



Eklem koruma ve yapay zekâ

Joint preservation and artificial intelligence

Halis Atıl Atilla, Fatih Barça

Ankara Etlik Şehir Hastanesi, Ortopedi ve Travmatoloji Kliniği, Ankara

Yapay zekânın tıbbi alanda kullanımı konusunda çalışmalar, özellikle elektronik ortamdaki klinik ve radyografik verilerin birikmeye başlamasıyla, gün geçtikçe artmaktadır. Geleneksel istatistiğin sınırlarının yapay zekâ yardımıyla kolaylıkla aşılması ve daha büyük veri setlerinin daha hızlı analizi mümkün olabilmektedir. Teknolojik gelişmelerin en yakından takip edildiği tıp alanlarından biri olan ortopedi ve travmatolojide bu konuya bir ilgi mevcuttur. Daha çok çalışmanın olduğu artroplasti ve omurga cerrahisi yanında eklem koruyucu tedaviler alanında da yapay zekânın deneysel uygulamaları bulunmaktadır. Özellikle kıkırdak kaybı, menisküs ve ön çapraz bağ yırtığı, rotator manşet lezyonları ve kalça eklemi sorunlarında tanı koymaya yardımcı uygulamalar olduğu gibi cerrahi tedavi planlama ve prognoz öngörmede yapay zekânın başarılı olduğu çalışmalar literatüre kazandırılmaya devam etmektedir. Bununla beraber, yapay zekânın bu alanlarda klinisyenin standart uygulamasına dâhil olmasının önünde çeşitli engeller vardır. Yapay zekâ konusunda yayınlanmış çalışmaların standardizasyonunun sağlanması ve kalitelerinin artırılması, bununla birlikte ilerleyen teknolojinin diğer unsurlarından da faydalanılması, gelecekte yapay zekânın eklem koruyucu tedavide klinik uygulamada daha önemli bir yer edinmesine yardımcı olacaktır.

Anahtar sözcükler: yapay zekâ; eklem koruma; artroskopi

With the accumulation of clinical and radiographic data in electronic form, studies on the use of artificial intelligence in the medical field are increasing rapidly. The limits of conventional statistics can be easily overcome with the help of artificial intelligence and larger data sets can be analyzed faster. In orthopedics and traumatology, one of the medical fields where technological developments are most closely followed, there is an increasing interest in this subject. In addition to arthroplasty and spine surgery, where there are more studies on this field, there are also experimental applications of artificial intelligence in the field of joint preservation. Diagnostic applications, studies in which artificial intelligence is successful in surgical treatment planning and prognosis prediction in cartilage loss, meniscus and anterior cruciate ligament tears, as well as rotator cuff lesions and hip joint problems, continue to be served to the literature. However, there are several barriers to the incorporation of AI into the clinician's standard practice in these areas. Ensuring the standardization and improving the quality of published studies on artificial intelligence, as well as taking advantage of other elements of advancing technology, will help artificial intelligence to gain a more important role in clinical practice in joint preservation in the future.

Key words: artificial intelligence; joint preservation; arthroscopy

Bilgisayar teknolojilerinin gelişmesiyle, bilgisayarların yapabileceklerinin sınırlarını zorlamak bir bilim kurgu ögesinden gerçek yaşam pratiğine dönüşmüş durumdadır. Yapay zekâ tam bu noktada karşımıza bir araştırma alanı olarak çıkmaktadır. Özellikle sanal ortamda birikmiş verilerin her alanda çok hızlı bir şekilde artması, bu verilerin analizi ve uygulamaya nasıl dönüşebileceği konusunda birtakım algoritma arayışlarına yol açmıştır. Yapay zekâ, bilişsel işlev gerektiren problem çözme, nesne ve kelime

tanıma veya karar verme gibi süreçlerin bilgisayarlar tarafından yapılabilmesine olanak tanıyan teknoloji olarak geniş şekilde tanımlanabilir.^[1] Çeşitli alanlarda (reklamcılık, taşıt otonom sürüş, arama motorları gibi) bu uygulamaların örneklerine gündelik hayatımızda sıklıkla rastlayabiliyoruz. Tıp alanı ise çeşitli zorluklar ve engeller nedeniyle yapay zekâ konusunda diğer alanlar kadar hızlı bir ilerleme gösterememiştir.^[2] Yine de son on yılda bu konuda yapılan çalışmaların arttığı, hatta çok büyük işbirliklerin de bu konuda yatırımlar

İletişim / Contact: Doç. Dr. Halis Atıl Atilla • **E-posta / E-mail:** dratilatilla@hotmail.com

ORCID iD: Halis Atıl Atilla, 0000-0002-5670-1469 • Fatih Barça, 0000-0002-8167-6146

Geliş / Received: 28 Ağustos 2023 • **Revizyon / Revised:** 8 Kasım 2023, 1 Aralık 2023 • **Kabul / Accepted:** 5 Aralık 2023

yaparak özellikle karar verme noktasında, tartışmalı olsa da yardımcı teknolojiler hazırladığını görmekteyiz.^[2]

Yapay zekânın alt öğelerinden makine öğrenmesi (yönlendirerek ya da kendiliğinden deneme ve yanılma yoluyla büyük verilerin içindeki geleneksel istatistiğin çıkarmayacağı örüntüleri ortaya çıkarma), yapay sinir ağları, derin öğrenme (çok katmanlı makine öğrenmesi), doğal dil işleme (verilen standart kodlar dışında konuşma diliyle yazılmış metinlerin içindeki verileri ortaya çıkarma ve işleme) ve bilgisayar görüşü (görselleri tanımlama ve anlamlandırma) tıpta birçok alanda kullanılmaktadır.^[1]

Ortopedi ve travmatolojide yapay zekâ konulu birçok çalışma yürütülmektedir. Özellikle artroplasti alanında bazı ülkelerin elektronik kayıt sistemlerinin gelişmiş, yerleşmiş olması ve omurga alanında nöroşirurjinin de ilgisinin olması, çalışmaların önemli bir kısmının bu alanlarda ilerlemesini sağlarken eklem koruyucu cerrahi alanında da özellikle tanısız görüntüleme konusunda literatürün bir ilgisi bulunmaktadır.^[3]

TANISAL UYGULAMALAR

Özellikle erken dönem osteoartrit saptama konusunda, eldeki verinin de fazla olması sayesinde, yapay zekâya başvuran çok sayıda çalışma mevcuttur.^[4-21] Kıkırdak kaybının ve osteoartritin tespitinde direkt grafi ve manyetik rezonans görüntüleme gibi radyolojik verilerle makine öğrenmesi sağlanabildiği gibi biyokimyasal veriler ve yürüme analizi gibi alternatif veri kaynakları da yapay zekânın kalça veya diz osteoartritiyle ilgili doğru karar vermesine yardımcı olabilmektedir (Tablo 1).^[4-21] Hatta, Chhabra tarafından, eklem korunup korunamayacağına kararının verilmesinde yapay zekânın rutin kullanıma girmesinin maliyetler ve gereksiz tedavilerden kaçınılması açısından yardımcı olabileceği konusunda bir görüş bildirilmiştir.^[22]

Mevcut literatür daha çok diz eklemiyle ilgili patolojilerin tanısıyla ilgili olmakla beraber diğer eklemler için de yapay zekâ uygulamalarıyla ilgili çalışmalar bulunmaktadır. Örneğin rotator manşet yırtığı tanısında yapay zekâ kullanımı konusunda manyetik rezonans görüntüleme ve ultrasonografi ile ilgili çalışmalar mevcut olup Shim ve ark. tarafından yapılmış bir çalışma yapay zekânın lezyon tanımlamada ortopedi ve travmatoloji cerrahlarından daha başarılı olduğunu göstermiştir.^[23] Kim ve ark. tarafından yapılmış bir çalışmada supraspinatus kas volümünün ölçümü konusunda da yapay zekâ uygulaması başarılı olmuştur.^[24] Ayrıca omuz patolojileri için risk faktörü olan ve direkt grafilere ölçülen kritik omuz açısının yapay zekâ ile tespitiyle ilgili çalışmalar da umut vermektedir.^[25] Talus osteokondral lezyon tanısında da

yapay zekâ başarı göstermektedir.^[26,27]

Kalça displazisi ile ilgili yapay zekâ uygulamaları, direkt grafilere ölçülen parametreleri (lateral merkez-kenar açısı ve Tönnis açısı gibi) belirleyip displazi tespit etme konusunda başarı göstermiştir.^[28,29] Femur başı osteonekrozu tanısıyla ilgili yapay zekâ uygulamaları, direkt grafilere tanı koymada az deneyimli radyologlardan, ortopedi ve travmatoloji hekimlerinden, manyetik rezonans görüntüleme ise ortopedi ve travmatoloji hekimlerinden daha başarılı olmuştur.^[30-32] Manyetik rezonans görüntüleriyle femoroasetabular sıkışma tespitinde de yapay zekâ uygulamaları bulunmaktadır.^[33]

Menisküs lezyonu tanısı, eldeki manyetik rezonans görüntüleme kesitlerin yırtık bölgesinden geçmesi ya da normal yapıların menisküs lezyonundan kimi zaman ayırt edilememesi nedeniyle zor olabilmektedir. Bu zorlukları gidermek için klinisyene yardımcı olabilecek çeşitli yapay zekâ uygulamalarıyla ilgili çalışmalar da yapılmıştır. Tıpkı bunun gibi ön çapraz bağ lezyonunun tespiti ve derecelendirilmesi ile ilgili yapay zekâ uygulamaları da çalışılmaktadır (Tablo 2).^[15,34-48]

TEDAVİ PLANLAMA UYGULAMALARI

Dijital ortamda radyografik veri miktarının çok fazla olması çoğunlukla tanı alanında yapay zekâ uygulamalarıyla ilgili çalışma yapmayı mümkün kılmıştır. Ancak cerrahi tedavi planlanmasında da radyografik verilerin otomatize şekilde değerlendirilmesi, klinisyene bu alanda oldukça yardımcı olabilir. Örneğin Morita ve ark. birikmiş radyografik verileri kullanarak ön çapraz bağ cerrahisinde tünel pozisyonunu belirlemenin deneysel olarak mümkün olabildiğini göstermişlerdir.^[49]

Yüksek tibial osteotomi planı yapılan hastalarda alt ekstremite dizilim ölçümlerinin yapay zekâ tarafından yapıldığı Schock ve ark. tarafından yapılan çalışmada yapay zekâ klinisyenlerden daha başarılı sonuçlar vermiştir.^[50] Revizyon ön çapraz bağ cerrahisinde uygulanan anterior kapalı kama osteotomisinde sagittal planda osteotomi planlaması yapay zekâ tarafından yapılabilir.^[51] Yüksek tibial osteotomi sırasında lateral hinge kırığı riski, Jeong ve ark. tarafından yapılmış çalışmada yapay zekâ tarafından tespit edilebilmiştir.^[52]

Kalça koruyucu cerrahi planlamasında yapay zekâ ile ilgili çalışmalar da mevcuttur. Zeng ve ark. tarafından yapılan bir çalışmada periasetabuler osteotomi planlaması yapay zekâ kullanılarak manyetik rezonans görüntülemeleriyle yapıldığında oldukça başarılı sonuçlar elde edilmiştir ve yazarlar bu yöntemin radyasyon maruziyetini azaltacağını öne sürmüşlerdir.^[53]

Tablo 1. Osteoartrit/kıkırdak lezyonu tanısında yapay zekâ kullanımı

Çalışma	Modalite/veri kaynağı	Anatomik bölge	Bulgular
Abedin ve ark. (2019) ^[4]	Direkt grafi	Diz	Kelgreen-Lawrence sınıflamasında yapay zekâ başarılı
Ahmed ve ark. (2016) ^[5]	Kan ve sinovyal sıvı aminoasit/ anti-CCP düzeyi	Diz	Osteoartrit ve enflamatuvar artrit ayrımı konusunda yapay zekâ kan parametreleri ile yüksek sensitivite ve spesivite ile başarılı
Antony ve ark. (2016) ^[6]	Direkt grafi	Diz	Kelgreen-Lawrence sınıflamasında yapay zekâ başarılı
Dam ve ark. (2015) ^[7]	Manyetik rezonans görüntüleme	Diz	Kıkırdak volümü hesaplama konusunda yapay zekâ başarılı
Laroche ve ark. (2014) ^[8]	Yürüme analizi	Kalça	Yapay zekânın bulguları WOMAC skoru ile korele
Liu ve ark. (2018) ^[9]	Manyetik rezonans görüntüleme	Diz	Kıkırdak lezyonu tespitinde yapay zekâ başarılı
Madelin ve ark. (2015) ^[10]	Manyetik rezonans görüntüleme	Diz	Osteoartrit tanısı koymada yapay zekâ başarılı
Marques ve ark. (2012) ^[11]	Manyetik rezonans görüntüleme	Diz	Trabeküler kemik yapısının değerlendirildiği yapay zekâ uygulaması osteoartrit tespitinde başarılı
Nagarajan ve ark. (2013) ^[12]	Faz kontrast bilgisayarlı tomografi	Diz (patella)	Patella kıkırdak yapısı ile osteoartrit arasında ilişki kurma konusunda yapay zekâ başarılı
Norman ve ark. (2018) ^[13]	Direkt grafi	Diz	Kelgreen-Lawrence sınıflamasında yapay zekâ başarılı
Oka ve ark. (2008) ^[14]	Direkt grafi	Diz	Osteoartrit tanısı koymada yapay zekâ başarılı (medial eklem aralığında daralma ile en çok ilişkili)
Pedoa ve ark. (2019) ^[15]	Manyetik rezonans görüntüleme	Diz (patella)	Menisküs ve patellar kıkırdak lezyonu belirleme konusunda yapay zekâ başarılı (demografik veriler de dâhil edilince başarı artıyor)
Schacky ve ark. (2020) ^[16]	Direkt grafi	Kalça	Osteoartrit tanısı koymada ve sınıflamada yapay zekâ başarılı
Tiulpin ve ark. (2018) ^[17]	Direkt grafi	Diz	Kelgreen-Lawrence sınıflamasında yapay zekâ başarılı
Ureten ve ark. (2020) ^[18]	Direkt grafi	Kalça	Osteoartrit tanısı koymada yapay zekâ başarılı
Xue ve ark. (2017) ^[19]	Direkt grafi	Kalça	Osteoartrit tanısı koymada yapay zekâ 10 yıllık deneyimi olan hekim kadar başarılı
Zhang ve ark. (2013) ^[20]	Manyetik rezonans görüntüleme	Diz	Kıkırdak tanımlama konusunda başarılı bir yöntem tanımlanmış
Zeng ve ark. (2021) ^[21]	Direkt grafi	Diz	Kelgreen-Lawrence sınıflamasında başarılı yapay zekâ yöntemleri karşılaştırılmış

Anti-CCP: Anti-siklik sitrülenmiş peptit, WOMAC: *Western Ontario and McMaster Universities arthritis index*.

Tablo 2. Menisküs ve ön çapraz bağ lezyonu tanısında yapay zekâ kullanımı

Çalışma	Lezyon	Bulgular
Awan ve ark. (2021) ^[34]	Ön çapraz bağ	Ön çapraz bağ lezyonu tespitinde yapay zekâ başarılı
Bien ve ark. (2018) ^[35]	Menisküs ve ön çapraz bağ	Menisküs ve ön çapraz bağ lezyonu tespitinde yapay zekâ başarılı
Chang ve ark. (2019) ^[36]	Ön çapraz bağ	Ön çapraz bağ yırtığı tespitinde yapay zekâ başarılı
Chou ve ark. (2023) ^[37]	Menisküs	Menisküs lezyonunun tespitinde ve lokalizasyonunun belirlenmesinde yapay zekâ başarılı
Couteaux ve ark. (2019) ^[38]	Menisküs	Menisküs lezyonunun tespitinde ve lokalizasyonunun belirlenmesinde yapay zekâ başarılı
Fritz ve ark. (2020) ^[39]	Menisküs	Menisküs lezyonu tespitinde yapay zekâ radyolog kadar sensitif ancak spesifik değil
Germann ve ark. (2020) ^[40]	Ön çapraz bağ	Ön çapraz bağ yırtığı tespitinde yapay zekâ başarılı (ancak başarı çekim yapılan cihaza göre değişiyor)
Irmakci ve ark. (2020) ^[41]	Menisküs ve ön çapraz bağ	Menisküs ve ön çapraz bağ lezyonu tespitinde yapay zekâ başarılı
Liu ve ark. (2019) ^[42]	Ön çapraz bağ	Ön çapraz bağ yırtığı tespitinde yapay zekâ başarılı
Namiri ve ark. (2020) ^[43]	Ön çapraz bağ	Ön çapraz bağ lezyonu sınıflamasında yapay zekâ başarılı
Pedoia ve ark. (2019) ^[15]	Menisküs	Menisküs ve patellar kırıkda lezyonu belirleme konusunda yapay zekâ başarılı (demografik veriler de dâhil edilince başarı artıyor)
Rizk ve ark. (2021) ^[44]	Menisküs	Menisküs lezyonunun tespitinde ve sınıflamasında yapay zekâ başarılı
Roblot ve ark. (2021) ^[45]	Menisküs	Menisküs lezyonu tespitinde yapay zekâ başarılı
Saygılı ve ark. (2019) ^[46]	Menisküs	Menisküs lezyonunun tespitinde, sınıflamasında ve lokalizasyonunun belirlenmesinde yapay zekâ başarılı
Stajduhar ve ark. (2017) ^[47]	Ön çapraz bağ	Hafif ön çapraz bağ yaralanmalarının ve tam kat yırtıkların tespitinde yapay zekâ başarılı
Tsai ve ark. (2020) ^[48]	Menisküs ve ön çapraz bağ	Menisküs ve ön çapraz bağ lezyonu tespitinde yapay zekâ başarılı

Artroskopi cerrahisi sırasında intraoperatif yapay zekâ kullanımı omuz ve diz artroskopisinde denenmiştir. Jonmohamadi ve ark. tarafından yapılan bir çalışmada diz artroskopisi görüntülerindeki menisküs, ön çapraz bağ gibi yapıları yapay zekâ tanıma konusunda başarılı olmuştur.^[54] Omuz artroskopisinde Benhenneda ve ark. tarafından yapılmış bir uygulamada ise yapay zekâ artroskopi görüntülerinde biceps tendonunun statik patolojilerini tespit etmeyi başarmış ancak dinamik analiz konusunda ek girdilere ihtiyaç duyulmuştur.^[55]

PROGNOZ UYGULAMALARI

Tıbbi elektronik kayıt verileri hastanın takip süreci konusunda yapay zekâ için bir hazine niteliğindedir. Bu verilerle birlikte radyografik dijital görüntülerin de değerlendirmeye dâhil edilmesiyle eklem koruyucu tedaviler alanında değerli prognostik bulguların yapay zekâ sayesinde ortaya çıkması mümkün olmaktadır.

Osteoartrit nedeniyle kırıkda kaybının seyri konusunda Marques ve ark. tarafından yapılmış çalışma yapay zekâ diz manyetik rezonans görüntülemesinde trabeküller kemik kaybını değerlendirerek Kelgreen-Lawrence sınıflamasını ve prognozu belirleme konusunda başarılı olmuştur.^[56] Yapay zekâyla diz eklem aralığında daralmanın progresyonunu belirleme konusunda Ntakolia ve ark. tarafından bir çalışma yapılmıştır.^[57] Direkt grafilerden ve hastaların demografik verilerinden yola çıkarak oluşturulan yapay zekâ algoritmaları kalça osteoartritin ilerleme olasılığını ve kalça replasmanı riskini öngörebilmektedir.^[58]

Ön çapraz bağ cerrahisinin başarısıyla ilgili Ye ve ark. tarafından yapılmış bir yapay zekâ çalışmasında, hastaların demografik özellikleri ve direkt grafilerinden elde edilen parametreler gibi ameliyat öncesi verileri, ameliyat sırasındaki verileri ve ameliyat sonrası manyetik rezonans görüntüleme takipleri analiz edilerek klinik başarı konusunda bir tahminde bulunmayı başarmışlardır.^[59]

Rotator manşet onarımları sonrasında yeniden yırtılma (re-rüptür) önemli bir sorundur. Cho ve ark. tarafından yayınlanmış bir çalışmada yapay zekâ uygulaması, ameliyat sırasındaki artroskopik görüntülerini kullanarak onarım sonrasında yeniden yırtılma riskini belirlemede başarılı olmuşlardır.^[60] Rotator manşet cerrahisini maliyet açısından değerlendirip değişkenleri yapay zekâ aracılığıyla belirlemeyi amaçlayan çalışmalar da bulunmaktadır.^[61] Lu ve ark. anterior omuz instabilitesinin prognozunu demografik ve radyografik verileri kullanarak öngörebilecek bir yapay zekâ çalışması yayınlamışlardır.^[62] Ayrıca Vassalou ve ark. tarafından yapılmış, omuz kalsifik tendinitinde ultrason eşliğinde perkütan irigasyonun başarısını yapay zekâ vasıtasıyla değerlendirmeyi hedefleyen bir çalışma mevcuttur.^[63]

Kalça osteonekrozunda üç yıllık kırıldak çökme (kolaps) olasılığını değerlendirmek ve çökme riskini arttıran etiyolojik faktörleri değerlendirmek ile ilgili Hernigou tarafından yapılmış bir klinik çalışmada yapay zekâ algoritmaları kullanılmıştır.^[64] Yine aynı yazar tarafından yapılmış, biyolojik tedavilerin ve *core* dekompresyon cerrahisinin etkinliği konusunda yapay zekânın analiz için kullanıldığı bir çalışma da mevcuttur.^[65] Femoroasetabular sıkışma için yapılan kalça artroskopisinin başarısını ve tekrar cerrahi olasılığını öngörmek için demografik verilerin ve fonksiyonel skorlama sistemlerinin kullanıldığı yapay zekâ uygulamaları da literatürde bulunmaktadır.^[66]

TARTIŞMA

Yapay zekânın hayatın her alanında olduğu gibi tıp alanında da hayat pratiklerini değiştireceği yadsınamaz bir gerçektir. Bu konuda gerek informatik, gerekse tıp profesyonellerinin giderek artan bir ilgisinin olduğu, bu konuda giderek büyüyen literatürden de anlaşılmaktadır. Hasta beklentilerinin giderek arttığı modern dünyada eklem koruyucu uygulamalarda mükemmelliğe ulaşma noktasında üstel şekilde güçlenen bilgisayarlardan faydalanmak mantıklı bir tercih gibi görülmektedir. Bununla beraber bilgisayarların pratik uygulamada henüz klinisyenlerin yerini alacak bir noktada olmadığıni söyleyebiliriz.

Öncelikle mevcut yapay zekâ ile ilgili yapılmış çalışmaların hemen hemen tamamı belli bir veri grubu kullanılarak yapılmış ve eksternal validasyon uygulanmamıştır. Bu da başarılı gibi görünen uygulamaların aslında evrensel uygulanabilir nitelikten yoksun olabileceği anlamına gelmektedir. Çoğu çalışmanın faz 2 ve daha düşük aşamada olması da dikkate alınması gereken bir durumdur.^[67] Bununla beraber, açık kaynak veri setlerinin bulunması, bu veri setlerinden çalışmacıların haberdar olması ve sayılarının artmasıyla veriler birkaç farklı grup için teyit edilerek evrensel olarak çalışan bir algoritma uygulanması konusunda daha başarılı olunabilecektir.

Yapay zekâ alanında yapılan çalışmalarla ilgili standardizasyon gereksinimi mevcuttur. Bu konuda kriterlerin belirlendiği bir kontrol listesinin geliştirilmesi gerekmektedir. Örneğin diz görüntülemesi için *Checklist for Artificial Intelligence in Medical Imaging* (CLAIM) isminde bir kontrol listesi önerilmiştir.^[68] Çeşitli ilgi alanları için benzer kontrol listelerinin bulunması çalışma kalitesini arttıracaktır. Ayrıca her ne kadar doğal dil işleme yeteneği yapay zekânın en önemli unsurlarından biri olsa da elektronik tıbbi kayıtların ortak bir dil kullanmaktan oldukça uzak olması veri standardizasyonunu hâlen zorlaştırmaktadır.

Yapay zekânın tıbbi karar vermesiyle ilgili birtakım etik sorunlar da henüz aşılanmamıştır. Örneğin özel iştraklerin hastaların tıbbi kayıtlarına ulaşması kişisel veri güvenliği için oldukça büyük bir sorun teşkil etmektedir.^[67] Makine öğrenmesinde çalışan algoritmanın kapalı olması ve anlaşılabilir olmaması kara kutu fenomeni, karar verme sürecini klinisyenin görememesine ve değerlendirememesine sebep olmaktadır.^[69] Nihai sorumluluğun klinisyende olduğunu düşündüğümüzde bu açık bir problem oluşturan bir durumdur. Ayrıca yapay zekânın birtakım süreçlerde insanın yerine geçmesi uzun vadede klinisyenin karar verme yeteneğinde körelmeye sebep olabilecektir.^[67]

Özellikle eklem koruyucu rehabilitasyonda eklem fonksiyonlarının takibi ve değerlendirmesinin kolaylaştırılması açısından, giyilebilir teknolojilerden faydalanılmaktadır. Giyilebilir teknolojilerin eklem fonksiyonları ve yürüme takibi yapabiliyor olması veri toplama imkanları açısından heyecan vermektedir. Bu teknolojiyi yapay zekâyla birlikte kullanmak da mümkündür.^[70]

Sonuç olarak, yapay zekânın eklem koruyucu cerrahi alanında kullanımı konusunda heyecan verici gelişmeler bulunmaktadır. Ancak kara göründü demek için aşılanması gereken önemli sorunlar bulunmaktadır. Klinisyene yardımcı olacak yapay zekâ teknolojileri ile ilgili çalışmaların kalitesinin artması ve yaygınlaşmasıyla eklem koruyucu tedavide mükemmelliğe daha da yaklaşılacaktır.

KAYNAKLAR

1. Hashimoto DA, Rosman G, Rus D, Meireles OR. Artificial intelligence in surgery: Promises and perils. *Ann Surg* 2018;268(1):70-6. **Crossref**
2. Microsoft News Center. Leaders across healthcare, academia and technology form new coalition to transform healthcare journey through responsible AI adoption. Published 2022. Erişim adresi: <https://news.microsoft.com/2022/01/13/leaders-across-healthcare-academia-and-technology-form-new-coalition-to-transform-healthcare-journey-through-responsible-ai-adoption/> (Erişim tarihi: 21 Ağustos 2023).

3. Federer SJ, Jones GG. Artificial intelligence in orthopaedics: A scoping review. *PLoS One* 2021;16(11):e0260471. [Crossref](#)
4. Abedin J, Antony J, McGuinness K, Moran K, O'Connor NE, Rebholz-Schuhmann D, et al. Predicting knee osteoarthritis severity: Comparative modeling based on patient's data and plain X-ray images. *Sci Rep* 2019;9(1):5761. [Crossref](#)
5. Ahmed U, Anwar A, Savage RS, Thornalley PJ, Rabbani N. Protein oxidation, nitration and glycation biomarkers for early-stage diagnosis of osteoarthritis of the knee and typing and progression of arthritic disease. *Arthritis Res Ther* 2016;18(1):250. [Crossref](#)
6. Antony J, McGuinness K, O'Connor NE, Moran K. Quantifying radiographic knee osteoarthritis severity using deep convolutional neural networks, 2016 23rd International Conference on Pattern Recognition (ICPR), Cancun, Mexico, 2016:1195-1200. [Crossref](#)
7. Dam EB, Lillholm M, Marques J, Nielsen M. Automatic segmentation of high-and low-field knee MRIs using knee image quantification with data from the osteoarthritis initiative. *J Med Imaging* 2015;2(2):024001. [Crossref](#)
8. Laroche D, Tolambiya A, Morisset C, Maillefert JF, French RM, Ornetti P, et al. A classification study of kinematic gait trajectories in hip osteoarthritis. *Comput Biol Med* 2014;55:42-8. [Crossref](#)
9. Liu F, Zhou Z, Samsonov A, Blankenbaker D, Larison W, Kanarek A, et al. Deep learning approach for evaluating knee MR images: Achieving high diagnostic performance for cartilage lesion detection. *Radiol* 2018;289(1):160-9. [Crossref](#)
10. Madelin G, Poidevin F, Makrymallis A, Regatte RR. Classification of sodium MRI data of cartilage using machine learning. *Magn Reson Med* 2015;74(5):1435-48. [Crossref](#)
11. Marques J, Genant HK, Lillholm M, Dam EB. Diagnosis of osteoarthritis and prognosis of tibial cartilage loss by quantification of tibia trabecular bone from MRI. *Magn Reson Med* 2013;70(2):568-75. [Crossref](#)
12. Nagarajan MB, Coan P, Huber MB, Diemoz PC, Glaser C, Wismüller A. Computer-aided diagnosis for phase-contrast X-ray computed tomography: Quantitative characterization of human patellar cartilage with high-dimensional geometric features. *J Digit Imaging* 2014;27:98-107. [Crossref](#)
13. Norman B, Pedoia V, Noworolski A, Link TM, Majumdar S. Applying densely connected convolutional neural networks for staging osteoarthritis severity from plain radiographs. *J Digit Imaging* 2019;32(3):471-7. [Crossref](#)
14. Oka H, Muraki S, Akune T, Mabuchi A, Suzuki T, Yoshida H, et al. Fully automatic quantification of knee osteoarthritis severity on plain radiographs. *Osteoarthritis and Cartilage* 2008;16(11):1300-6. [Crossref](#)
15. Pedoia V, Norman B, Mehany SN, Bucknor, MD, Link TM, Majumdar S. 3D convolutional neural networks for detection and severity staging of meniscus and PFJ cartilage morphological degenerative changes in osteoarthritis and anterior cruciate ligament subjects. *J Magn Reson Imaging* 2019;49(2):400-10. [Crossref](#)
16. von Schacky CE, Sohn JH, Liu F, Ozhinsky E, Jungmann PM, Nardo L, et al. Development and validation of a multitask deep learning model for severity grading of hip osteoarthritis features on radiographs. *Radiol* 2020;295(1):136-45. [Crossref](#)
17. Tiulpin A, Thevenot J, Rahtu E, Lehenkari P, Saarakkala S. Automatic knee osteoarthritis diagnosis from plain radiographs: A deep learning-based approach. *Sci Rep* 2018;29;8(1):1727. [Crossref](#)
18. Üreten K, Arslan T, Gültekin KE, Demir AND, Özer HF, Bilgili Y. Detection of hip osteoarthritis by using plain pelvic radiographs with deep learning methods. *Skeletal Radiol* 2020;49:1369-74. [Crossref](#)
19. Xue Y, Zhang R, Deng Y, Chen K, Jiang T. A preliminary examination of the diagnostic value of deep learning in hip osteoarthritis. *PloS One*, 2017;12(6):e0178992. [Crossref](#)
20. Zhang K, Lu W, Marziliano P. Automatic knee cartilage segmentation from multi-contrast MR images using support vector machine classification with spatial dependencies. *Magn Reson Imaging* 2013;31(10):1731-43. [Crossref](#)
21. Zeng K, Hua Y, Xu J, Zhang T, Wang Z, Jiang Y, et al. Multicentre study using machine learning methods in clinical diagnosis of knee osteoarthritis. *J Healthc Eng* 2021:1-12. [Crossref](#)
22. Chhabra A. Reduce unnecessary joint MRI utilization for already known advanced degenerative disease by incorporating structured templates in X-ray reports to enhance the value-base care. *Eur Radiol* 2023;33(9):6402-3. [Crossref](#)
23. Shim E, Kim JY, Yoon JP, Ki SY, Lho T, Kim Y, et al. Automated rotator cuff tear classification using 3D convolutional neural network. *Sci Rep* 2020;10(1):15632. [Crossref](#)
24. Kim JY, Ro K, You S, Nam BR, Yook S, Park HS, et al. Development of an automatic muscle atrophy measuring algorithm to calculate the ratio of supraspinatus in supraspinous fossa using deep learning. *Comput Methods Programs Biomed* 2019;182. [Crossref](#)
25. Minelli M, Cina A, Galbusera F, Castagna A, Savevski V, Sconfienza LM. Measuring the critical shoulder angle on radiographs: An accurate and repeatable deep learning model. *Skeletal Radiol* 2022;51(9):1873-8. [Crossref](#)
26. Wang G, Li T, Zhu L, Sun S, Wang J, Cui Y, et al. Automatic detection of osteochondral lesions of the talus via deep learning. *Front Phys* 2022;10. [Crossref](#)
27. Shin H, Park D, Kim JK, Choi GS, Chang MC. Development of convolutional neural network model for diagnosing osteochondral lesions of the talus using anteroposterior ankle radiographs. *Medicine (United States)* 2023;102(19):E33796. [Crossref](#)
28. Archer H, Reine S, Alshaikhsalama A, Wells J, Kohli A, Vazquez L, et al. Artificial intelligence-generated hip radiological measurements are fast and adequate for reliable assessment of hip dysplasia: An external validation study. *Bone Jt Open* 2022;3(11):877-84. [Crossref](#)
29. Stotter C, Klestil T, Röder C, Reuter P, Chen K, Emprechtlinger R, et al. Deep learning for fully automated radiographic measurements of the pelvis and hip. *Diagnostics* 2023;13(3). [Crossref](#)

30. Chee CG, Kim Y, Kang Y, Lee KJ, Chae HD, Cho J, et al. Performance of a deep learning algorithm in detecting osteonecrosis of the femoral head on digital radiography: A comparison with assessments by radiologists. *AJR Am J Roentgenol* 2019;213(1):155-62. [Crossref](#)
31. Chen C, Liu P, Feng Y, Lee KJ, Chae HD, Cho J, et al. Diagnostic performance for severity grading of hip osteoarthritis and osteonecrosis of femoral head on radiographs: Deep learning model vs. board-certified orthopaedic surgeons. *OA* 2023;3(2):100092. [Crossref](#)
32. Wang P, Liu X, Xu J, Li T, Sun W, Li Z, et al. Deep learning for diagnosing osteonecrosis of the femoral head based on magnetic resonance imaging. *Comput Methods Programs Biomed* 2021;208:106229. [Crossref](#)
33. Bugeja JM, Xia Y, Chandra SS, Murphy NJ, Eyles J, Spiers L, et al. Automated volumetric and statistical shape assessment of cam-type morphology of the femoral head-neck region from 3d magnetic resonance images. *Quant Imaging Med Surg* 2022;12(10):4924-41. [Crossref](#)
34. Awan JM, Mohd Rahim MS, Salim N, Mohammed MA, Garcia-Zapirain B, Abdulkareem KH. Efficient detection of knee anterior cruciate ligament from magnetic resonance imaging using deep learning approach. *Diagnostics* 2021;11(1):105. [Crossref](#)
35. Bien N, Rajpurkar P, Ball RL, Irvin J, Park A, Jones E et al. Deep-learning-assisted diagnosis for knee magnetic resonance imaging: Development and retrospective validation of MRNet. *PLoS Med* 2018;15(11):e1002699. [Crossref](#)
36. Chang PD, Wong TT, Rasiej MJ. Deep learning for detection of complete anterior cruciate ligament tear. *J Digit Imaging* 2019;32:980-6. [Crossref](#)
37. Chou YT, Lin CT, Chang TA, Wu YL, Yu CE, Ho TY, et al. Development of artificial intelligence-based clinical decision support system for diagnosis of meniscal injury using magnetic resonance images. *Biomed Signal Process Control* 2023;82:104523. [Crossref](#)
38. Couteaux V, Si-Mohamed S, Nempont O, Lefevre T, Popoff A, Pizaine G et al. Automatic knee meniscus tear detection and orientation classification with Mask-RCNN. *Diagn Interv Imaging* 2019;100(4):235-42. [Crossref](#)
39. Fritz B, Marbach G, Civardi F, Fucetese SF, Pfirrmann CW. Deep convolutional neural network-based detection of meniscus tears: Comparison with radiologists and surgery as standard of reference. *Skeletal Radiol* 2020;49:1207-17. [Crossref](#)
40. Germann C, Marbach G, Civardi F, Fucetese SF, Fritz J, Sutter R, et al. Deep convolutional neural network-based diagnosis of anterior cruciate ligament tears: Performance comparison of homogenous versus heterogeneous knee MRI cohorts with different pulse sequence protocols and 1.5-T and 3-T magnetic field strengths. *Invest Radiol* 2020;55(8):499. [Crossref](#)
41. Irmakci I, Anwar SM, Torigian DA, Bagci U. Deep learning for musculoskeletal image analysis. In 2019 53rd Asilomar Conference on Signals, Systems, and Computers 2019;1481-5. [Crossref](#)
42. Liu F, Guan B, Zhou Z, Samsonov A, Rosas H, Lian K, et al. Fully automated diagnosis of anterior cruciate ligament tears on knee mr images by using deep learning. *Radiol Artif Intell* 2019;1(3):180091. [Crossref](#)
43. Namiri NK, Flament I, Astuto B, Shah R, Tibrewala R, Caliva F, et al. Deep Learning for Hierarchical Severity Staging of Anterior Cruciate Ligament Injuries from MRI. *Radiol Artif Intell* 2020;2(4):e190207. [Crossref](#)
44. Rizk B, Brat H, Zille P, Guillin R, Pouchy C, Adam C, et al. Meniscal lesion detection and characterization in adult knee MRI: A deep learning model approach with external validation. *Phys Med* 2021;83:64-71. [Crossref](#)
45. Roblot V, Giret Y, Bou Antoun M, Morillot C, Chassin X, Cotten A, et al. Artificial intelligence to diagnose meniscus tears on MRI. *Diagn Interv Imaging* 2019;100(4):243-9. [Crossref](#)
46. Saygılı A, Albayrak S. An efficient and fast computer-aided method for fully automated diagnosis of meniscal tears from magnetic resonance images. *Artif Intell Med* 2019;97:118-30. [Crossref](#)
47. Štajduhar I, Mamula M, Miletić D, Ünal G. Semi-automated detection of anterior cruciate ligament injury from MRI. *Comput Methods Programs Biomed* 2017;140:151-64. [Crossref](#)
48. Tsai CH, Kiryati N, Konen E, Eshed I, Mayer A. Knee injury detection using MRI with efficiently-layered network (ELNet). *MIDL* 2020:784-94.
49. Morita K, Nii M, Kambara S, Kashiwa K, Nakayama H, Yoshiya S, et al. Clinical big image data based pre-operative planning in ACL reconstruction. In 2016 IEEE International Conference on Machine Learning and Cybernetics (ICMLC) 2016;1:19-23. [Crossref](#)
50. Schock J, Truhn D, Abrar DB, Merhof D, Conrad S, Post M, et al. Automated analysis of alignment in long-leg radiographs by using a fully automated support system based on artificial intelligence. *Radiol Artif Intell* 2021;3(2):e200198. [Crossref](#)
51. Yang CZ, Abdelhameed MA, AlMaen BN, Bernard de Villeneuve F, Fernandes LR, Jacquet C, et al. In slope-changing osteotomy one millimeter is not one degree: results of an artificial intelligence-automated software analysis. *Int Orthop* 2023;47(4):915-20. [Crossref](#)
52. Jeong HW, Kim M, Choi HG, Park SY, Lee YS. Development of a machine learning model to predict lateral hinge fractures by analyzing patient factors before open wedge high tibial osteotomy. *Knee Surg Sports Traumatol Arthrosc* 2023;31(8):3070-3078. [Crossref](#)
53. Zeng G, Schmaranzer F, Degonda C, Gerber N, Gerber K, Tannast M, et al. MRI-based 3D models of the hip joint enables radiation-free computer-assisted planning of periacetabular osteotomy for treatment of hip dysplasia using deep learning for automatic segmentation. *Eur J Radiol Open* 2021;18;8:100303. [Crossref](#)
54. Jonmohamadi Y, Takeda Y, Liu F, Sasazawa F, Maicas G, Crawford R, et al. Automatic segmentation of multiple structures in knee arthroscopy using deep learning. *IEEE Access* 2020;8:51853-61. [Crossref](#)

55. Benhenneda R, Brouard T, Dordain F, Gadéa F, Charousset C, Berhouet J. Can Artificial Intelligence help decision-making in arthroscopy? Part 1: Use of a standardized analysis protocol improves inter-observer agreement of arthroscopic diagnostic assessments of the long head of biceps tendon in small rotator cuff tears. *Orthop Traumatol Surg Res* 2023;103648. [Crossref](#)
56. Marques J, Genant HK, Lillholm M, Dam EB. Diagnosis of osteoarthritis and prognosis of tibial cartilage loss by quantification of tibia trabecular bone from MRI. *Magn Reson Med* 2013;70(2):568-75. [Crossref](#)
57. Ntakolia C, Kokkoti S, Moustakidis S, Tsaopoulos D. Prediction of joint space narrowing progression in knee osteoarthritis patients. *Diagnostics* 2021;11(2):285. [Crossref](#)
58. Jang SJ, Fontana MA, Kunze KN, Anderson CG, Sculco TP, Mayman DJ, et al. An interpretable machine learning model for predicting 10-year total hip arthroplasty risk. *J Arthroplasty* 2023;38(7):S44-S50.e6. [Crossref](#)
59. Ye Z, Zhang T, Wu C, Qiao Y, Su W, Chen J, Xie G, et al. Predicting the objective and subjective clinical outcomes of anterior cruciate ligament reconstruction: A machine learning analysis of 432 patients. *Am J Sports Med* 2022;50(14):3786-95. [Crossref](#)
60. Cho SH, Kim YS. Prediction of retear after arthroscopic rotator cuff repair based on intraoperative arthroscopic images using deep learning. *Am J Sports Med* 2023;51(11):2824-30. [Crossref](#)
61. Lu Y, Labott JR, Salmons IV, Gross BD, Barlow JD, Sanchez-Sotelo J, et al. Identifying modifiable and nonmodifiable cost drivers of ambulatory rotator cuff repair: A machine learning analysis. *J Shoulder Elbow Surg* 2022;31(11):2262-73. [Crossref](#)
62. Lu Y, Pareek A, Wilbur RR, Leland DP, Krych AJ, Camp CL. Understanding anterior shoulder instability through machine learning: New models that predict recurrence, progression to surgery, and development of arthritis. *Orthop J Sports Med* 2021;9(11). [Crossref](#)
63. Vassalou EE, Klontzas ME, Marias K, Karantanis AH. Predicting long-term outcomes of ultrasound-guided percutaneous irrigation of calcific tendinopathy with the use of machine learning. *Skeletal Radiol* 2022;51(2):417-22. [Crossref](#)
64. Hernigou P. Revisiting prediction of collapse in hip osteonecrosis with artificial intelligence and machine learning: A new approach for quantifying and ranking the contribution and association of factors for collapse. *Int Orthop* 2023;47(3):677-89. [Crossref](#)
65. Hernigou P, Verrier S, Homma Y, Rouard H, Lachaniette CHF, Sunil Kumar KH. Prognosis of hip osteonecrosis after cell therapy with a calculator and artificial intelligence: Ten year collapse-free survival prediction on three thousand and twenty one hips. *Int Orthop* 2023;47(7):1689-705. [Crossref](#)
66. Kunze KN, Polce EM, Clapp IM, Alter T, Nho SJ. Association between preoperative patient factors and clinically meaningful outcomes after hip arthroscopy for femoroacetabular impingement syndrome: A machine learning analysis. *Am J Sports Med* 2022;50(3):746-56. [Crossref](#)
67. Myers TG, Ramkumar PN, Ricciardi BF, Urish KL, Kipper J, Ketonis C. Artificial intelligence and orthopaedics: An introduction for clinicians. *J Bone Joint Surg Am* 2020;102(9):830-40. [Crossref](#)
68. Si L, Zhong J, Huo J, Xuan K, Zhuang Z, Hu Y, et al. Deep learning in knee imaging: A systematic review utilizing a Checklist for Artificial Intelligence in Medical Imaging (CLAIM). *Eur Radiol* 2022;32(2):1353-61. [Crossref](#)
69. Durán JM, Jongsma KR. Who is afraid of black box algorithms? On the epistemological and ethical basis of trust in medical AI. *J Med Ethics* 2021;47(5):329-35. [Crossref](#)
70. Burns DM, Leung N, Hardisty M, Whyne CM, Henry P, McLachlin S. Shoulder physiotherapy exercise recognition: Machine learning the inertial signals from a smartwatch. *Physiol Meas* 2018;39(7):075007. [Crossref](#)