



Ortopedi ve travmatolojide yapay zekâ ve segmentasyon ağları

Artificial intelligence and segmentation networks in orthopaedics and traumatology

Zafer Soydan

Nişantaşı Üniversitesi, Ortopedi ve Travmatoloji Ana Bilim Dalı, Bhtclinic İstanbul Tema Hastanesi, İstanbul

Yapay zekâ ağları, tüm teknolojik alanlarda olduğu gibi, modern tıpta da gittikçe daha fazla uygulama alanı bulan ve insan zekâsını oluşturan nöral ağları simüle etmeye çalışan yapılardır. Tıbbi alanlarda özellikle tanısal görüntüleme, yapay zekâ için çok yüksek bir gelişme potansiyeli barındırmaktadır. Çeşitli tıbbi bölümler gibi ortopedi ve travmatolojide de segmentasyon araçlarından faydalanmaktadır. Kas iskelet sisteminin segmentasyonu, bu yapıları değerlendirmek ve olası tıbbi müdahaleleri planlayabilmek için çok önemli bir anahtardır. Görüntülerde var olan çeşitli artefaktlar segmentasyonu zorlaştırmaktadır. Bir görüntü içerisinde, istenilen bölgeyi tanımlayıp ayırt etme anlamına gelen segmentasyon, yapay zekâ ağları tarafından büyük bir başarıyla yapılabilmektedir. Bu ağlar, segmentasyonu insana bağlı kısıtlayıcı faktörlerin etkisinden arındırılmış ve otomatize olduğu için de daha yüksek güvenilirlik ve hız sağlamıştır. Güncel literatürde, bu ağların başarısını gösteren çok sayıda çalışma vardır. Bu ağların kullanımı için çalışma prensiplerinin doğru anlaşılması gereklidir. Bu derlemede ortopedi ve travmatolojide yaygın olarak kullanılan segmentasyon uygulamaları ele alınacak ve ağların genel özellikleri, çalışma prensipleri, işleyiş aşamaları ve sonuçlarının değerlendirilmesi süreçleri ortaya konacaktır.

Anahtar sözcükler: yapay zekâ ağları; segmentasyon; derin öğrenme

Artificial Intelligence networks are structures that attempt to simulate the neural networks that comprise human intelligence and are increasingly finding applications in modern medicine, as in all technological fields. In medical fields, especially diagnostic imaging, there is a very high development potential for artificial intelligence. Like various medical departments, orthopedics and traumatology also benefit from segmentation tools. Segmentation of the musculoskeletal system is a crucial key to evaluating these structures and planning possible medical interventions. Various artifacts present in images make segmentation difficult. Segmentation, which means identifying and separating the desired region from an image, can be performed with great success by artificial intelligence networks. These networks make segmentation free from the influence of human constraints and provide higher reliability and speed because they are automated. In the current literature, there are numerous works demonstrating the success of these networks. The use of these networks requires a proper understanding of their working principles. In this review, the segmentation applications commonly used in orthopedics and traumatology will be discussed, and the general characteristics of the networks, their working principles, the stages of operation, and the evaluation of the results will be presented.

Key words: artificial neural networks; segmentation; deep learning

Segmentasyon bir nesnenin şeklini belirlemek için içerdiği piksellerin sınıflandırmasını da içeren bir analiz ve temsil sürecidir.^[1,2] Bu işlem girdi olarak kullanılan resmi, ilgilenilen bölge (rol) olarak belirlenen alan ile yüksek korelasyon gösterecek şekilde bölgelerine ayırır. Segmentasyonun amacı, anatomiyi incelemek, ilgilenilen bölgeyi tanımlamak için verilen bir giriş görüntüsünü anlamlı bir biçimde temsil etmektir. Bu işlem manuel olarak da yapılabilir ancak

buna dair düşük gözlemci içi ve gözlemciler arası güvenilirlik, yapan kişinin tecrübe düzeyine bağlılık gibi kısıtlamaları mevcuttur, bu sebeple bu sürecin otomatize edilmesi ihtiyacı doğmuştur.^[1,3] İlk segmentasyon modelleri, eşikleme, kenar tabanlı, bölge tabanlı teknikler ve graf tabanlı teknikleri içeren geleneksel resim işleme tekniklerinden köken almaktaydı.^[4-7] Son yıllarda ise daha iyi performans gösteren modeller oluşturan derin öğrenme (*deep learning*, DL) ağları öne çıkmıştır.

İletişim / Contact: Dr. Öğr. Üyesi Zafer Soydan • **E-posta / E-mail:** zsoydan@gmail.com

ORCID iD: Zafer Soydan, 0000-0001-6387-8628

Geliş / Received: 29 Ağustos 2023 • **Revizyon / Revised:** 7 Kasım 2023, 21 Kasım 2023 • **Kabul / Accepted:** 23 Kasım 2023

Derin öğrenme ağıları çok tabakalı nöral ağlardan oluşan yapılardır.^[8] Her tabaka kendine gelen veriden özgün bir bilgi çıkarır, öncekinden aldığı bilgiyle kombine eder, sonraki tabakaya aktarır. Böylece komplike özelliklerin çıkarımı mümkün olur. Bu ağ yapıları segmentasyon için gittikçe popüler hâle gelen bir uygulama alanıdır.

Son yıllarda, anatomik yapıların segmentasyonu için çeşitli derin öğrenme araçları uygulanmış ve bu sayede klinik uygulamalar için yüksek hassasiyetli değerlendirme ve geniş bir yelpazede destek sağlanmıştır. Kas-iskelet sisteminin segmentasyonu için derin öğrenme araçları, bilgisayar yardımıyla cerrahi, tedavi karar ve planlaması, *biomarker* (biyolojik belirteç) tanımlama, doku işaretleme, model rekonstrüksiyon, yapay gerçeklik, yapısal özelliklerin analiz ve nicelendirilmesi, vücut içerik analizi, kemik yapı değerlendirme gibi çeşitli alanlardaki uygulamalarla klinisyenlere yardımcı olmak için önerilmiştir.^[9-20]

Bilgisayar destekli ortopedi ve travmatoloji alanında ki cerrahi çeşitli dokuları ilgilendiren geniş bir hastalık ve hasta yelpazesini kapsar. Bu dokuların medikal görsellerinin segmentasyonu, direkt grafi (X-ray, XR), bilgisayarlı tomografi (BT) ve manyetik rezonans (MR) görüntülerindeki gri değerlerin benzerliği sebebiyle zor olabilir.

Derin öğrenme ağlarının başarısı veri miktarına (*big data*) bağlıdır. Dolayısıyla, küçük veri seti ilgili aşırı uyum gösterme (*overfitting*) gibi problemleri aşmak için bazı metodlar geliştirilmiştir. Veri artırma (data augmentasyon) prosedürleri mevcut veriyle (datayla) ilgili geliştirmeler sunarken, çekişmeli üretici ağ (*generative adversarial network*, GAN) ağları veriye ait intrinsik dağılımları öğrenerek tamamen yeni sentetik veri setleri oluşturmaya imkân sağlar.^[15,21] Bir diğer yöntem ise transfer öğrenme olarak bilinir, daha önceden var olan eğitilmiş bir algoritmayı yeni bir veri setiyle kullanarak eğitmeyi sağlar.^[22] Veri setiyle ilgili en büyük problemlerden bir diğeri de farklı teknik özelliklere sahip cihazlardan elde edilen görüntülerin varyasyonudur. Bunu aşmak ve verilerde aynılık (*uniformity*) sağlamak için normalizasyon/histogram eşitleme ve yoğunluk/boyut bazlı filtreleme gibi ön işleme teknikleri kullanılır.^[23] Bunların kullanıldığı çalışmalara örnekler Tablo 1'de verilmiştir.

Verilerin eğitim, değerlendirme ve test gruplarına ayrılması için de çeşitli yaklaşımlar geliştirilmiştir. Bu veri grupları birbirinden farklılaştıkça ağ başarımı belirgin

şekilde düşebilir. Genel olarak eğitim/değerlendirme/test gruplarının ayrıştırılması orantılı olarak gerçekleştirilir. Ortalama test hatasının belirlenmesinde k-katlı çapraz değerlendirmesi kullanılır ancak eğitim verisi miktarının yeterli sayıda olduğu durumlarda buna gerek olmadığını savunan yazarlar da vardır.^[24,25]

Kamiya ve ark, BT görüntülerinde kas segmentasyonu için hesaplamalı (*computational*) anatomi tabanlı kas segmentasyonu ve derin öğrenme tabanlı kas segmentasyonu olmak üzere iki farklı yöntem geliştirmişlerdir.^[26] Derin öğrenme ağı olarak FCN8s ağını kullanmışlar ve ortalama olarak hesaplamalı anatomi tabanlı metotta %78,5, derin öğrenme ağı metodunda ise %82,8 başarı bildirmişlerdir. Derin öğrenme ağı, sadece 10 hastanın veri setiyle eğitim yapılmasına rağmen oldukça iyi sonuç vermiştir.^[27] Tablo 2'de çeşitli vücut bölgeleri için farklı görüntü modaliteleri kullanılan segmentasyon çalışmalarından örnekler verilmiştir.

Yıllar boyunca kas iskelet sistemi segmentasyonu için çeşitli ağ yapıları geliştirilmiştir. Bunlar genel olarak dört alt grupta toplanır. Evrişimli sinir ağı (*convolutional neural network*, CNN), (*Fully/Regional*), *Encoder/Decoder Network* (U-net,V-net), *Regional CNN* (bölge tabanlı evrişimli sinir ağı, *fast region-based convolutional neural network*, RCNN, *Faster RCNN*, *Mask RCNN*) ve *DeepLab V1* (önceden eğitilmiş ResNet/VGG16 kullanır), V2, V3 ve V3+. Bunların en popüler olanı Ronneberger ve ark. tarafından geliştirilen U-net isimli CNN yapısı ve bu yapının U-net++, *Attention U-net* ve *Stripping Down-U-net* gibi modifikasyonlarıdır.^[35] Bu ağların her birinin belirli avantajları ve dezavantajları vardır. Bir çalışmada U-net ağının araştırmacıların %60'ı tarafından kullanıldığı bildirilmiştir.^[36] Bir ağın segmentasyon başarımlarını arttırmak için eğitim verisinin spesifik alanlarına odaklanmayı sağlayan ve dikkat mekanizmaları olarak isimlendirilen yapısal dizayn stratejileri de önerilmiştir.^[37,38] Veri seti ve ağ yapısı tanımlandıktan sonra ağın eğitimi ve sonuçların değerlendirilmesi gereklidir.

Tablo 2. Çeşitli vücut bölgelerinin segmentasyonunda kullanılan modaliteler

Bölge	Görüntü Modalitesi	Referans
Alt ekstremite	Manyetik rezonans görüntüleme	[3,11]
	Ultrasonografi	[10,28,29]
	Bilgisayarlı tomografi	[1,30,31]
	Direkt grafi	[32]
Üst ekstremite	Manyetik rezonans görüntüleme	[33]
	Ultrasonografi	[34]
	Direkt grafi	[20]
Pelvis	Bilgisayarlı tomografi	[17]

Tablo 1. Ön işleme teknikleri

Ön İşleme Tekniği	Referans
Normalizasyon/histogram eşitleme	[2,16-18,20]
Yoğunluk/boyut tabanlı filtreleme	[10,12,16,20]

Tablo 3. Performans indeksleri ve kullanıldıkları çalışmalar

Performans İndeksi	Referanslar
DSC	[1-3,10-12]
HD	[1,2,11,12,15,28,42]
IoU	[2,3,9,10,13,14,28]
SD	[1,2,41,42]

DSC: Zar benzerlik katsayısı, *dice similarity coefficient*; HD: Hausdorff mesafesi, *Hausdorff distance*; IoU: *Intersection over union*; SD: Yüzey mesafesi, *surface distance*.


Bunun için çeşitli skorum sistemleri mevcuttur. Eğitim esnasında beklenen çıktı ile tahmin edilen çıktı arasındaki fark kayıp fonksiyonu tarafından hesaplanır. Doğrulama kaybı olarak isimlendirilen değer platoya ulaştığında öğrenme oranı düşmeye başlar.^[1] Kayıp fonksiyonlarından en sık kullanılanları DICE çapraz entropi ve bu ikisinin kombinasyonlarıdır.^[1,3,11,13,15,16,39,40,41] Sonuçların değerlendirilmesi için de çeşitli performans indeksleri kullanılır. En çok kullanılan indeksler DICE indeksi (DSC), Jaccard indeksi (IoU), Hausdorff mesafesi (*Hausdorff distance*, HD) ve yüzey mesafesi (*surface distance*, SD) indeksleridir. HD ve SD indeksleri genellikle 3 boyutlu (*3-dimentional*, 3D) modellerin ölçümleri için kullanılır. Tablo 3'te bu indeksler ve kullanıldıkları çalışmalardan örnekler verilmiştir.

Ağ performansını değerlendirmek için önerilen diğer bir ölçüt de tahmin süreleridir. Bu süreler donanımla doğrudan ilişkilidir.^[43] Bu zamanlama eforu açısından,

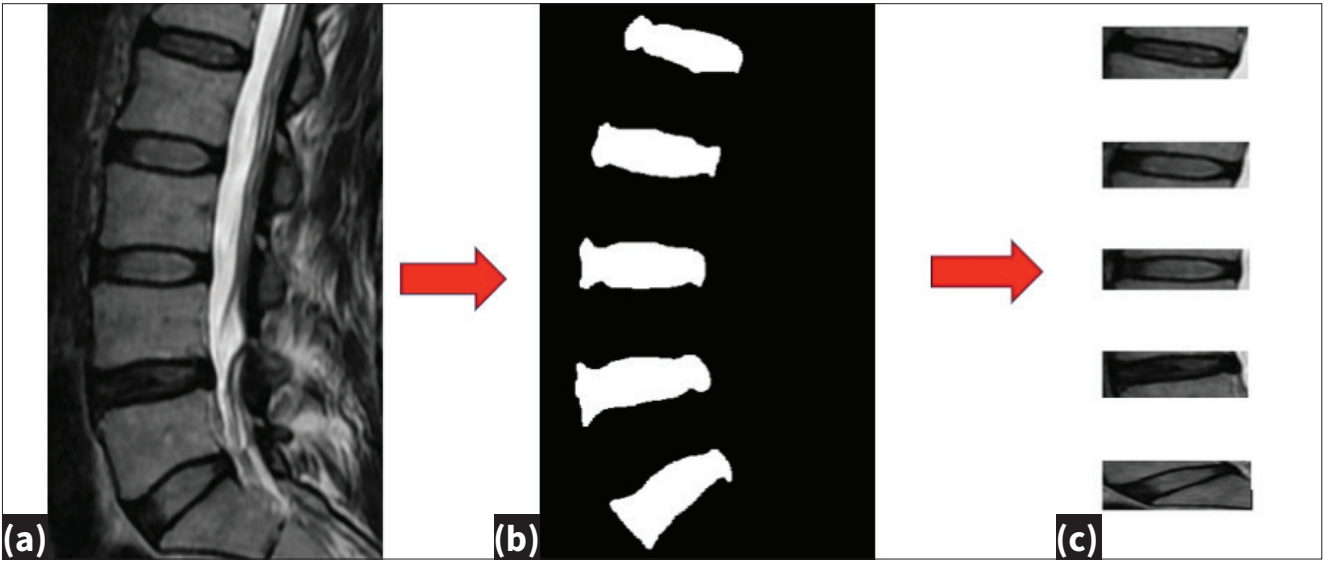
model optimizasyonunu sağlamak için kullanılan *bayesian* optimizasyonu gibi metotlarla ağ hiperparametrelerinin ayarlanması gerekebilir.^[2] Tüm bu aşamalardan sonra etiketleme hatalarını düzeltmek ve daha kesin sonuçlar elde etmek için işlem-sonrası operasyonlar ismi verilen düzenlemeler kullanılabilir. Bunların en yaygın olanları morfolojik operasyonlar ve boyut eşikleme işlemleridir.^[15-18]

U-net ağı kullanılarak lomber intervertebral diskleri segmente etmek için yapılan bir çalışmadaki eğitim ve değerlendirme aşamaları gösterilmiştir. Şekil 1'de gösterilen orijinal veri üzerinde, kullanıcı tarafından *image J* yazılımı kullanarak ilgili alan işaretlenmiştir. Bu şekilde işaretlenen yeteri kadar veri ile U-net ağı eğitilmiş ve U-net ağı her bir veri üzerinde nereyi ilgili alan olarak tanımlaması gerektiğini öğrenmiştir. Şekil 2'de, eğitimi tamamlanmış olan U-net ağına yeni bir veri verildiğinde, ağ tarafından oluşturulan maske ve bu maske sayesinde ilk veriden başarıyla segmente edilen diskler gösterilmiştir. Bu diskler aynılık sağlama açısından, sığacağı minimum dikdörtgen ile çerçevelenip yatay hâle getirilmiştir.^[44]

Kas iskelet sistemi yapılarının, farklı görüntü modaliteleri (BT, MR, ultrasonografi, XR) ile elde edilen görüntülerde otomatize edilmiş segmentasyonu için son yıllarda çok çeşitli çözümler geliştirilmiştir. Kullanılan ağların klinikte karşılaşılan veri çeşitliliğini simüle edebilmek amacıyla farklı teknik özelliklere sahip görüntüleme cihazlarının verileri ile eğitim-doğrulama-değerlendirme işlemleri yapılması, veri dağılımının aynılığının sağlanması, ve



Şekil 1. U-net eğitim verisinin hazırlanışı. Orijinal veri (a), *image J* ile oluşturulan eğitim verisi (b).



Şekil 2. U-net ađı ile yapılan bir segmentasyon alıřmasının ařamaları. Segmente edilecek veri (a), eđitilmiş olan U-net ađının oluřturduđu maske (b), maske ile segmente edilen diskler (c).

sonuların deđerlendirilmesinde oluřabilecek hataların azaltılması iin n iřlemlerin kullanılması gerekebilir.^[36] Byk miktarda veriyle alıřmak nemlidir ancak veri yetersizliđi ve dzensizliđi sz konusu ise veri arttırma ya da veri ykseltme, n ve art iřlemlerin kullanılması yntemleriyle veri kaynaklı problemleri ařmak mmkndr. Derin đrenme ađları bir veriden ok paralı bilgi elde etmeyi sađlayan yapılardır, bu sebeple derin đrenme, kas iskelet sistemi bozuklukları iin insan algısının kısıtlılıklarını ařan yeni bir *biomarker* olarak dřnlebilir. Pratikte segmentasyon araları ile donatılmış tıbbi cihazlar, belirli blgelerin tedavisinin planlamasında ve tedavi etkisinin izlenmesinde klinisyenlere yardımcı olabilir.

KAYNAKLAR

- Balagopal A, Kazemifar S, Nguyen D, Lin MH, Hannan R, Owrangi A, et al. Fully automated organ segmentation in male pelvic ct images. *Phys Med Biol* 2018;63:245015. [Crossref](#)
- Das P, Pal C, Acharyya A, Chakrabarti A, Basu S. Deep neural network for automated simultaneous intervertebral disc (IVDs) identification and segmentation of multi-modal MR images. *Comput Methods Programs Biomed* 2021;205:106074. [Crossref](#)
- Burton W 2nd, Myers C, Rullkoetter P. Semi-supervised learning for automatic segmentation of the knee from MRI with convolutional neural networks. *Comput Methods Programs Biomed* 2020;189:105328. [Crossref](#)
- Senthilkumaran N, Vaithegi S. Image segmentation by using thresholding techniques for medical images. *Int J Comput Sci Eng* 2016;6(1):1-13. [Crossref](#)
- Fabijańska A. Variance filter for edge detection and edge-based image segmentation. *Perspective Technologies and Methods in MEMS Design IEEE*, 2011.
- Liu T, Xu H, Jin W, Liu Z, Zhao Y, Tian W. Medical image segmentation based on a hybrid region-based active contour model. *Comput Math Methods Med* 2014;2014:890725.
- Bragantini J, Martins SB, Fernandez CC, Falcao AX, et al. Graph-based image segmentation using dynamic trees. *Iberoamerican Congress on Pattern Recognition*. Cham: Springer International Publishing, 2018. [Crossref](#)
- Kim P. *MATLAB Deep Learning*; Apress: New York, NY, USA, 2017. [Crossref](#)
- Alsınan AZ, Patel VM, Hacihaliloglu I. Automatic segmentation of bone surfaces from ultrasound using a filter-layerguided CNN. *Int J Comput Assist Radiol Surg* 2019;14:775-83. [Crossref](#)
- Kompella G, Antico M, Sasazawa F, Jeevakala S, Ram K, Fontanarosa D, et al. Segmentation of femoral cartilage from knee ultrasound images using Mask R-CNN. *Proc Annu Int Conf IEEE Eng Med Biol Soc EMBS* 2019;966-9. [Crossref](#)
- Norman B, Padoia V, Majumdar S. Use of 2D U-Net convolutional neural networks for automated cartilage and meniscus segmentation of knee MR imaging data to determine relaxometry and morphometry. *Radiol* 2018;288:177-85. [Crossref](#)
- Torosdaglı N, Liberton DK, Verma P, Sincan M, Lee JS, Bagci U. Deep geodesic learning for segmentation and anatomical landmarking. *IEEE Trans Med Imaging* 2019;38(4):919-31. [Crossref](#)
- Lo Giudice A, Ronsivalle V, Spampinato C, Leonardi R. Fully automatic segmentation of the mandible based on convolutional neural networks (CNNs). *Orthod Craniofac Res* 2021;24 Suppl 2:100-7. [Crossref](#)
- Lahoud P, Diels S, Niclaes L, Van Aelst S, Willems H, Van Gerven A, et al. Development and validation of a novel artificial intelligence driven tool for accurate mandibular canal segmentation on CBCT. *J Dent* 2022;116:103891. [Crossref](#)

15. Nikan S, Van Osch K, Bartling M, Allen DG, Rohani SA, Connors B, et al. PWD-3DNet: A deep learning-based fully-automated segmentation of multiple structures on temporal bone CT scans. *IEEE Trans Image Process* 2021;30:739-53. [Crossref](#)
16. Kim DH, Jeong JG, Kim YJ, Kim KG, Jeon JY. Automated vertebral segmentation and measurement of vertebral compression ratio based on deep learning in X-Ray images. *J Digit Imaging* 2021;34(4):853-61. [Crossref](#)
17. Hemke R, Buckless CG, Tsao A, Wang B, Torriani M. Deep learning for automated segmentation of pelvic muscles, fat, and bone from CT studies for body composition assessment. *Skeletal Radiol* 2020;49(3):387-95. [Crossref](#)
18. Zopfs D, Bousabarah K, Lennartz S, Santos DPD, Schlaak M, Theurich S, et al. Evaluating body composition by combining quantitative spectral detector computed tomography and deep learning-based image segmentation. *Eur J Radiol* 2020;130:109153. [Crossref](#)
19. Krishnaraj A, Barrett S, Bregman-Amitai O, Cohen-Sfady M, Bar A, Chetrit D, et al. Simulating dual-energy X-Ray absorptiometry in CT using deep-learning segmentation cascade. *J Am Coll Radiol* 2019;16(10):1473-9. [Crossref](#)
20. Gao Y, Zhu T, Xu X. Bone age assessment based on deep convolution neural network incorporated with segmentation. *Int J Comput Assist Radiol Surg* 2020;15(12):1951-1962. [Crossref](#)
21. Zaman A, Park SH, Bang H, Park CW, Park I, Joung S. Generative approach for data augmentation for deep learning-based bone surface segmentation from ultrasound images. *Int J Comput Assist Radiol Surg* 2020;15(6):931-41. [Crossref](#)
22. Hudson M, Martin B, Hagan T, Demuth HB. *Deep Learning Toolbox™ User's Guide*; The MathWorks Inc. Natick, MA, USA, 1992.
23. Dey, N. Uneven illumination correction of digital images: A survey of the state-of-the-art. *Optik* 2019;183:483-95. [Crossref](#)
24. Goodfellow IJ, Bengio Y, Courville A. *Deep Learning*; MIT Press: Cambridge, MA, USA, 2016.
25. Rampun A, López-Linares K, Morrow PJ, Scotney BW, Wang H, Ocaña IG, et al. Breast pectoral muscle segmentation in mammograms using a modified holistically-nested edge detection network. *Med Image Anal* 2019;57:1-17. [Crossref](#)
26. Kamiya N. Muscle Segmentation for orthopedic interventions. *Adv Exp Med Biol* 2018;1093:81-91. [Crossref](#)
27. Zhou X, Ito T, Takayama R, Wang S, Hara T, Fujita H. Three-dimensional CT image segmentation by combining 2D fully convolutional network with 3D majority voting, proceeding of workshop on the 2nd Deep Learning in Medical Image Analysis (DLMA) in MICCAI 2016. LNCS 10008:111-20. [Crossref](#)
28. Chanti DA, Duque VG, Crouzier M, Nordez A, Lacourpaille L, Mateus D. IFSS-net: Interactive few-shot siamese network for faster muscle segmentation and propagation in volumetric ultrasound. *IEEE Trans Med Imaging* 2021;40(10):2615-28. [Crossref](#)
29. Antico M, Sasazawa F, Dunnhofer M, Camps SM, Jaiprakash AT, Pandey AK, et al. Deep learning-based femoral cartilage automatic segmentation in ultrasound imaging for guidance in robotic knee arthroscopy. *Ultrasound Med Biol* 2020;46(2):422-35. [Crossref](#)
30. Chen F, Liu J, Zhao Z, Zhu M, Liao H. Three-dimensional feature-enhanced network for automatic femur segmentation. *IEEE J Biomed Health Inform* 2019;23(1):243-52. [Crossref](#)
31. Ju Z, Wu Q, Yang W, Gu S, Guo W, Wang J, et al. Automatic segmentation of pelvic organs-at-risk using a fusion network model based on limited training samples. *Acta Oncol* 2020;59(8):933-9. [Crossref](#)
32. Kim YJ, Lee SR, Choi JY, Kim KG. Using convolutional neural network with taguchi parametric optimization for knee segmentation from x-ray images. *Biomed Res Int* 2021;2021:5521009. [Crossref](#)
33. Medina G, Buckless CG, Thomasson E, Oh LS, Torriani M. Deep learning method for segmentation of rotator cuff muscles on MR images. *Skeletal Radiol* 2021;50(4):683-92. [Crossref](#)
34. Folle L, Meinderink T, Simon D, Liphardt AM, Krönke G, Schett G, et al. Deep learning methods allow fully automated segmentation of metacarpal bones to quantify volumetric bone mineral density. *Sci Rep* 2021;11(1):9697. [Crossref](#)
35. Ronneberger O, Fischer P, Brox T. *U-Net: Convolutional Networks for Biomedical Image Segmentation*; Springer: Cham, Switzerland, 2015. [Crossref](#)
36. Bonaldi L, Pretto A, Pirri C, Ucheddu F, Fontanella CG, Stecco C. Deep learning-based medical images segmentation of musculoskeletal anatomical structures: A survey of bottlenecks and strategies. *Bioengineering (Basel)* 2023;10(2):137. [Crossref](#)
37. Byra M, Wu M, Zhang X, Jang H, Ma YJ, Chang EY, et al. Knee menisci segmentation and relaxometry of 3D ultrashort echo time cones MR imaging using attention U-Net with transfer learning. *Magn Reson Med* 2020;83(3):1109-22. [Crossref](#)
38. Xue YP, Jang H, Byra M, Cai ZY, Wu M, Chang EY, et al. Automated cartilage segmentation and quantification using 3D ultrashort echo time (UTE) cones MR imaging with deep convolutional neural networks. *Eur Radiol* 2021;31(10):7653-63. [Crossref](#)
39. Gaj S, Yang M, Nakamura K, Li X. Automated cartilage and meniscus segmentation of knee MRI with conditional generative adversarial networks. *Magn Reson Med* 2020;84(1):437-49. [Crossref](#)
40. Awan MJ, Rahim MSM, Salim N, Rehman A, Garcia-Zapirain B. Automated knee MR images segmentation of anterior cruciate ligament tears. *Sensors (Basel)* 2022;22(4):1552. [Crossref](#)
41. Latif MHA, Faye I. Automated tibiofemoral joint segmentation based on deeply supervised 2D-3D ensemble U-Net: Data from the osteoarthritis initiative. *Artif Intell Med* 2021;122:102213. [Crossref](#)

42. Zhou GQ, Huo EZ, Yuan M, Zhou P, Wang RL, Wang KN, et al. A single-shot region-adaptive network for myotendinous junction segmentation in muscular ultrasound images. *IEEE Trans Ultrason Ferroelectr Freq Control* 2020;67(12):2531-42. [Crossref](#)
43. Ackermans LLGC, Volmer L, Wee L, Brecheisen R, Sánchez-González P, Seiffert AP, et al. Deep learning automated segmentation for muscle and adipose tissue from abdominal computed tomography in polytrauma patients. *Sensors (Basel)* 2021;21(6):2083. [Crossref](#)
44. Soydan Z, Bayramoglu E, Karasu R, Sayin I, Salturk S, Uvet H. An automatized deep segmentation and classification model for lumbar disk degeneration and clarification of its impact on clinical decisions. *Global Spine J* 2023;12:21925682231200783. [Crossref](#)