışma gerçekleştirmişlerdir. Çalışmada resNet50, AlexNet, Inception3 modelleri kullanılmıştır. Çalışma belirli sinir ağı modellerinin performansının belirsizliğin

hesaba katılmasıyla atırlabileceğini göstermiştir [23]. Yılmaz gerçekleştirdiği çalışmada akciğer X-Ray görüntülerinden otomatik Covid-19 tanısını beş evrişim kanalına sahip olan çok kanallı CNN mimarisi sunumu ve bu kanalların ürettiği sonuçlar arasında en belirgin özellik filtrelerini seçmek için önerilen çok kanallı CNN mimarisinde kanal seçim formülü ortaya koyarak yapmıştır. Çalışma sonucunda elde edilen sonuçlar ile laboratuvar sonuçlarının uyduğu görülmüştür [24].

Gerçekleştirilen çalışmada US görüntülerinin analiz edilebilirliğinin tespiti için 2 aşamalı bir yapay zekâ sistemi önerilmiştir. İki aşamalı bir yapay zekâ sisteminin kullanılmasının temel nedeni US görüntülerinin karmaşık yapısıdır. Bu karmaşıklık en aza indirmek ve doğruluğu arttırmak için iki farklı yapay zekâ algoritması kullanılmıştır. Bu sayede algoritmaların kendi içerisindeki bazı dezavantajları minimize edilerek sistemin performansı artırılmıştır.

İlk aşamada kullanılan U-NET mimarisi anlamsal segmentasyon tabanlı bir mimaridir. U- Net mimarisinin en büyük avantajı az sayıdaki verilerde de yüksek doğrulukta anlamsal segmentasyon yapmasıdır. Karmaşık yapıdaki US görüntülerinde 3 temel anatomik yapı hedeflenerek anlamsal segmentasyon yapılmaktadır. Bu sayede 2. Aşama olan maske ile bölge tabanlı evrişimli sinir ağı (MBT-ESA) mimarisinden önce US görüntüsü sadeleşecek ve sadece 3 temel anatomik yapı kalacak. Bu sayede ikinci aşamada MBT-ESA mimarisi sadece tespit edilecek anatomik yapıların sınırlarının belirlenmesi ve tüm yapıların tespit edilip edilmediğine odaklanmaktadır. Bu şekilde U- Net mimarisinin örnek segmentasyonundaki dezavantajını MBT-ESA mimarisi ile giderilmektedir. Gerçekleştirilen çalışma ile iki farklı yapay zekâ mimarisinin beraber kullanılması ile yeni bir bakış açısı getirilmiştir.

Bu makalenin 2. bölümünde GKD tespiti için gerekli anatomik yapıları ve kullanılan yapay zekâ mimarileri verilmiştir. Bölüm 3'te, oluşturulan sistemin detayları ve elde edilen performansa dair detaylar, Bölüm 4'te ise deneysel sonuçlar ve öneriler yer almaktadır.

Materiyaller ve Yöntemler (Materials and Methods)

2.1. Görüntü Veri Tabanı (Image Database)

Çalışma kullanılan yenidoğan kalçasına ait ultrason görüntüleri Selçuk Üniversitesi Tıp Fakültesi Hastanesi'nden 2020/586 sayılı Etik Kurul onayı ile 540 adet US görüntüsü temin edilmiştir. Elde edilen görüntülerden 400 adeti analiz edilebilir 140 adeti ise analiz edilemez şeklindedir. Şekil 2'de US görüntü örneği yer almaktadır.

Elde edilen US görüntülerinin boyutları 700x600 ile 934x700 arasında değişen değerlere sahiptir. Görüntülerin farklı boyutlarda olması, görüntülerin analiz edilebilirliğini etkilediğinden, tüm görüntülerin boyutu 256x256 olacak şekilde ayarlanmıştır.

Tüm görüntüler aynı boyuta getirildikten sonra veri büyütme işlemine başlanmıştır. Bu işlemin amacı, mevcut 540 US görüntüsünü artırarak daha çeşitli ve daha büyük bir veri seti elde etmektir. Veri büyütme işlemi için döndürme ve aynalama yöntemleri kullanılmıştır. Döndürme ve aynalama, görüntü verisini çeşitlendirmek ve veri arttırmak için kullanılan yaygın olarak kullanılır. Bu teknikler, geometrik dönüşümleri temel alır ve görüntülerin farklı açılardan veya yansıtılmış hallerinden yeni örnekler oluşturur. Bu sayede eğitimde aşırı öğrenmenin önüne geçilmesi hedeflenmiştir. Veri artırma işlemlerinin ardından aynı çözünürlükte 840 US görüntüsü elde edilmiş ve veri seti tamamlanmıştır.

Şekil 3'de veri büyütme ve yeniden boyutlandırma işlemlerinin akış şeması gösterilmektedir.

2.2. US Görüntülerinde Anatomik Yapıların Bölütlemesi (Segmentation of Anatomical Structures in US Images)


Gelişimsel kalça displazisini tespitinde kullanılan US görüntülerinin analizi için belirli standartlar vardır. Şekil 4'de kalça eklemi ve periferik elemanlarının bir diyagramı gösterilmektedir.

Graf yönteminin belirlediği standartlara göre, bir ultrason görüntüsünün analiz edilebilir olması için ilium, labrum ve iskium'un anatomik yapılarının net bir şekilde görülebilmesi gerekir. Bu 3 temel anatomik yapıdan herhangi birinin US görüntüsünde gözlemlenememesi, başarısız bir US görüntüsü elde edildiğini gösterir. Çünkü 3 temel anatomik yapı doğru bir şekilde gözlemlenemezse kalça çıkığına tespit etmek için gerekli olan taban çizgisi, kemik çatı çizgisi ve kıkırdak çatı çizgisi çizilemez. Bu çizgiler olmadan alfa ve beta açıları hesaplanamaz ve durum teşhis edilemez. Şekil 5'te alfa ve beta açılarının hesabı için gerekli çizgiler gösterilmektedir.

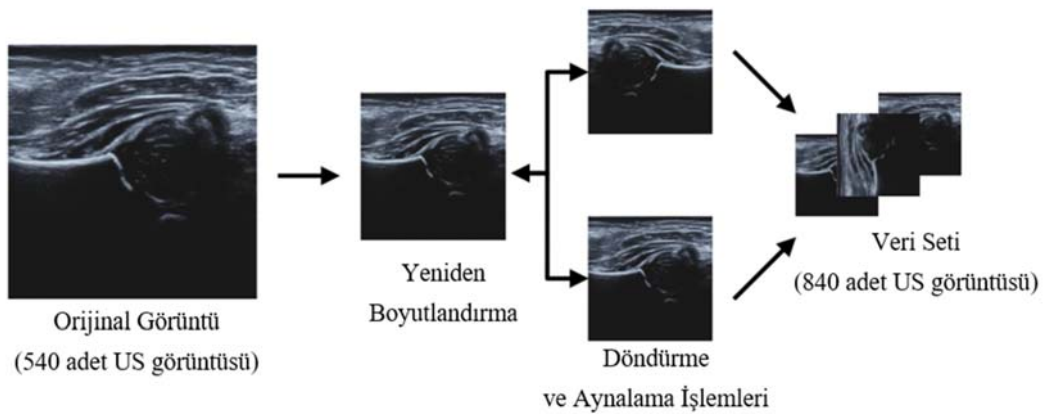
Bir yapay zekâ modelinin yüksek performans göstermesi için dikkat edilmesi gereken bazı noktalar vardır. İlk olarak veri setinin elde edilmesi ve bu veri setinin kullanılacağı yapay zekâ algoritmasına göre ön işleminin gerçekleştirilmesidir. Bu veri standartlaştırılması için önemlidir. İkinci olarak verileri eğitim, doğrulama ve test kümelerine bölme işleminin gerçekleştirilmesidir. Bu, modeli eğitirken performansının değerlendirmeye yardımcı olur. 3. aşama ise model seçimidir. Veri setine uygun doğru modeli seçmek yüksek performans elde etmek için önemlidir. Diğer önemli nokta ise seçilen modelin performansına uygun hiper parametreleri belirlemektir. Bu hiper parametreler modelin aşırı öğrenme yapmaması, zaman maliyeti gibi konular için büyük önem taşımaktadır.

Gerçekleştirilen çalışmada yapay zekâ aracılığıyla US görüntüsündeki 3 temel anatomik yapının tespiti için bölütlemeye dayalı iki derin öğrenme modeli kullanılmıştır. Bu modeller U-NET ve MBT-ESA'dır. Bu nedenle görüntü bölütleme büyük önem taşımaktadır.

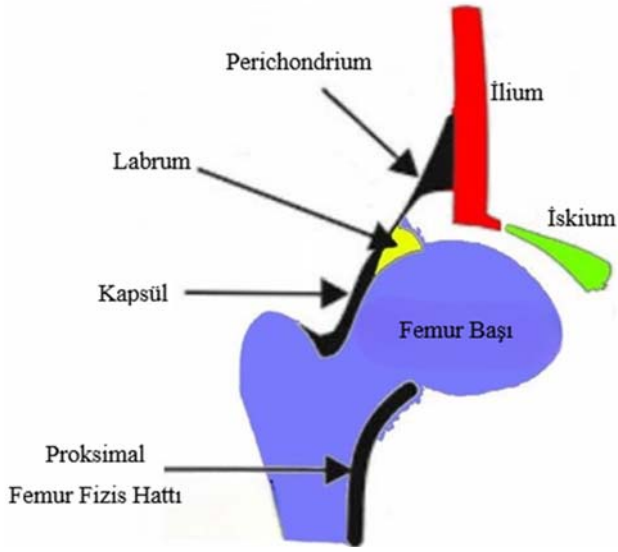
Görüntü bölütleme, dijital bir görüntüyü bir dizi farklı parçaya bölme işlemidir. Bölütlemenin 2 ana yöntemi vardır. Bunlar anlamsal bölütleme ve örnek bölütlemidir.




Şekil 2. Yenidoğan kalça bölgesinin US görüntüsü (US image of the neonatal hip region)



Şekil 3. Veri Seti Oluşturma Diyagramı (Data Set Creation Diagram)



Şekil 4. Kalça eklemi ve periferik elemanları (Hip joint and peripheral elements) [25]



Şekil 5. Alfa açısı ve beta açısının şematik çizilmesi Temel çizgi (1), kemik çatı çizgisi (2), kıkırdak çatı çizgisi (3) (Schematic drawing of alpha angle and beta angle Baseline (1), bone roof line (2), cartilage roof line (3)) [25]

Anlamsal bölütleme, nesne örneklerini ayırt etmeden her pikseli sabit bir kategori kümesine sınıflandırmakla ilgilidir. Başka bir deyişle, anlamsal bölütleme piksel düzeyinde benzer nesnelere tek bir sınıf olarak tanımlamak/sınıflandırmakla ilgilidir. Anlamsal bölütleme, görüntüdeki nesnelere arka plandan ayırdığı için arka plan bölütlemesi olarak da bilinir. Şekil 6a anlamsal bölütleme sonucunu göstermektedir.

Anlamsal bölütleme sonucunda 3 temel anatomik yapıya segment edilmiştir. Ancak bu 3 yapı tek bir yapı olarak görülmektedir. Semantik bölütleme hangi yapının ilium hangisinin iskiüm olduğunu bilmemektedir. Bu yapıları ayırt etmek ve kesin sınırlarını bilmek için kullanılan bölütleme modeline örnek bölütleme modeli denir.


Örnek bölütleme, bir görüntüdeki tüm nesnelere doğru bir şekilde algılanması ve aynı zamanda her bir örneğin doğru bir şekilde bölütlenmesi ile ilgilidir. Bu nedenle nesne tespiti, nesne lokalizasyonu ve nesne sınıflandırmasının bir kombinasyonudur. Başka bir deyişle, bu bölütleme türü, benzer bir örnek olarak sınıflandırılan her nesne arasında net bir ayrım yaparak sınırlarını belirler. Şekil 6b örnek bölütleme sonucunu göstermektedir. Örnek bölütleme sonucunda 3 temel anatomik yapı net bir sınırla ayrılmış ve ayrı ayrı gözlemlenebilir hale getirilmiştir.

2.2.1. U-net

Gerçekleştirilen çalışmada kullanılması planlanan U-NET mimarisi bir tür ESA yaklaşımıdır. U-NET ilk olarak biyomedikal görüntüler üzerinde daha iyi bir bölütleme (bölütleme) yapma önerisi ile 2015 yılında, Olaf Ronneberger, Philip Fischer ve Thomas Brox tarafından duyurulmuştur [26].

Mimari, yapısı itibarıyla 'U' şeklindedir. Ağ mimarisi Şekil 7'de gösterilmiştir.

U-NET mimarisi kodlama veya aşağı örnekleme yolu, darboğaz (kod çözme) ve yukarı örnekleme yolu olmak üzere üç bölüme ayrılmıştır. Aşağı örnekleme yolu kısmı, birçok kodlama bloğundan oluşmaktadır. Her bir bloktan sonra, özellik haritası sayısı, modelin karmaşık yapıları verimli bir şekilde öğrenebileceği şekilde çarpılır. Darboğaz kısmı, aşağı örnekleme ile yukarı örnekleme arasındadır. İki evrimsel katmandan oluşmaktadır. U-Net mimarisinin özü, kod çözme kısmında yatmaktadır. Kodlama kısmı gibi çeşitli kod çözme bloklarından oluşmaktadır. U-Net modeli girdiyi kodlayarak ve onun



Şekil 6. Bölütleme sonuçları (a) Anlamsal Bölütleme (b) Örnek Bölütleme (Segmentation results (a) Semantic Segmentation (b) Sample Segmentation)

derin özelliklerini bularak aşamalı bir şekilde çalışmaktadır. Daha sonra bu özellikleri Ters evrişim ile deşifre eder ve bu kod çözme sonuçlarını aynı boyutlara sahip özelliklerle kanal olarak birleştirmektedir.


Bu mimaride giriş görüntüleri ağ eğitimi sonucunda segmente edilmiş/bölünmüş çıkış haritası olarak elde edilir. U- Net mimarisinin en önemli özelliği ağın tam bağlı bir katmana sahip olmamasıdır. Sadece konvolüsyonel katmanı kullanılmaktadır. Her standart evrişim işlemi doğrusal doğrultma birimi (DDB) ile aktive edilmektedir [27]. İlk aşamada, anlamsal bölütleme U- Net mimarisi kullanılarak gerçekleştirilmiş, bu da bir sonraki aşama için US görüntülerinin analizini kolaylaştırmıştır.

İlk olarak, 540 görüntü U- Net mimarisi için 256x256 çözünürlüğe yeniden boyutlandırılmıştır. Daha sonra görüntü döndürme ve yansıma gibi veri artırma yöntemleri uygulanmıştır. Veri artırma işlemleri sonucunda 840 görüntüden oluşan bir veri seti elde


edilmiştir. Veri setinin oluşturulmasının ardından verilerin etiketlenmesi sürecine geçilmiştir.

Bir yapay zekanın herhangi bir veri parçasına uygun sonuçlar üretebilmesi için o verinin önceden belirlenmiş kategorizasyonunu tanıyabilmesi ve her bir kategorinin özelliklerine öğrenmesi gerekir. Yapay zeka veriyi ham haliyle anlamlandıramaz, bu nedenle öncelikle karşılaştığı verinin anlamının ne olduğunu bilmesi gerekir. Görüntüde tespit edilmesi gereken noktaların kategorilere göre etiketleme işlemine veri etiketleme denir.

Veri etiketleme sürecinde, segmente edilecek anatomik yapılar işaretlenerek U- Net ağı için kullanılabilir hale getirilir. Veri etiketleme işlemi için Labelme programı kullanılmıştır. Şekil 8'de, veri etiketleme süreci gösterilmektedir. Etiketlenen veri daha sonra uzman radyologlar tarafından kontrol edilmiş ve standart oluşturulmuştur.



Şekil 7. U-NET Mimarisi (U-NET Architecture)



Şekil 8. U- Net Mimarisi için Veri Etiketleme Süreci (Data Labelling Process for U- Net Architecture)

2.2.2. Maske ile bölge tabanlı evrişimli sinir ağı (Region-based convolutional neural network with mask)

Maske ile bölge tabanlı evrişimli sinir ağı (MBT-ESA), daha hızlı bölge tabanlı sinir ağı (HBEA) modeli temelinde geliştirilen bir bölge-tabanlı evrişimsel sinir ağıdır. İşleyişini anlamak için HBEA modelini temel olarak ele almak gerekmektedir. HBEA modelinde, giriş resimlerinden özellik haritaları elde edilir. Bu özellik haritaları, resimdeki nesne özelliklerini temsil eden bilgileri içerir.

Maskeli bölge tabanlı evrişimli sinir ağı, HBEA'nın üzerine ek olarak nesne maskelerini tahmin etmek için bir maske çıktısı ekler. Bu şekilde, model aynı anda nesne tespiti ve nesne segmentasyonunu gerçekleştirebilir.

MBT-ESA mimarisinde, önceki adımlardan farklı olarak bölgesel öneri ağı (BÖA) kullanılır. BÖA, giriş resmi üzerindeki potansiyel nesne bölgelerini belirlemek için kullanılır. BÖA, özellik haritalarını analiz ederek bölge önerileri üretir. Bu bölge önerileri, olası nesne konumlarını içeren sınırlayıcı kutuları temsil eder.

Daha sonra, bölge önerileri havuzlama işlemine tabi tutulur. Havuzlama işlemi, bölge önerilerini daha küçük boyutlara indirger ve daha sonra nesne tespiti ve segmentasyonu için kullanılan tam bağlantılı çoklu katman algılayıcılara (ÇKA) giriş olarak sunulur. ÇKA aşamasında, sınıf tahmini ve sınırlayıcı kutu ofseti tahmini yapılmaktadır.

MBT-ESA mimarisinde özellik haritaları üzerinde piksel seviyesinde hizalama işlemi yapılır ve maske çıktıları üretilir. Maskeler, nesnelerin her pikseline ait segmentasyon bilgisini içerir. Bu segmentasyon bilgisi, nesnelerin kenarları ve iç bölgeleri gibi daha ayrıntılı özellikleri yakalamaya yardımcı olur.

MBT-ESA mimarisi, HBEA mimarisine kıyasla daha hızlı sonuçlar elde etmektedir. Çünkü HBEA'da maskelerin tahmin edilmesi için

ayrı bir aşama gerekmektedir, MBT-ESA'da maskeler doğrudan modelin bir parçası olarak tahmin edilir. Bu sayede nesne tespiti ve segmentasyonu aynı anda gerçekleştirilebilir. Şekil 9'da Maskeli bölge tabanlı evrişimli sinir ağı mimarisi gösterilmektedir.

MBT-ESA algoritmasında, örnek bölütleme(segmentasyon) özelliği kullanılarak nesnelerin yüzeyleri renklendirilerek maskeleme işlemi gerçekleştirilir. Bu işlem, aynı türden birden fazla nesnenin olduğu durumlarda bu nesnelerin farklı renklerle ayrılmasını sağlar.

MBT-ESA algoritmasındaki kayıplar(L), sınıflandırma kaybı (Lcsc), maskeleme kaybı (LNACK) ve çerçeve kaybı (Lbos) olmak üzere üç ana bileşenden oluşur. Bu kayıplar, algoritmanın eğitim aşamasında kullanılır ve modelin performansını optimize etmeye yöneliktir.

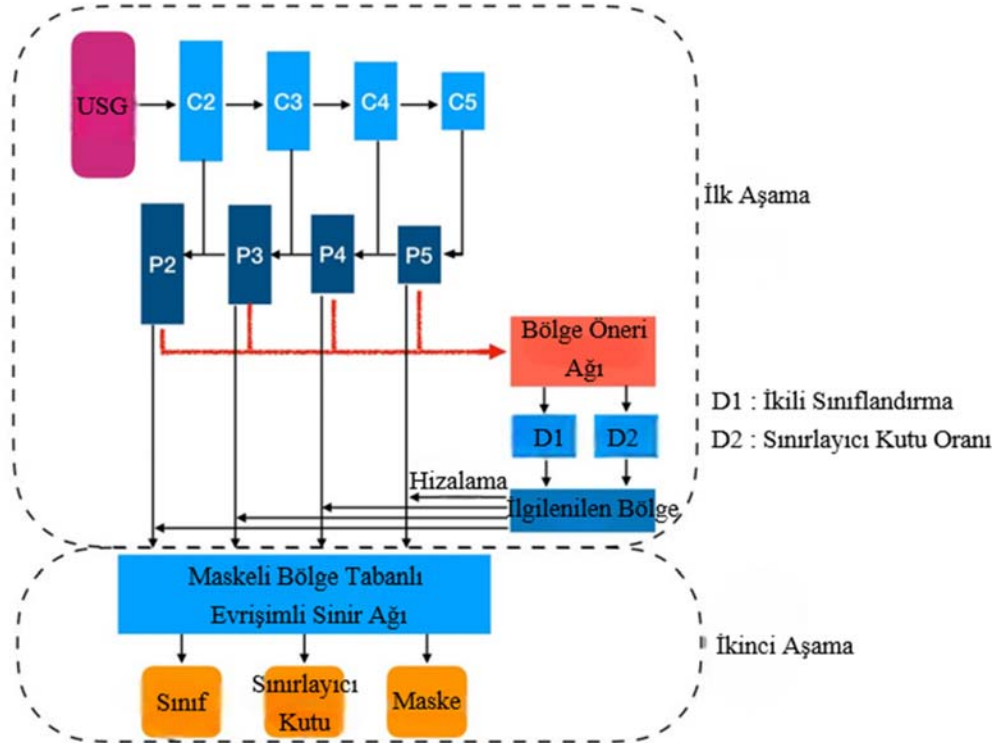
Eş. 1'e göre, algoritma kaybı (L) aşağıdaki şekilde ifade edilir:

$$L=L_{csc}+L_{NAC}+L_{bos} \quad (1)$$

Burada, Lcsc sınıflandırma kaybını, LNACK maskeleme kaybını ve Lbos çerçeve kaybını temsil eder.


Bu kayıplar, modelin tahminlerinin gerçek değerlerden ne kadar farklı olduğunu ölçer ve bu farkı azaltmaya çalışarak daha doğru tahminler elde etmeyi hedefler. Bu şekilde, MBT-ESA mimarisinde yüksek doğrulukla nesne tanıma ve bölütleme işlemlerini gerçekleştirebilir. MBT-ESA mimarisi, omurga, bölgesel öneri ağı (BÖA), ilgili bölge hizalaması (İBH), sınıflandırma ve sınırlayıcı kutu ve maskeleme bölümlerinden oluşmaktadır.

MBT-ESA mimarisinin eğitimi için 200 görüntü alınmıştır. Bu görüntüler U- Net ağının sonuçlarından oluşmaktadır. Semantik bölütleme sonucunda bu görüntülerdeki anatomik yapılar tek bir bölge olarak karşımıza çıkmaktadır. Veri etiketleme işlemi anatomik yapıların sınırlarını belirlemek ve örneklerin bölütlenmesinde altyapı



Şekil 9. Maskeli bölge tabanlı evrişimli sinir ağı mimarisi (Masked region based convolutional neural network architecture)

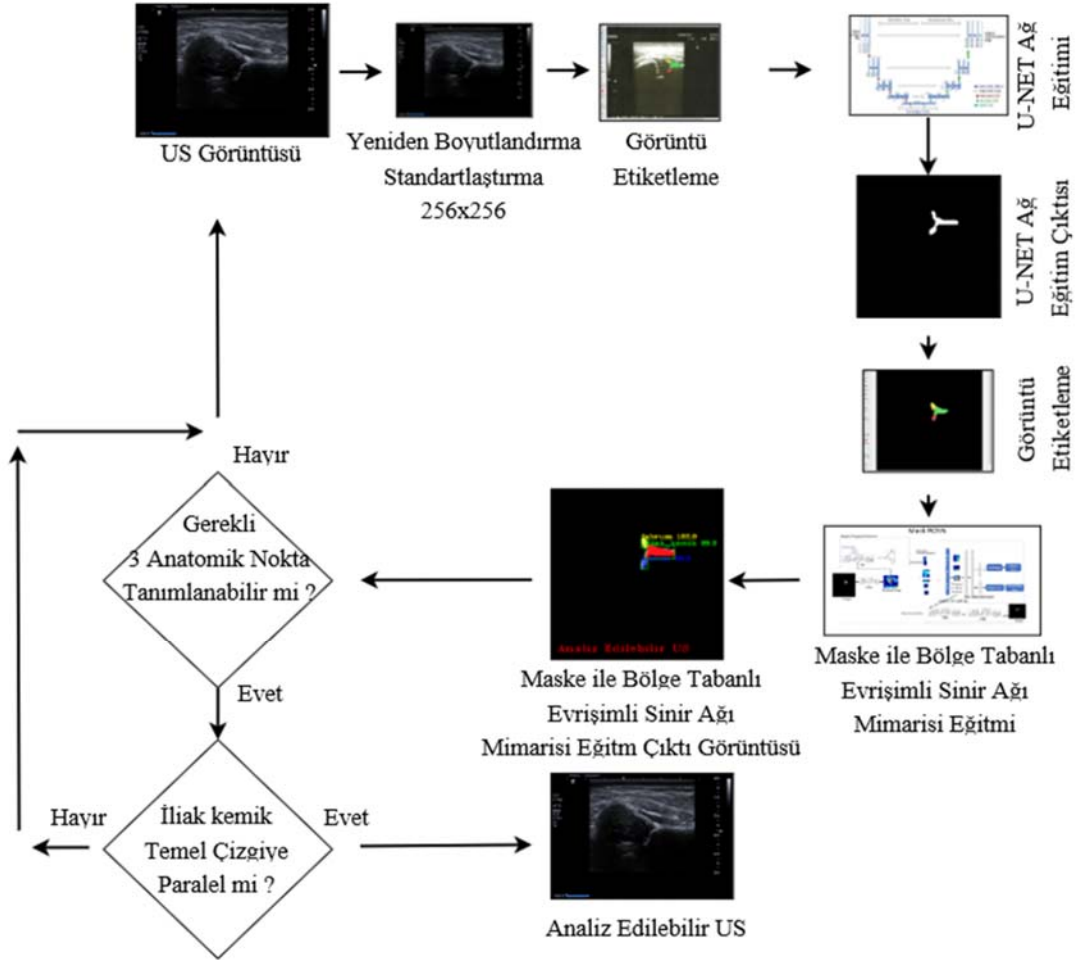
olarak kullanılacak veri kümesini hazırlamak için kullanılmaktadır. Şekil 10'da verilerin etiketlenmesiyle ilgili adımı göstermektedir.



Şekil 10. MBT-ESA için Veri Seti Etiketleme Süreci (Data Set Labelling Process for MBT-ESA)

3. Sistem Performansı (System Performance)

Ultrason görüntülerinin analizi ve yorumlanması genellikle zor olabilmektedir. Özellikle, anatomik yapıları otomatik olarak tespit edebilen ve insan müdahalesi olmadan gerekli açılı elde edebilen bir yapay zekâ sistemi oluşturmak için büyük miktarda görüntü verisine ihtiyaç vardır [28]. Bu zorluğu minimuma indirmek için, daha az görüntü içeren veri setlerinde de iyi sonuç veren U-Net algoritması kullanılmıştır. U-Net mimarisi ile US görüntülerinde anatomik yapılar anlamsal bölütleme ile tanımlanmıştır. Daha sonra tanımlanan anatomik yapılar MBT-ESA algoritmasında girdi olarak kullanılarak sınırları ayrıştırılır ve analiz edilebilirlikleri kontrol edilir. Gerçekleştirilen çalışmada 2 aşamalı bir yapay zekâ sistemi uygulanmaktadır. İki aşamalı bir yapay zekâ modelinin kullanılma sebebi iki mimarinin birbirlerinin eksik yönlerini tamamlamasıdır. U-Net mimarisi anlamsal segmentasyonda etkili bir mimardır. Düşük veri setinde yüksek performanslı segmentasyon gerçekleştirebilir. Ancak bir segmentasyon alanında birden çok yapı varsa bu tür problemlerde farklı yapıların sınırlarını belirlemede bazı zorluklar yaşadığı için yüksek performans sağlayamamaktadır. MBT-ESA mimarisi ise örnek segmentasyonu ve nesne tespitinde yüksek performans veren bir mimardır. MBT-ESA mimarisi ise US görüntüsü gibi birbirine benzeyen karmaşık yapılarda segmentasyon konusunda düşük performans gösterdiği ve eğitim için çok fazla veriye ihtiyaç duyduğu için sıkıntılar oluşturmaktadır. Bu nedenle bu mimariler beraber kullanılarak dezavantajlı yönleri minimuma indirilmiştir.



Şekil 11. İki aşamalı kalça US görüntüsü kontrol sistemi (Two-stage hip US image control system)

Oluşturulan sistemin akış şeması Şekil 11'de gösterilmektedir.

Şekil 11'da gösterilen diyagramda, ilk adım farklı boyut ve çözünürlükteki US görüntülerini çözünürlük be boyut bakımından standart hale getirmektir. US görüntülerini standartlaştırma işleminden sonra, tanımlanacak anatomik yapılar etiketlenmiş ve veri kümesi oluşturulmuştur. Elde edilen veri kümesi U-Net mimarisi kullanılarak eğitilmiştir. Bu sayede US görüntüleri anlamsal segmentasyon ile sadeleştirilmiştir. MBT-ESA mimarisi için veri kümesi, U-Net ağının bir sonucu olarak üretilen çıktı görüntülerinin yeniden etiketlenmesiyle oluşturulmuştur. MBT-ESA mimarisi veri kümesi ile eğitilerek, tespit edilmek istenen 3 temel anatomik yapının (iskium, iliak kemik, labrum) elde edilip edilmediği kontrol edilir. En az biri bile tespit edilmemişse program "Tekrar US Alın" uyarısını verecektir. Eğer 3 temel anatomik yapının tümü tespit edilmişse sonraki aşama olan iliak kemiğe paralel bir çizgi çizmesi işlemine geçilir. Bu çizgi taban çizgisi olarak adlandırılır. Daha sonra US görüntüsünün analiz edilebilir olduğundan emin olmak için taban çizgisi ile iliak kemik arasındaki paralellik tekrar kontrol edilir. Paralellik belirlenen eşik değerinin altındaysa ekranda "Tekrar US Alın" mesajı bir kez daha görüntülenecektir. Eğer iliak kemik temel çizgiye paralel ise US görüntüsü analiz edilebilir olarak sınıflandırılacaktır. Genel olarak sistemde 3 temel anatomik yapı tespit edilmiş ve iliak kemik temel çizgiye paralel ise US görüntüsü analiz edilebilir olarak sınıflandırılacaktır.

3.1. Anatomik Yapıların Çıkarılması için U-NET Bölütlemesinin Sonuçları (Results of U-NET Segmentation for Extraction of Anatomical Structures)

Oluşturulan sistemin ilk aşamasında U-Net ağının eğitimi bulunmaktadır. Bu aşamanın temel amacı US görüntüsünde belirlenmesi gereken noktaları (iskium, iliak kemik, labrum) segmente ederek verileri MBT-ESA mimarisine hazırlamaktır. Bu aşamada U-NET mimarisinin tercih edilmesinin sebebi mimarinin semantik bölütlemeye dayalı olmasıdır. Çünkü ilk aşamada karmaşık bir ultrason görüntüsünün basitleştirilmesi ve sistemin sadece tespit edilmek istenen anatomik yapılara odaklanması hedeflenmektedir. Bu sayede MBT-ESA mimarisinin performansı artırılmış olacaktır.

US görüntülerinin veri etiketleme işlemi sonucunda U-NET ağı için 840 adet US görüntüsünden oluşan veri kümesi hazırlanmış ve eğitim işlemi gerçekleştirilmiştir. Veri kümesinin eğitimi U-NET ağı kullanılarak gerçekleştirilmiştir. Eğitim, her 500 adımda bir model performansı kontrol edilmek üzere toplam 75000 adımdan oluşmaktadır. Öğrenme oranı 0.0001'e sabitlenmiştir ve yığın boyutu 16'dır. Mimarinin eğitiminde adam optimizasyonu kullanılmıştır. Adam optimizasyonu fonksiyonu büyük veri kümesi ve karmaşık modeller üzerinde iyi performans göstermektedir [29]. Eğitimde aktivasyon fonksiyonu olarak sigmoid aktivasyon fonksiyonu kullanılmıştır. Sigmoid aktivasyon fonksiyonu girdi değerini 0 ile 1 arasında bir çıktıya dönüştürmektedir. Sigmoid aktivasyonu, türevi hesaplamak ve geriye yaymak için uygun bir aktivasyon fonksiyonudur. Bu, eğitim sırasında gradyan inişinin verileri iyi bir şekilde öğrenmesini ve modeli eğitmesini kolaylaştırır.

$$S(x) = 1 / (1 + e^{(-x)}) \quad (2)$$


Eş. 2'de $S(x)$, sigmoid fonksiyonunun çıktısı, x , girdi değerini, e ise euler sabitini temsil eder.

Eğitimin doğruluğunu değerlendirmek için kesişim üzerine birliktelik (KÜB) ve dice benzerlik katsayısı gibi metrikler kullanılmıştır

Kesişim üzerine birliktelik (KÜB) iki bölgenin (gerçek ve tahmin edilen) ne kadar örtüşüğünü ölçen bir değerlendirme metriğidir.


550

Özellikle nesne tespit ve segmentasyon problemlerinde yaygın olarak kullanılır. İki bölge arasındaki örtüşme alanının, birleşim alanına bölünmesiyle elde edilir. KÜB, genellikle 0 ile 1 arasında bir değer alır, 1'e ne kadar yakınsa, iki bölge o kadar iyi örtüşmektedir. KÜB metriğine ait görsel şekil 12'de gösterilmektedir.



Şekil 12. KÜB metriğinin gösterimi
(Representation of the KÜB metric) [30]

Dice benzerlik katsayısı iki kümenin benzerliklerini ölçmek için kullanılan bir metriktir. Özellikle görüntü segmentasyonu ve medikal görüntü analizi gibi alanlarda yaygın olarak kullanılır. Gerçek ve tahmin edilen bölgelerin ortak alanının iki kümenin toplam alanına oranı olarak hesaplanır. Dice benzerlik katsayısı da 0 ile 1 arasında bir değer alır, 1'e ne kadar yakınsa, iki küme o kadar benzerdir. Şekil 13'te dice benzerlik Katsayısı metriğine ait görsel gösterilmektedir.



Şekil 13. Dice katsayısı metriğinin gösterimi
(Representation of the Dice coefficient metric) [31]

Eğitim sonucunda oluşan toplam hata 0,07 olarak hesaplanmıştır. U-NET ağının eğitim ve çıktı sonuçları Tablo 1'de gösterilmektedir.

Tablo 1. U-NET ağ parametreleri ve sonuçları

Eğitim süresi (min)	Eğitim adımı	Doğruluk (%)	Ortalama küb
185	75000	0.93	0.87

Eğitim sonucunda Şekil 14'te görülebileceği gibi iliak kemik ve labruma karşılık gelen alanlar üzerinde semantik bölütleme gerçekleştirilmiştir.

3.2. MBT-ESA Kullanılarak Anatomik Yapıların Sınırlarının Belirlenmesi (Boundary Delineation of Anatomical Structures Using MBT-ESA)

U-NET mimarisi sonucunda üretilen çıktı görüntülerinde iskiüm, iliak kemik ve labrum noktaları tek bir nokta olarak yorumlanmaktadır. Bu noktaların sınırlarının belirlenmesi ve anlamlandırılması için Labelme programı kullanılarak etiketleme işlemi gerçekleştirilmiştir. Etiketleme işleminin ardından 200 veriden oluşan yeni bir veri kümesi oluşturularak eğitime hazır hale getirilmiştir. MBT-ESA mimarisi eğitiminde ara katmanlarda relu aktivasyon fonksiyonu kullanılmıştır. Sınıflandırma işleminde ise sigmoid aktivasyon fonksiyonu kullanılmıştır. Optimizasyon fonksiyonu olarak stokastik gradyan iniş (SGD) fonksiyonu kullanılmıştır. Bu optimizasyon algoritmaları, ağız eğitim sürecinde ağırlıkları güncellemek ve kayıp fonksiyonunu minimize etmek için kullanılır. MBT-ESA modeli örnek bölütleme dayalı bir modeldir. Böylece, U-Net mimarisi tarafından tek bir bölge şeklinde oluşturulan anatomik yapıların sınırları birbirinden ayrılmıştır. Eğitim, en iyi model seçimini doğrulamak için her 200 adımda bir model performansı kontrol edilerek 16000 adımdan oluşur.

Öğrenme oranı ve ağırlık azaltma 0,001 olarak ayarlanmıştır. Stokastik gradyan inişi, 10'luk bir parti boyutu ile kullanılmıştır. Eğitim, veri artırma yöntemi kullanılarak gerçekleştirilmiştir. Veri artırma işleminde aşağı kaydırma, rastgele ölçekleme, rastgele döndürme gibi özellikler kullanılmıştır. Eğitim sonucunda toplam hata 0,04 olarak hesaplanmıştır.


Tablo 2. MBT-ESA ağ parametreleri ve sonuçları

Eğitim süresi (min)	Eğitim adımı	Doğruluk (%)	Ortalama küb
540	16000	0.96	0.80


İkinci eğitim olan MBT-ESA ağının temel amacı, U-Net ağı sonucunda oluşan görüntünün sınırlarını belirlemek ve tespit edilecek bölgeleri ayırt etmektir. MBT-ESA ağına girdi olarak verilen görüntü ve eğitim süreci sonucunda oluşan çıktı görüntüsü Şekil 15'te gösterilmiştir.

3.3. Gelişimsel Kalça Displazisi için US Görüntüleri Sınıflandırma Sonuçları (US Images Classification Results for Developmental Hip Dysplasia)

Bir kalça US görüntüsünün analiz edilebilir olarak değerlendirilebilmesi için İlium (iliak kemik), labrum ve iskiüm



Şekil 14. (a) US Görüntüsü (b) U-NET Mimarisinin sonucu ((a) US Image (b) Result of U-NET Architecture)



Şekil 15. (a) Giriş görüntüsü (b) MBT-ESA mimarisi ile elde edilen çıkış görüntüsü
(a) Input image (b) Output image obtained with MBT-ESA architecture ()

(kalça kemiği) noktalarının üçünün birden net olarak görünmesi gerekmektedir. Bu yapılar her biri ayrı ayrı görüldükten sonra iliak kemiğin temel çizgiye paralelliği kontrol edilmektedir olarak değerlendirilecektir.

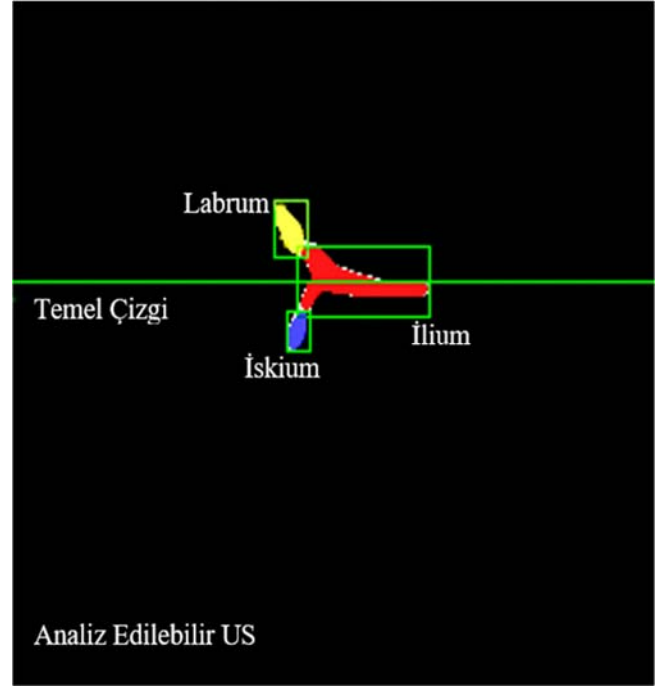
Önerilen sistemin eğitimi tamamlandıktan sonra sistemin test aşamasına geçilmiştir. Test yazılımında hem U-NET hem de MBT-ESA mimarileri bir arada kullanılmıştır. U-NET'in sonucu otomatik olarak MBT-ESA için girdi olarak kullanılmaktadır. Sistemin değerlendirilmesi için test yazılımında iki kriter belirlenmiştir. Bu kriterler, 3 temel anatomik yapının (iskium, ilium, labrum) tespit edilebilirliğinin kontrolü ve iliumun taban çizgisine paralelliğinin kontrolüdür.

İlk kriter sonucunda 3 temel anatomik yapıdan en az biri tespit edilemezse US görüntüsü analiz edilemez olarak sınıflandırılır ve US görüntüsünün tekrarlanması için uyarı verilir. Üç temel anatomik yapının tespit edilebilirliği MBT-ESA mimarisi ile kontrol edilmektedir. Üç temel anatomik yapı tespit edildiyse, ikinci kriter olan iliumun taban çizgisine paralelliği kontrol edilir.

İkinci kriter değerlendirmesi ilium üzerine odaklanmıştır. İlk olarak iliumun sınırları belirlenmiştir. Daha sonra temel çizgisi ilium'a paralel olarak çizilmiştir. Temel çizgi çizdikten sonra ilium sınırları üzerinde 3 paralel nokta belirlenmektedir. Paralel 3 noktanın taban çizgisine olan uzaklığı ölçülerek, uzaklık tanımlanan eşikten büyükse paralellik yoktur. Bu durumda US görüntüsü analiz edilemez olarak sınıflandırılmaktadır ve program "US görüntüsünü tekrar alın" uyarısını ekranda görüntülemektedir. Uzaklıklar eşik değerinden küçükse temel çizgi iliuma paralel olarak kabul edilir. Bu durumda da görüntü, analiz edilebilir US olarak sınıflandırılmakta ve ekranda bu şekilde görüntülenmektedir.

Geliştirilen iki aşamalı yapay zekâ sistemi sonucunda elde edilen görüntü Şekil 16'da gösterilmiştir. Şekil 16a, eğitim sonucunda tüm anatomik tespit edilmediği ve bu yüzden analiz edilemez US olarak sınıflandırılan US görüntüsü gösterilmektedir. Tüm anatomik yapılar tespit edildikten sonra ilium'un temel çizgisine göre paralelliğinin belirtilen toleranslar dahilinde olup olmadığını kontrol edilmektedir. İlium temel çizgisine paralel olmadığında, görüntü analiz edilemez US olarak sınıflandırılır. Şekil 16b'de gösterildiği gibi ilium'un taban çizgisine paralel olmadığını göstermektedir.

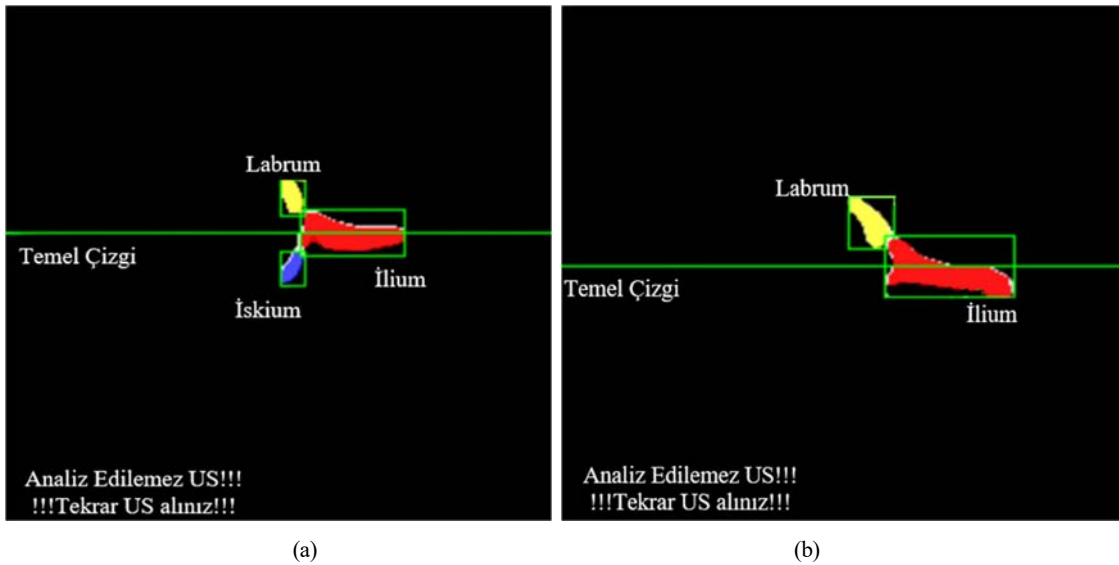
Şekil 17'de birinci ve ikinci kriter kontrollerinin başarıyla tamamlanmasının ardından analiz edilebilir bir US olarak sınıflandırılan US görüntüsünü göstermektedir.



Şekil 17. Analiz edilebilir olarak tespit edilen US görüntüsü (US image detected as analyzable)

4. Sonuçlar ve Tartışmalar (Results and Discussions)

US görüntüleme tekniği, gelişimsel kalça displazisinin tespiti için mükemmel sonuçlar sağlayan güvenli bir tanı aracıdır [32]. Bununla birlikte, gözlemciler arası değişkenlik kalça US görüntülemesinin ölçümünde standartın kaybolmasına neden olabilmektedir. Deneyim düzeyi ve eğitimi, gözlemcilerin yorgunluk, dikkat eksikliği veya yoğun çalışma temposu gibi faktörler, standartın kaybolmasında önemli etkenlerdir.



Şekil 16. Analiz edilemez olarak tespit edilen US görüntüleri (US image detected as unanalyzable)

Tablo 3. Kalça eklemine gelişimsel displazisinin analizine ilişkin önceki çalışmaların karşılaştırılması.

Yıl	Çalışma Adı	Yöntem	Veri seti sayısı	Doğruluk
2019	Li, Q., Zhong, L., Huang [37]	Maske-RCNN	11574	76.73%
2020	Si-Cheng Zhang, Jun Sun [36]	RESNET-101	9081	95.5%
2021	Wook Lee vd. [38]	Maske R-CNN	1243	80.9%
2021	Hareendranathan, A.R. [33]	Maske R-CNN	214	85%
				IoU/88%
2021	Shin vd. [34]	U-NET		Zar Katsayısı/ 0.99
2022	Chen vd. [35]	YOLOv3-tiny	1051	89.51%
2022	Hareendranathan vd. [39]	CNN	2187	91%
2023	Bu Çalışma	U-NET-MBT-ESA	840	96%

Bu çalışmanın literatürdeki diğer çalışmalardan temel farkı, iki farklı yapay zeka mimarisinin birbirine bağlı olarak kullanılmasıdır. Literatürdeki çalışmalarda ya sadece U-Net algoritması ya da sadece MBT-ESA algoritması kullanılmıştır. Literatürde kullanılan iki aşamalı yapılarda da analiz edilebilirlik tespiti üzerine odaklanılmamış aynı zamanda da iki aşamada da aynı yapay zeka mimarisi kullanılmıştır. Ancak bu yaklaşımın bazı dezavantajları vardır. Yeni doğan kalça ultrason görüntüleri çok sayıda benzer yapı içermektedir bu da tek bir mimarinin başarısını kısıtlayabilmektedir.

Bu çalışmada diğer çalışmalardan farklı olarak iki farklı yapay zeka algoritması, U-Net ve MBT-ESA birlikte kullanılmıştır. Bu sayede iki algoritmanın eksiklikleri büyük ölçüde giderilmiştir.

Gerçekleştirilen çalışma ile U-Net mimarisi kullanılarak tespit edilmek istenen anatomik yapıların özellik haritası çıkarılırken aynı zamanda bu özellikleri görüntünün orijinal boyutlarına geri dönüştüren bir yapıya sahiptir. Bu, GKD tanısında US görüntüsünde tespit edilmesi gereken anatomik yapıların doğru şekilde segmente edilmesi ve bölgelerin ayrılması açısından faydalı sağlamaktadır. Konum bilgisini bağlamsal bilgi ile birleştirerek iyi bir segmentasyon haritası tahmin etmek için 3 temel anatomik yapı için gerekli olan genel bilgiyi elde eder. Ancak bu bilgide 3 temel anatomik yapı için tek bir bölge haritası vardır. Bu bölgenin içerisinde hangi alanın ilium 'a hangi bölgenin iskiuma, hangi bölgenin iliak kemiğe ait olduğu bilinmemektedir. Bu yapıların sınırlarının belirlenmesi US görüntüsünün analiz edilebilirliğinin kararını vermek için olmazsa olmazdır. Anatomik sınırlarının belirlenmesi aşamasında tekrar U-NET mimarisi de kullanılabilir ancak bu bazı dezavantajları da beraberinde getirmektedir. U-NET mimarisinin çıktısı, tüm giriş görüntüsü için ikili segmentasyon maskesi içerdiğinden örnek segmentasyonu konusunda başarısı düşük kalmaktadır [40]. Bu nedenle anlamsal segmentasyonla tek bir bölge olarak segmente edilmiş anatomik yapıların sınırlarının tam olarak ayrıştırılması ve yapıların tespit edilip edilmediğinin kontrolü için ikinci aşamada MBT-ESA mimarisi kullanılmıştır. MBT-ESA mimarisi US görüntüsünde örnek segmentasyonu gerçekleştirerek anlamsal segmentasyon ile tek bir bölge olarak ayrışan yapının ayrıştırarak sınırlarını ayırır. Bu sayede 3 anatomik yapının sınırları net şekilde belli olmaktadır. Ayrıca bu sınırların tespiti işlemi de maskeleme işlemi gerçekleştirir ve ilium, iskium ve iliak kemiğe ait alanlarda maskelemiş olmaktadır.

İlk aşamada neden MBT-ESA kullanılmadığı düşünülebilir. İlk aşamada US görüntüleri içerisinde birbirine benzeyen karmaşık yapılar bulundurmaktadır. MBT-ESA mimarisi bu yapıların sınırlarını belirleme ve maskeleme konusunda zorlanmaktadır [41]. Hedef görselin maskesi oluştururken tam maskeleme hatasından dolayı anatomik yapıları tespit edebilmektedir. Bu nedenle önce anlamsal segmentasyon ile US görüntüsü sadeleştirilmekte ve MBT-ESA'nın sadece bu bölgeye odaklanması hedeflenmiştir.

2 aşamalı yapay zekâ sistemi toplam 840 kalça US görüntüsünü analiz etmiştir. Kalça US görüntüsünün okunabilirliğini 0.96 doğrulukla

belirlemiştir ve sistem gözlemciler arası değişkenliği ortadan kaldıracak şekilde tasarlanmıştır. Çalışmanın çeşitli kısıtlamaları vardır. Bu çalışmada kullanılan kalça ultrason veri seti, analiz için yeterli olsa da daha fazla veri kullanılması sistem doğruluğunu artırabilir. Veri seti, farklı hastaların, farklı yaş gruplarının ve farklı etnik kökenlere sahip bireylerin görüntülerini içermelidir. Bunun için, daha geniş bir hasta grubunu kapsayan ve farklı merkezlerden elde edilen veri setleri kullanılabilir.

Gerçekleştirilen çalışma sonuçlarının ve önerilen sistemin klinik ortamda gerçek hasta verileriyle uzun süreli bir tarama izleme süreci doğrultusunda test edilmesi önemlidir. Bu sayede sistemin gerçek dünya koşullarında kullanılabilirliği ve güvenilirliği kanıtlanabilir. Yapılan çalışma ile, doktorların analiz edilebileceğini düşündüğü birçok farklı US görüntüsünü yapay zekânın sonuçlarıyla karşılaştırdı ve bir standart belirlendi. Bu standart, operatörler arasındaki değişkenliği ortadan kaldırdı. Sistemin doğruluğu, veri kümesinin dışından alınan US görüntüleriyle test edildi ve başarısı büyük ölçüde doğrulandı.

Tablo 3'te görüldüğü gibi 2 aşamalı yapay zekâ sistemi diğer çalışmalara göre daha düşük sayıda veri setinde daha iyi sonuç verdiği görülmektedir.

Gelişimsel kalça displazisinin erken teşhisi çok önemlidir. Tanı gecikirse, tedavi daha zor hale gelir. Önerilen sistem, gelişimsel kalça displazisinde gözlemciler arası değişkenliği azaltmayı amaçlamaktadır ve deneyimsiz hekimler için yararlı bir araç olacaktır.

Gelişimsel kalça displazisinin tespiti için alınan kalça US görüntülerinin analiz edilebilirliğini belirlemek için iki aşamalı bir yapay zekâ modeli geliştirilmiştir. Sistemin performansı, gerçek zamanlı uygulamalar için de kullanılabilirliğini göstermektedir. Bu nedenle, GKD taramalarında kalça US görüntülerinin analiz edilebilirliğini belirlemede yardımcı olarak kullanılabilir.

5. Referanslar (References)

1. H. Patel, "Canadian Task Force on Preventive Health Care. Preventive health care, 2001 update: Screening and management of developmental dysplasia of the hip in newborns," CMAJ, 164, 1669-1677, 2001.
2. V. Bialik, G. M. Bialik, S. Blazer, P. Sujov, F. Wiener, and M. Berant, "Developmental dysplasia of the hip: A new approach to incidence," Pediatrics, 103, 93-99, 1999.
3. H. Atalar, U. Sayli, O. Y. Yavuz, I. Uras, and H. Dogruel, Indicators of successful use of the Pavlik harness in infants with developmental dysplasia of the hip, Int. Orthop., 31, 145-150, 2007.
4. W. H. Harris, Etiology of osteoarthritis of the hip, Clin. Orthop. Relat. Res., 213, 20-33, 1986.
5. P. Tomà, M. Valle, U. Rossi, and G. M. Brunenghi, Paediatric hip—ultrasound screening for developmental dysplasia of the hip: A review, Eur. J. Ultrasound, 14, 45-55, 2001.
6. H. Omeroğlu, Use of ultrasonography in developmental dysplasia of the hip, J. Child Orthop., 8 (2), 105-113, 2014.
7. T. Centel, Doğumsal Kalça Çıkığı (DDH) Nedir?, [Online]. Erişim

- Tarihi: [Ziyaret Tarihi: 24 Haziran 2023]. Web Adresi: <https://tuncaycentel.com/ddh/ddhTR7.htm>.
8. H. Dogruel, H. Atalar, O. Y. Yavuz, and U. Sayli, Clinical examination versus ultrasonography in detecting developmental dysplasia of the hip, *Int. Orthop.*, 32, 415–419, 2008.
 9. R. Graf, The diagnosis of congenital hip-joint dislocation by the ultrasonic combbound treatment, *Arch. Orthop. Trauma Surg.*, 97, 117–133, 1980.
 10. S.-W. Lee, H.-U. Ye, K.-J. Lee, W.-Y. Jang, J.-H. Lee, S.-M. Hwang, and Y.-R. Heo, Reply to Çiftçi, S.; Aydin, B.K. Comment on 'Accuracy of New Deep Learning Model-Based Segmentation and Key-Point Multi-Detection Method for Ultrasonographic Developmental Dysplasia of the Hip (DDH) Screening', *Diagnostics*, 12, 7, article 1739, 2022.
 11. J. J. Dias, I. H. Thomas, A. C. Lamont, B. S. Mody, and J. R. Thompson, The reliability of ultrasonographic assessment of neonatal hips, *J. Bone Joint Surg. Br.*, 75, 479–482, 1993.
 12. Y. Lecun, L. Bottou, Y. Bengio, and P. Haffner, Gradient-based learning applied to document recognition, *Proc. IEEE*, 86, 2278–2324, 1998.
 13. D. Golan, Y. Donner, C. Mansi, J. Jaremko, and M. Ramachandran, Fully automating Graf's method for DDH diagnosis using deep convolutional neural networks, in *Lecture Notes in Computer Science*, G. Carneiro, Ed., 10008, Springer, 130–141, 2016.
 14. A. R. Hareendranathan, D. Zonoobi, M. Mabee, D. Cobzas, K. Punithakumar, M. Noga, and J. L. Jaremko, Toward automatic diagnosis of hip dysplasia from 2D ultrasound, in *Proc. IEEE 14th Int. Symp. Biomed. Imaging (ISBI)*, 982–985, 2017.
 15. H. Den, J. Ito, and A. Kokaze, Diagnostic accuracy of a deep learning model using YOLOv5 for detecting developmental dysplasia of the hip on radiography images, *Sci. Rep.*, 13, article 6693, 2023.
 16. S.-W. Lee, H.-U. Ye, K.-J. Lee, W.-Y. Jang, J.-H. Lee, S.-M. Hwang, and Y.-R. Merhaba, Ultrasonografik Gelişimsel Kalça Displazisi (GKD) Taramasında Yeni Derin Öğrenme Modeline Dayalı Segmentasyon ve Anahtar Noktalı Çoklu Tespit Yönteminin Doğruluğu, *Teşhis*, 11, article 1174, 2021.
 17. M. Kinugasa, A. Inui, S. Satsuma, D. Kobayashi, R. Sakata, M. Morishita, I. Komoto, and R. Kuroda, Derin Öğrenmeyi Kullanarak Ultrason Görüntüleme ile Gelişimsel Kalça Displazisinin Tanısı, *Pediatric Orthopedic Dergisi*, 43 (7), e538-e544, 2023.
 18. A. R. Hareendranathan, B. Chahal, S. Ghasseminia, et al., Impact of scan quality on AI assessment of hip dysplasia ultrasound, *J. Ultrasound*, 25, 145–153, 2022.
 19. S.-C. Zhang, H.-L. Ma, X.-W. Sun, et al., Clinical study on ultrasonic artificial intelligence-assisted diagnosis of developmental hip dysplasia in children, Preprint, Research Square, May 8, 2023.
 20. R. Gandhi, R-CNN, Fast R-CNN, Faster R-CNN, YOLO — Object Detection Algorithms: Understanding object detection algorithms, *Towards Data Science*, Jul. 9, 2018. [Online]. Available: <https://towardsdatascience.com/r-cnn-fast-r-cnn-faster-r-cnn-yolo-object-detection-algorithms-36d53571365e>. [Accessed: Apr. 6, 2023].
 21. S. Ren, K. He, R. Girshick, and J. Sun, Faster R-CNN: Towards real-time object detection with region proposal networks, *IEEE Trans. Pattern Anal. Mach. Intell.*, 39, 1137–1149, 2017.
 22. Kadiroğlu Z., Deniz E., Şenyiğit A., A comparison of deep learning models for pneumonia detection from chest x-ray images, *Journal of the Faculty of Engineering and Architecture of Gazi University*, 39 (2), 729-740, 2024.
 23. Üzülmöz S., Çiftçi M.A., Early diagnosis of lung cancer using deep learning and uncertainty measures, *Journal of the Faculty of Engineering and Architecture of Gazi University*, 39 (1), 385-400, 2024.
 24. Yılmaz A., Diagnosing COVID-19 from X-Ray images with using multi-channel CNN architecture, *Journal of the Faculty of Engineering and Architecture of Gazi University*, 36 (4), 1761-1774, 2021.
 25. İsmail, T., "Evaluation of Ultrasonography of the Neonatal Hip," *Journal of the Turkish Orthopedics and Traumatology Association*, 3, no. 3-4, 2004.
 26. Ronneberger, O., Fischer, P., and Brox, T., U-NET: Convolutional Networks for Biomedical Image Segmentation, in *Medical Image Computing and Computer-Assisted Intervention – MICCAI 2015*, N. Navab, J. Hornegger, W. Wells, and A. Frangi, Eds., Springer, 9351, 2015.
 27. He, K., Gkioxari, G., Dollár, P., and Girshick, R., Mask R-CNN, in *Proceedings of the IEEE International Conference on Computer Vision (ICCV)*, 2961–2969, 2017.
 28. Lee, S.-W., Ye, H.-U., Lee, K.-J., Jang, W.-Y., Lee, J.-H., Hwang, S.-M., and Heo, Y.-R., Accuracy of New Deep Learning Model-Based Segmentation and Key-Point Multi-Detection Method for Ultrasonographic Developmental Dysplasia of the Hip (DDH) Screening, *Diagnostics*, 11 (7), 1174, 2021.
 29. Anand, V., Gupta, S., Koundal, D., Nayak, S. R., Barsocchi, P., and Bhoi, A. K., Modified U-NET Architecture for Segmentation of Skin Lesion, 22, 867, 2022.
 30. Rosebrock, A., Intersection over Union (IoU) for Object Detection, *PyImageSearch*, Nov. 7, 2016. [Online]. Available: <https://www.pyimagesearch.com/2016/11/07/intersection-over-union-iou-for-object-detection/>. [Accessed: Apr. 6, 2023].
 31. Tiu, E., Metrics to Evaluate Your Semantic Segmentation Model, *Towards Data Science*, Aug. 10, 2019. [Online]. Available: <https://towardsdatascience.com/metrics-to-evaluate-your-semantic-segmentation-model-6bcb99639aa2>. [Accessed: Apr. 6, 2023].
 32. Tomà, P., Valle, M., Rossi, U., and Brunenghi, G. M., Pediatric Hip—Ultrasound Screening for Developmental Dysplasia of the Hip: A Review, *European Journal of Ultrasound*, 14, 45-55, 2001.
 33. Hareendranathan, A. R., Chahal, B. S., Zonoobi, D., et al., Artificial Intelligence to Automatically Evaluate Scan Quality in Hip Ultrasound, *Journal of the Indian Orthopaedic Association*, 55, 1535–1542, 2021.
 34. Shin, Y., et al., Artificial Intelligence in Musculoskeletal Ultrasound Imaging, *Ultrasonography (Seoul, Korea)*, 40 (1), 30-44, 2021.
 35. Chen, T., Zhang, Y., Wang, B., Wang, J., Cui, L., He, J., and Cong, L., Development of a Fully Automated Graf Standard Plane and Angle Evaluation Method for Infant Hip Ultrasound Scans, *Diagnostics*, 12, 1423, 2022.
 36. Zhang, S.-C., Sun, J., Liu, C.-B., Fang, J.-H., Xie, H.-T., and Ning, B., The Bone & Joint Journal, *The Bone & Joint Journal*, 102-B, no. 11, 1574-1581, 2020.
 37. Li, Q., Zhong, L., Huang, H., Liu, H., Qin, Y., Wang, Y., Zhou, Z., Liu, H., Yang, W., Qin, M., Wang, J., Wang, Y., Zhou, T., Wang, D., Wang, J., Xu, M., and Huang, Y., Auxiliary Diagnosis of Developmental Dysplasia of the Hip by Automated Detection of Sharp's Angle on Standardized Anteroposterior Pelvic Radiographs, *Medicine*, 98, no. 52, article e18500, 2019.
 38. Lee, S.-W., Ye, H.-U., Lee, K.-J., Jang, W.-Y., Lee, J.-H., Hwang, S.-M., and Heo, Y.-R., Accuracy of New Deep Learning Model-Based Segmentation and Key-Point Multi-Detection Method for Ultrasonographic Developmental Dysplasia of the Hip (DDH) Screening, *Diagnostics*, 11 (7), 1174, 2021.
 39. Hareendranathan, A. R., Mabee, M., Chahal, B. S., Dulai, S. K., and Jaremko, J. L., Can AI Automatically Assess Scan Quality of Hip Ultrasound? *Applied Sciences*, 12 (8), 4072, 2022.
 40. Jejurikar, N., et al., What Is the Interobserver Reliability of an Ultrasound-Enhanced Physical Examination of the Hip in Infants? A Prospective Study on the Ease of Acquiring Skills to Diagnose Hip Dysplasia, *Clinical Orthopaedics and Related Research*, 479 (9), 1889-1896, 2021.
 41. Patil, S., Varadarajan, V., Mahadevkar, S., Athawade, R., Maheshwari, L., Kumbhare, S., Garg, Y., Dharrao, D., Kamat, P., and Kotecha, K., Enhancing Optical Character Recognition on Images with Mixed Text Using Semantic Segmentation, *Journal of Sensor and Actuator Networks*, 11, 63, 2022.