



Konvolüsyonel sinir ağlarının total kalça artroplastisinde kullanımı

Use of convolutional neural networks in total hip arthroplasty

Cemil Yıldız, Ahmet Metin Özsezen

Sağlık Bilimleri Üniversitesi Gülhane Tıp Fakültesi, Ortopedi ve Travmatoloji Ana Bilim Dalı, Ankara

Yapay zekâ uygulamaları, günlük hayatımızda birçok alanda kullanılmaya başlamıştır. Derin öğrenme tekniklerinden biri olan konvolüsyonel sinir ağları görüntü tanıma ve değerlendirme yetenekleri ile tıbbi verilerin değerlendirilmesinde gelecek vadetmektedir. Aynı zamanda insan gücünün analiz kapasitesini aşan büyüklükte veri tabanlarını kısa süre içinde değerlendirebilme potansiyeline sahiptir. Bu yazının amacı konvolüsyonel sinir ağlarının çalışma mantığını açıklamak ve aynı zamanda total kalça artroplastisinde uygulandığı örnekleri incelemektir. Konvolüsyonel sinir ağları fikri 1959'da ortaya atılmış olsa da, bilgisayar işlem gücündeki gelişmeler sonucunda son 10 yılda büyük atılım göstermiştir. Görüntü tanıma gücü; insan müdahalesi olmadan görüntüleri sınıflandırabilmesi, büyük veri setlerini değerlendirebilmesi ile tıbbi görüntüleme alanında kullanımı yaygınlaşmıştır. Tıbbi görüntüleme alanında kullanım hedefleri; tetkik miktarını azaltmak, insan faktörü nedeniyle oluşan yanlılığın azaltılması, daha doğru tanımlara ulaşmak ve maliyet-etkin sistemler geliştirmek olarak örneklendirilebilir. Total kalça artroplastisi alanında da ameliyat öncesi planlama, ameliyat sırasında ve ameliyat sonrası dönemde başarılı uygulamalar geliştirilmiştir. Ameliyat öncesi planlamada dizilimin değerlendirilmesi, asetabuler ve femoral yerleşim yerlerinin belirlenmesi, komponent büyüklüklerinin saptanması, revizyon cerrahilerinde var olan implantların marka ve modelinin belirlenmesi, ameliyat içinde femoral komponentin (bileşenin) yerleştirilmesi esnasında çekiç seslerinin değerlendirilmesi ile periprostetik kırık oluşma riskinin algılanması, ameliyat sonrası dönemde implant yerleşimlerinin ve aseptik gevşemenin saptanması, total kalça artroplastisinde konvolüsyonel sinir ağları ile çalışılan konulara örnek verilebilir. Konvolüsyonel sinir ağları ile geliştirilen algoritmalar total kalça artroplastisinin her aşamasında pratiğimizi etkileyecek çözümler sunmaktadır. Ancak rutin kullanıma girmeleri için daha geniş veri setleri ve etik problemlere neden olmaması için daha açıklanabilir modeller geliştirilmelidir.

Anahtar sözcükler: yapay zekâ; derin öğrenme; konvolüsyonel sinir ağları; evrimsel sinir ağları; total kalça artroplastisi

Artificial intelligence applications have become a part of our daily life. Deep learning methods like convolutional neural networks are promising in the evaluation of processing medical data, with their image recognition and evaluation capabilities. At the same time, it has the potential to evaluate databases that exceed the analysis capacity of human power. The aim of this article is to explain the working logic of convolutional neural networks and also to examine the examples of their application in total hip arthroplasty. Although the idea of convolutional neural networks was introduced in 1959, it has made a great breakthrough in the last 10 years as a result of developments in computer science. Its use in the field of medical imaging has become widespread with its image recognition power, classification of images without human intervention, and evaluation of large data sets. The goals of use in the field of medical imaging are, reducing the amount of radiological workups, reducing the bias caused by the human factor, reaching more accurate diagnoses, and developing cost-effective systems. Successful applications have been developed in the field of total hip arthroplasty. In preoperative planning, determination of acetabular and femoral component placement, evaluation of the alignment, determination of component sizes, detecting the brand and model of the existing implants for revision surgeries, intraoperatively with the evaluation of the hammer sounds during the placement of the femoral component, predicting the risk of periprosthetic fracture, post-operatively, implant placements, detection of aseptic loosening from plain radiographs can be given as examples of the studies with convolutional neural networks in total hip arthroplasty. Algorithms developed with convolutional neural networks offer solutions that will affect our daily practice. However, in order not to cause ethical problems, more explainable models should be developed and for the development of more accurate algorithms, larger datasets should be obtained.

Key words: artificial intelligence; deep learning; convolutional neural networks; total hip arthroplasty

İletişim / Contact: Prof. Dr. Cemil Yıldız • **E-posta / E-mail:** cemilyildiz@icloud.com

ORCID ID: Cemil Yıldız, 0000-0001-7526-6071 • Ahmet Metin Özsezen, 0000-0002-2298-021X

Geliş / Received: 17 Kasım 2021 • **Kabul / Accepted:** 19 Aralık 2021

Son yıllarda artan şekilde yaygınlık kazanan ve yaşamımızın her alanına dokunan yapay zekâ uygulamaları, hayatımızı etkileyen birçok teknolojiye olduğu gibi (yüz tanıma, çeviri, ses tanıma, müzik ve benzeri), tıbbın her alanında ve bizim özel ilgi alanımız olan kas iskelet sistemi hastalıklarında birçok uygulama ile pratiğimize girmektedir.^[1-5] Gelişmiş donanım ve yazılım imkânları ve bulut tabanlı çözümler sonucunda radyografî görüntüleri, raporları, takip ve ameliyat notları gibi neredeyse tüm tıbbi verilerin dijitalleşmesi ile geniş veri tabanları oluşmaya başlamıştır. Çok değerli ancak her geçen gün artan miktardaki bu verilerin analizi insan gücünü aşmaktadır. Aynı zamanda analizlerin içinde insan faktörünün bulunması doğal olarak tutarsızlıklara ve yanlı değerlendirmelere de yol açmaktadır. Tam bu aşamada yapay zekâ, geniş veri setlerinden insan gücünün veya zamanının değerlendirmek için yeterli olmadığı analizleri gerçekleştirme potansiyeli taşımaktadır.^[5]

Bir yapay zekâ tekniği olan konvolüsyonel (evrimsel) sinir ağları (KSA), görüntü işleme (*image processing*) ve bilgisayar görüşü (*computer vision*) uygulamalarında en önemli yapay sinir ağı mimarilerindedir (Şekil 1). Görüntü değerlendirme, obje tanıma, görüntüleri sınıflandırma, büyük verileri işleyebilme ve görüntüleri tanıma becerileri; son yıllarda tıbbi görüntülemenin öne çıktığı branşlarda ilgi odağı olmaktadır.^[6] KSA kullanarak fundus görüntüleri üzerinden diyabetik retinopatilerin saptanması^[7], lezyonların fotoğraflarından cilt kanserlerinin sınıflandırılması^[8] ve meme kanserinde patolojik preparatlardan lenf nodu metastazlarının saptanması^[9] gibi konularda uzman düzeyinde sonuçlar çıkarabilen algoritmalar, bahsi geçen uygulamalara birkaç örnek olarak sıralanabilir.



Şekil 1. Yapay zekâ alt birimleri (KSA: Konvolüsyonel sinir ağları).

Görüntüleme, ortopedi ve travmatoloji alanının pratiğinde hem tanı hem de tedavide vazgeçilmez bir bileşendir. Direkt grafi üzerinden vertebra, femur ve proksimal humerus kırıklarının saptanması^[10-12], manyetik rezonans (MR) görüntülerinde servikal spinal kord yaranmalarının saptanması^[13], ön kol radyografilerinden üç boyutlu (3B) görüntülerin elde edilmesi^[14], MR görüntüleri üzerinden kırık dokusunun segmentasyonu ve kalınlığının kantitatif olarak ölçülmesi^[15], tomografi görüntülerinde metal nedeniyle oluşan kirliliğin giderilerek görüntünün yeniden oluşturulması^[16], pelvik radyografilerden gelişimsel kalça displazisinin tanınması^[17] örnekler arasında gösterilebilir.

Bu yazımın amacı, tıbbi verilere bakış açımızı değiştiren konvolüsyonel sinir ağlarının çalışma şeklini tanımlamak ve total kalça artroplastisi alanındaki örnekleri incelemektir.

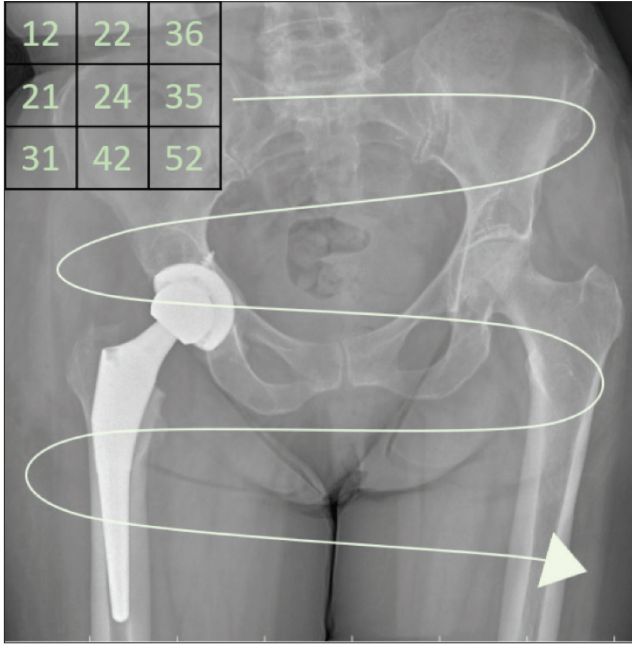
TARİHÇE

1959 yılında David Hubel ve Torsten Wiesel'in görüntü örüntülerini tanımak için ortaya attığı basit ve karmaşık hücre teorisi, 1980'de Fukushima ve 90'lı yıllarda LeCun'un katkıları ile gelişim göstermiştir.^[18] Ancak asıl atılımını "graphic processing unit (GPU)" kullanımı ile AlexNet'in 2012'de konvolüsyonel sinir ağları ile ImageNet sınıflandırma çalışması ile gerçekleştirmiştir.^[19] Günümüzde Google tarafından yapay sinir ağları için geliştirilen tensor işleme üniteleri (*tensor processing unit*) gibi hızlandırıcılar ile daha yaygın kullanım alanı bulmaktadır.

KONVOLÜSYONEL SİNİR AĞLARI NASIL ÇALIŞIR?

Konvolüsyonel sinir ağlarının çalışma sistemi iki bölüm şeklinde tanımlanabilir. Bunlardan ilki, görüntüden karakteristik özelliklerinin çıkartılması; ikinci bölüm ise bunların sınıflandırılmasıdır.

Bilgisayarlar, görüntüleri veya sinyalleri birer matris şeklinde algılar. Siyah beyaz 512x512 piksel büyüklüğünde bir pelvis grafisi örnek verilecek olursa 512x512 büyüklüğünde bir matristen bahsedilmiş olur. Matrisin her hücresi bir pikseli temsil eder ve her piksel 1-256 (2^8) arasında bir değer alır. Eğer renkli bir görüntü söz konusu ise RGB (*Red-Green-Blue*) renk uzayında her renk için ayrı bir matris oluşturur ve 512x512x3 (enxboyxderinlik) şeklinde algılanır. Konvolüsyonel sinir ağlarının ilk bölümü olan özellik çıkartma işlemini gerçekleştirilirken, 'filtre' ya da 'kernel' adı verilen daha küçük matrisler ile görüntü taranır (Şekil 2). Bu şekilde büyük bir görüntünün küçük kesitleri incelenerek, özelliklerin uzaysal konum bilgisi korunarak farklı noktalarda da benzer veya ayırt edici özelliklerin olup olmadığı taranır (Şekil 3). Bu özellik hari-




Şekil 2. Röntgenin filtre (*kernel*) tarafından taranması ve özellik çıkarımı işlemi.

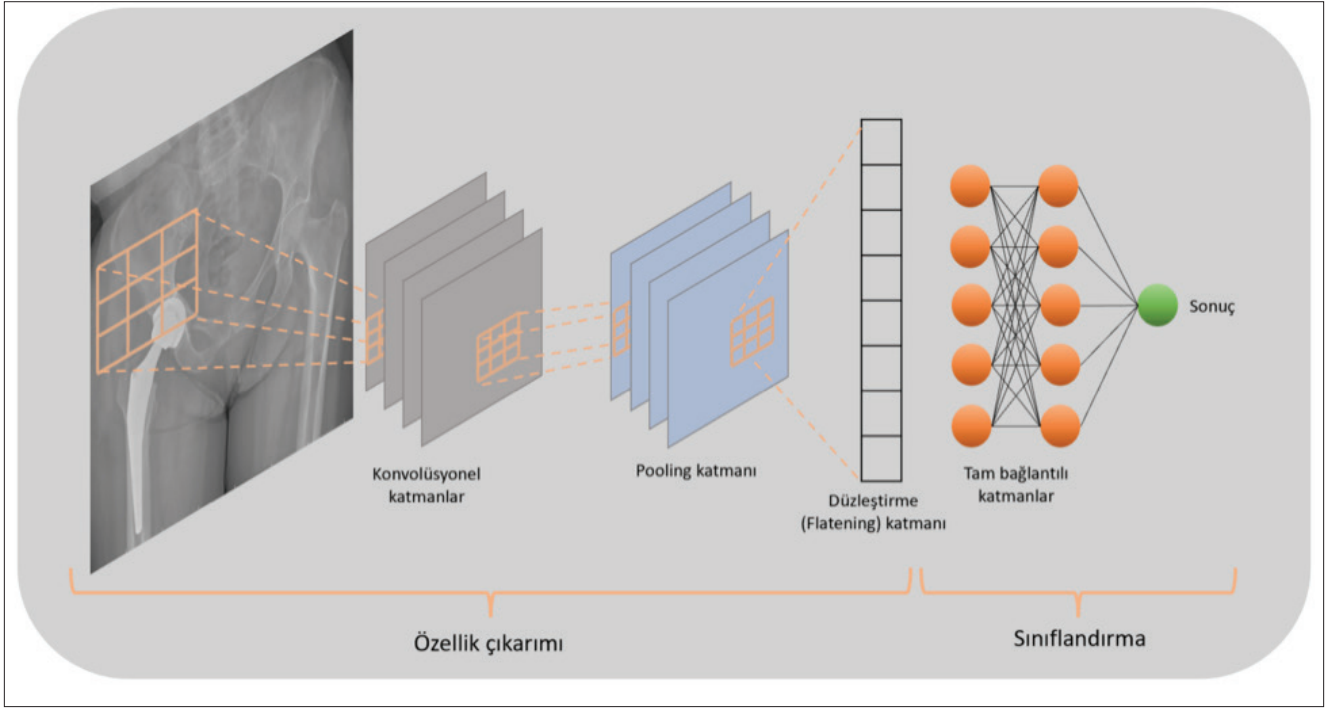
taralı daha küçük matrisler şeklinde özetlenir ve bilgisayar tarafından daha kolay işlenir hale getirilir.

Ortaya çıkan matrisler özellik haritası (*feature map*) olarak adlandırılır. Bu özellik haritalarında belirgin olan kenar-köşe gibi veya renk-oryantasyon gibi özellikler bilgisayar tarafından algılanır ve görüntünün insanlara benzer şekilde tanınmasını sağlar. Güncel yapay sinir ağları, en az birkaç konvolüsyonel katman içerir ve her tasarımın farklı avantaj/dezavantajları vardır.

Sonraki katman 'havuzlama katmanı (*pooling layer*)' olarak adlandırılır. Bu katmanda oluşan matrisler çeşitli fonksiyonlar ile daha küçük ve daha yoğun matrisler haline getirilir. Ardından matris tek sıralı bir dizi haline getirilir ve birbiri ile bağlantılı katman adı verilen konvolüsyonel sinir ağlarının 'sınıflandırma' fonksiyonunu yerine getiren bölümü oluşturur (Şekil 4). Sinir ağı içindeki yapay nöronlar eğitimlerinin başlangıcında rastgele matematiksel değerler ile çalışırlar. Tahminlerden aldığı sonuçları kesin doğru olarak sınıflandırılmış olan veriler ile doğrularlar. Önceki katmanlardaki fonksiyon değerlerini (ağırlıklarını) değiştirir ve optimal değerleri bularak en doğru sonuca ulaşmaya çalışırlar.



Şekil 3. Konvolüsyonel katman özellik çıkarımı görüntüleri.



Şekil 4. Konvolüsyonel sinir ağlarının çalışma şekli: Röntgenin matris şekline çevrilmesi, özellik çıkarımı işlemi, özelliklerin yoğunlaştırılması, sınıflandırılması ve sonuç.

KSA'da bir model oluştururken veri seti; eğitim, doğrulama ve test olarak üçe ayrılır. Eğitim ve doğrulama setindeki veriler ile model kendini doğruya ulaşmak için optimize eder (Şekil 5). Ardından daha önce karşılaşmadığı test verileri ile performansı değerlendirilir. Konvolüsyonel sinir ağları temelde istatistiksel modellere dayandığı için, doğruluğunu arttırmak ve genellenebilirliğini sağlamak adına en önemli faktör veri sayısıdır.

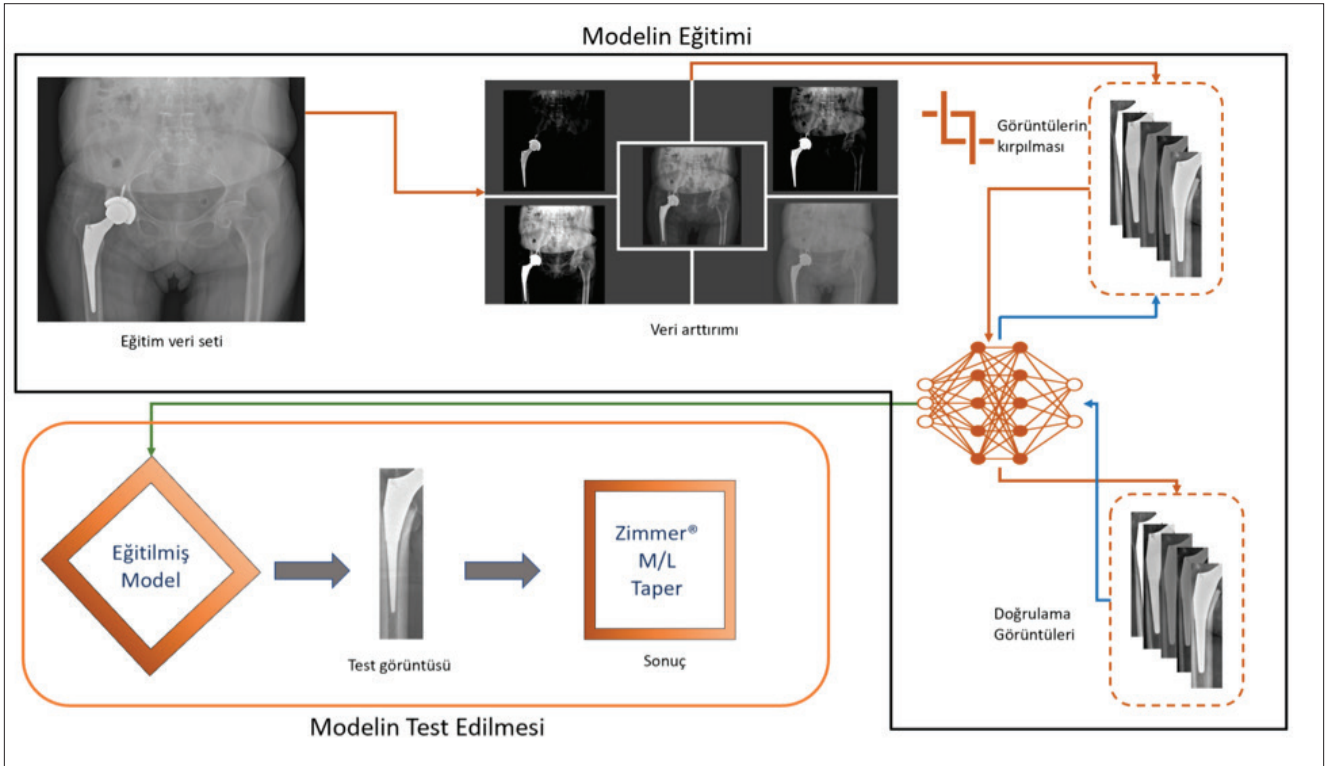
TOTAL KALÇA ARTROPLASTİSİ VE KONVOLÜSYONEL SİNİR AĞI UYGULAMALARI

Literatürde total kalça artroplastisinde konvolüsyonel sinir ağları ile ilgili ameliyat öncesi, sırası ya da sonrası için birçok çalışma gerçekleştirilmiştir. Ameliyat öncesi hazırlıkta şablonlamanın önemi oldukça yüksektir. İki boyutlu olarak direkt radyografiden yapılabildiği gibi üç boyutlu olarak tomografi üzerinden de gerçekleştirilebilir. Her tekniğin zaman ve tutarlılık açısından farklı avantaj ve dezavantajları bulunmaktadır. Changmuğu şirketi, 'HIP AI' adı verdikleri konvolüsyonel sinir ağlarının kullanıldığı bir program geliştirmiştir. Program tomografi görüntülerinde yüz tanıma sistemlerine benzeyen bir yöntem ile pelvis, femur, tibial anatomik referans noktalarını otomatik olarak algılamaktadır. Bu noktaların koordinatlarını değerlendirip daha önce öğrendiği verilerden optimal protez yerleşimine karar verir. Huo ve ark. çalışmalarında HIP AI algoritmasını, manuel 3B planlama

yapılan *Mimics*® yazılımı ve klasik dijital şablonlamayı harcanan zaman, planlanan implant boyu ile tutarlılık açısından karşılaştırılmıştır. Aynı zamanda algoritmanın tutarlılığını etkileyen displazi, vücut kitle indeksi ve cinsiyet gibi faktörler de değerlendirilmiştir.^[20] Asetabuler, kap ve femoral stem (sap) boyutunda HIP AI ile %74,58 ve 3D mimics ile %71,19 oranında tutarlılık saptanırken, dijital şablonlamada %40,68 tutarlılık olduğunu bildirmiştir. Aynı zamanda HIP AI ve dijital şablonlamanın harcanan zaman açısından benzer olduğunu, 3D *Mimics* ile yapılan planlamadan ise belirgin olarak daha hızlı olduğunu bildirmiştir. Bunun yanında displastik kalçaların sonuçlardaki tutarlılığı negatif olarak etkilediğini bildirmişlerdir.

Jodeiri ve ark., pelvik sagittal indeksi lateral grafiye gerek kalmaksızın antero-posterior kalça grafilerinden ölçebilmek amacıyla konvolüsyonel sinir ağlarını kullanarak bir algoritma geliştirmişler ve hastaların dörtte üçünde küçük hata payı ile değerlendirmeyi başarmışlardır.^[21]

Ameliyat esnasında femoral komponentin yerleşimi sırasında %5,4 oranında periprotetik kırık riski bildirilmiştir. Leon ve ark., implantın yerleşimi sırasında oluşan çekiş seslerini analiz ederek konvolüsyonel sinir ağları ile bir algoritma geliştirmiştir.^[22] Çalışmada hem *in vitro* hem de *in vivo* şartlarda kayıtlar alınıp ses dalgaları sınıflandırılmış ve algoritma ile değerlendirilmiştir. Periprotetik



Şekil 5. Model Eğitim şeması.

kırık gelişimini %80 oranında doğru tahmin eden model, konvolüsyonel sinir ağlarının sinyal algılama ve değerlendirme kapasitesini göstermesi açısından önemlidir.

Cerrahi sonrası takip ve değerlendirmelerde komplikasyon gelişme ihtimali olan nüfusun tahmin edilmesi önemlidir. Taunton ve ark., ameliyat sonrası AP pelvis grafilerinden çıkık riski yüksek olan hastaları KSA ile saptamayı hedeflemiştir.^[23] Geliştirilen model yüksek duyarlılık ve negatif prediktif değer ile çıkık riskini değerlendirmiştir. Çıkık riskini arttıran başka bir değişken de komponent malpozisyonudur. Rouzrokh ve ark., postoperatif (ameliyat sonrası) radyografilerde KSA ile AP ve lateral grafileri kullanarak asetabular komponentin anteversiyon ve inklinasyonunu otomatik olarak ölçen bir model geliştirmiştir.^[24] Algoritma iskiyal çıkıntıları ve asetabular komponenti otomatik olarak tanıyarak yaptığı ölçümde, inklinasyonu 1,35°; anteversiyonu ise 1,27° derece hata payı ile oldukça keskin bir biçimde ölçmeyi başarmıştır.

Total kalça artroplastisinin komplikasyonlarından biri olan aseptik gevşemenin tanısında radyografinin önemi büyüktür. KSA ile geliştirilen bir algoritma ile direkt grafide aseptik gevşeme tanısında ortopedi ve travmatoloji uzmanından daha iyi performans gösterdiği bildirilmiştir.^[25] Bu tip uygulamalar ile risk altındaki nüfusun tespiti ve takibi ile komplikasyon oranlarının azaltılması hedeflenmektedir.

Revizyon cerrahileri planlanmasında hastanın mevcut implantlarının tanınması büyük önem taşır. Bu aşamada ortopedi uzmanlarının planlamada sıklıkla implant marka ve modeline ulaşamadığı veya ulaşmak için birkaç yöntem denedikleri ve ciddi zaman harcadıkları raporlanmıştır.^[26] Konvolüsyonel sinir ağları ile eğitilen modeller sayesinde çeşitli marka ve modellerdeki femoral stemler yüksek duyarlılık ile direkt grafilerden saptanabilmektedir.^[27-30] Hatta artroplasti uygulayan cerrahların, implantları tanıma performansından daha yüksek doğruluk oranına ulaşan modeller de mevcuttur.^[31]

KONVOLÜSYONEL SİNİR AĞLARININ GÜÇLÜ YANLARI VE KISITLILIKLARI

Konvolüsyonel sinir ağlarının en büyük avantajı insan ile karşılaştırıldığında görüntü tanıma oranlarındaki yüksek başarılarıdır. Aynı zamanda bu beceriyi bilgisayarın hesaplama kapasitesini oldukça etkili kullanarak yaparlar.

Bu güçlü özelliğinin yanında tıbbi uygulamalarda bazı kısıtlılıkları mevcuttur. Bu kısıtlılıkların en başında çalışma sisteminin net olarak açıklanamaması yer almaktadır. Sistemin karar alırken dayanaklarının neler olduğu tam olarak açıklığa kavuşturulmadan günlük pratiğe girmesi etik problemler doğurabilir. Geliştirilen algoritma-

ların karar alırken yaptığı hataların tespiti ile sistemi iyileştirmek için kullanılabilir. Aynı şekilde, modelin insanlardan daha iyi sonuçlar aldığı durumlarda, insanlardan nasıl daha iyi karar alabildiğini açıklamak yeni buluşlara imkân sağlayabilir. Dikkat haritaları (*saliency maps*) ve aktivasyon maksimizasyonu (*activation maximization*) gibi teknikler ile algoritmaların görüntüler üzerinde dikkat ettiği bölgeler görüntülenebilir.^[5]

Bir başka problem ise patolojik verilerin göreceli olarak az sayıda olmasıdır. Küçük boyutta veri setlerinde patolojik verilerin az olması nedeniyle yanlışlık oluşabilir.

SONUÇ

Total kalça artroplastisinin her aşamasında konvüsyonel sinir ağları ve yapay zekâ uygulamaları umut vadetmektedir. Görüntüler konvüsyonel sinir ağları ile daha hızlı ve doğru biçimde değerlendirilebilecektir. Bu sayede yorgunluk veya deneyimsizlik nedeniyle ortaya çıkabilecek insan hataları önenebilecektir. Aynı zamanda alanında uzman kişiler tarafından geliştirilen bu sistemler yeterli deneyimin bulunmadığı yerlerde başarıyı arttıracaktır. Daha büyük, doğrulanmış ve kaliteli veri setleri ile eğitilmiş, çalışma sistemleri açıklanabilir yapay zekâ modelleri yakın gelecekte günlük pratiğimizde daha fazla kullanım alanı bulacaktır.

KAYNAKLAR

- Özsezen AM. Yapay zeka ve derin öğrenme teknolojileri ile kalça eklemi radyografilerinde femoral komponentin tanınması, Tıpta Uzmanlık Tezi (Danışman: Dr. Cemil Yıldız). Ankara Gülhane Tıp Fakültesi 2021.
- Yıldız C, Ersönmez H, Şahin S, Arı M, Özsezen AM, Sanal HT. Automated detection of intertrochanteric femoral fractures with deep learning methods. 1st İzmir International Orthopedic Trauma Course; 5-7 Kasım 2021.
- Yıldız C, Ersönmez H, Şahin S, Arı M, Özsezen AM, Sanal HT. Yapay Zekâ Yöntemlerinden Derin Öğrenme ile İntertrokanterik Femur Kırıklarının Tanısı. Kemik Eklem Cerrahisi Derneği Kongresi; 13-16 Ekim 2021.
- Özsezen AM, Yıldız C. Yapay zeka ve derin öğrenme teknolojileri ile kalça eklemi radyografilerinde femoral komponentin tanınması. 30. Ulusal Ortopedi ve Travmatoloji Kongresi; 9-13 Kasım 2021.
- Borjali A, Chen AF, Muratoglu OK, Morid MA, Varadarajan KM. Deep learning in orthopedics: how do we build trust in the machine? Healthcare Transformation Epub: 30 Mar 2020. [Crossref](#)
- Sarvamangala D, Kulkarni RV. Convolutional neural networks in medical image understanding: a survey. Evolutionary Intelligence 2021;1:22. [Crossref](#)
- Gulshan V, Peng L, Coram M, Stumpe MC, Wu D, Narayanaswamy A, et al. Development and validation of a deep learning algorithm for detection of diabetic retinopathy in retinal fundus photographs. JAMA 2016;316(22):2402-10. [Crossref](#)
- Esteva A, Kuprel B, Novoa RA, Ko J, Swetter SM, Blau HM, et al. Dermatologist-level classification of skin cancer with deep neural networks. Nature 2017;542(7639):115-8. [Crossref](#)
- Ehteshami Bejnordi B, Veta M, van Diest PJ, van Ginneken B, Karssemeijer N, Litjens G, et al. Diagnostic assessment of deep learning algorithms for detection of lymph node metastases in women with breast cancer. JAMA 2017;318(22):2199-210.
- Chung SW, Han SS, Lee JW, Oh K-S, Kim NR, Yoon JP, et al. Automated detection and classification of the proximal humerus fracture by using deep learning algorithm. Acta Orthop 2018;89(4):468-73. [Crossref](#)
- Chen H-Y, Hsu BW-Y, Yin Y-K, Lin F-H, Yang T-H, Yang R-S, et al. Application of deep learning algorithm to detect and visualize vertebral fractures on plain frontal radiographs. PLoS One 2021;16(1):e0245992. [Crossref](#)
- Yu J, Yu S, Erdal B, Demirer M, Gupta V, Bigelow M, et al. Detection and localisation of hip fractures on anteroposterior radiographs with artificial intelligence: proof of concept. Clin Radiol 2020;75(3):237.e1-.e9. [Crossref](#)
- Ma S, Huang Y, Che X, Gu R. Faster RCNN-based detection of cervical spinal cord injury and disc degeneration. J Appl Clin Med Phys 2020;21(9):235-43. [Crossref](#)
- Shiode R, Kabashima M, Hiasa Y, Oka K, Murase T, Sato Y, et al. 2D-3D reconstruction of distal forearm bone from actual X-ray images of the wrist using convolutional neural networks. Sci Rep 2021;11(1):1-12. [Crossref](#)
- Raj A, Ajani B, Krishnan K, Viswanathan S, Agarwal HK (eds). 3D deep learning based cartilage segmentation for visualization and analysis of quantitative MRI for osteoarthritis. 10th ISMRM Workshop on Osteoarthritis Imaging; 2017.
- Gjesteby L, Yang Q, Xi Y, Zhou Y, Zhang J, Wang G (eds). Deep learning methods to guide CT image reconstruction and reduce metal artifacts. Physics of Medical Imaging 2017; Proc. of SPIE Vol. 101322W-1.
- Zhang S-C, Sun J, Liu C-B, Fang J-H, Xie H-T, Ning B. Clinical application of artificial intelligence-assisted diagnosis using anteroposterior pelvic radiographs in children with developmental dysplasia of the hip. The Bone & Joint Journal 2020;102(11):1574-81. [Crossref](#)
- Yalçın O. The Brief History of Convolutional Neural Networks 2021 [23 September 2021]. Erişim adresi: <https://towardsdatascience.com/the-brief-history-of-convolutional-neural-networks-45afa1046f7f> (Erişim tarihi: 2/09/2021).
- Krizhevsky A, Sutskever I, Hinton GE. Imagenet classification with deep convolutional neural networks. Adv Neural Inf Process Syst 2012;25:1097-105.
- Huo J, Huang G, Han D, Wang X, Bu Y, Chen Y, et al. Value of 3D preoperative planning for primary total hip arthroplasty based on artificial intelligence technology. J Orthop Surg Res 2021;16(1):1-13.

21. Jodeiri A, Otake Y, Zoroofi RA, Hiasa Y, Takao M, Uemura K, et al. Estimation of pelvic sagittal inclination from anteroposterior radiograph using convolutional neural networks: Proof-of-concept study. arXiv preprint 2019; arXiv:1910.12122.
22. Galindo León SA. Periprosthetic femur fracture prevention during hip arthroplasty through analysis of the hammering-related sound of stem implantation: [tez] Uniandes; 2020.
23. Taunton MJ. Deep learning artificial intelligence model for prediction of hip dislocation following primary total hip arthroplasty from postoperative radiographs. Bone Joint J Orthopaedic Proceedings 2020;102(Supp10):9.
24. Rouzrokh P, Wyles CC, Philbrick KA, Ramazanian T, Weston AD, Cai JC, et al. A deep learning tool for automated radiographic measurement of acetabular component inclination and version after total hip arthroplasty. J Arthroplasty 2021;36(7):2510-7. [Crossref](#)
25. Borjali A, Chen AF, Muratoglu OK, Morid MA, Varadarajan KM. Detecting mechanical loosening of total hip replacement implant from plain radiograph using deep convolutional neural network. arXiv preprint 2019; arXiv:1912.00943.
26. Wilson N, Broatch J, Jehn M, Davis III C (eds). National projections of time, cost and failure in implantable device identification: Consideration of unique device identification use. Healthcare; 2015;3(4):196-201. [Crossref](#)
27. Borjali A, Chen AF, Muratoglu OK, Morid MA, Varadarajan KM. Detecting total hip replacement prosthesis design on plain radiographs using deep convolutional neural network. J Orthop Res 2020;38(7):1465-71. [Crossref](#)
28. Kang Y-J, Yoo J-I, Cha Y-H, Park CH, Kim J-T. Machine learning-based identification of hip arthroplasty designs. J Orthop Translat 2020;21:13-7. [Crossref](#)
29. Karnuta JM, Haeberle HS, Luu BC, Roth AL, Molloy RM, Nystrom LM, et al. Artificial intelligence to identify arthroplasty implants from radiographs of the hip. J Arthroplasty 2021;36(7):S290-S4.e1. [Crossref](#)
30. Murphy M, Killen C, Burnham R, Sarvari F, Wu K, Brown N. Artificial intelligence accurately identifies total hip arthroplasty implants: a tool for revision surgery. Hip Int 2021.
31. Borjali A, Chen AF, Bedair HS, Melnic CM, Muratoglu OK, Morid MA, et al. Comparing the performance of a deep convolutional neural network with orthopedic surgeons on the identification of total hip prosthesis design from plain radiographs. Med Phys 2021;48(5):2327-36. [Crossref](#)