



Ortopedi ve travmatolojide karar destek, tedavi başarı tahmini ve ölçme aracı olarak yapay zekâ

Artificial intelligence as a decision support, treatment success prediction and measurement tool in orthopaedics and traumatology

İsmail Demirkale

Sağlık Bilimleri Üniversitesi, Hamidiye Tıp Fakültesi, Prof. Dr. Cemil Taşcıoğlu Şehir Hastanesi,
Ortopedi ve Travmatoloji Kliniği, İstanbul

Bilgisayar sistemleri aracılığıyla yazılım düzeyinde modeller olarak tanımlanabilecek yapay zekâ (YZ) ile YZ'nin makine öğrenimi (MÖ) ve derin öğrenme gibi alt kümesinde yer alan uygulamalar büyük veri setlerini işleyebilirler. Ortopedi ve travmatoloji cerrahisinde işlevsel iyileşme ve iş yükünde hafifleme YZ'nin maliyet analizi, taburculuk süresi tahmini, hasta seçimi ve cerrahi planlamayla hasta takibi gibi idari ve klinik karar destek uygulamaları ile mümkün olmuştur. Klinik karar verme sürecine yardımcı olmak için üç ana türde MÖ yöntemi bulunmaktadır. Bunlar; doğal dil işleme, tanısal ve öngörülse sonuç uygulamaları içeren klinik tahmin ve sonuç hesaplayıcısıdır. Makine öğreniminin klinik karar verme sürecine entegrasyonu, büyük miktarda bilgiyi işleyebilme ve karmaşık desenleri tanımlayabilme yeteneğiyle güçlü bir öngörü aracı olmasını sağlamıştır. Bu uygulamalar, ortopedi ve travmatoloji alanında hastaların daha iyi tedavi edilmesini, hastane yönetiminin daha verimli çalışmasını ve tedavi sonuçlarının iyileştirilmesini amaçlasa da rastgele olmayan eksik veriler, sınırlı örneklem büyüklüğü, hastalık sınıflandırmasının yanlış yapılması ve ölçümlerde uyumsuzluk gibi bazı ön yargılara açık olduğu da bilinmelidir. Ayrıca, bu modellerle elde edilen algoritmalarla elde edilen verilerin hem farklı popülasyonlardan veya katmanlardan gelen verilerle hem de klinik tecrübelerle uyumu sorgulanmalıdır.

Anahtar sözcükler: yapay zekâ, makine öğrenimi, klinik karar destek, tahmin

Through computer systems, applications belonging to artificial intelligence (AI) and its subsets like machine learning (ML) and deep learning, which can be defined as software-level modeling, have the capability to process large datasets. In the field of orthopedics and traumatology surgery, the use of AI enables functional improvement and reduction of workload through administrative and clinical decision support applications such as cost analysis, discharge time estimation, patient selection, surgical planning, and patient monitoring. To assist in the clinical decision-making process, there are three main types of ML methods: natural language processing, clinical prediction, and outcome calculators that include diagnostic and predictive result applications. The integration of ML into the clinical decision-making process has made it a powerful predictive tool with the ability to process large amounts of information and identify complex patterns. While these applications aim to improve the treatment of patients in the field of orthopedics and traumatology, make hospital management more efficient, and enhance treatment outcomes, it should be noted that they are susceptible to certain biases such as non-random missing data, limited sample size, misclassification of diseases, and discrepancies in measurements. Additionally, the compatibility of the data obtained from algorithms derived from these models with data from different populations or strata, as well as with clinical experiences, should be questioned.

Key words: artificial intelligence; machine learning; clinical decision support; prediction

İlk kez 1956 yılında John McCarthy tarafından "akıllı makinelerin bilim ve mühendisliği" olarak kullanılan yapay zekâ (YZ) terimi, bilgisayar teknolojisinin hızlanmasıyla birlikte bilim kurgudan çıkarak neredeyse

günlük hayatın her alanına entegre olmuştur.^[1] Risk analizinde kullanılan ama sınırlı sayıda parametrenin değerlendirilebildiği lojistik regresyon gibi istatistik temelli yöntemler yerine hızla artan grafik işlemci hızı

İletişim / Contact: Prof. Dr. İsmail Demirkale • **E-posta / E-mail:** drismail@yahoo.com

ORCID iD: İsmail Demirkale, 0000-0001-7230-1599

Geliş / Received: 28 Ağustos 2023 • **Revizyon / Revised:** 9 Kasım 2023, 24 Kasım 2023 • **Kabul / Accepted:** 26 Kasım 2023

ve evrensel veri bankaları ile çok daha fazla parametrenin YZ sayesinde çok kısa sürede değerlendirilebilmesi imkânı ortaya çıkmıştır. Bu nedenle, ortopedi ve travmatoloji alanında da bu teknolojinin hastalıkların yönetimini nasıl etkileyeceği merak konusudur. Ortopedi ve travmatoloji uzmanlarının YZ terminolojisi ve metodolojisi hakkında temel bilgiye sahip olmaları çok önemlidir.

YAPAY ZEKÂ ve MAKİNE ÖĞRENİMİ

Yapay zekâ, insan benzeri düşünme ve problem çözme yeteneklerini yüksek hesaplama yeteneklerine sahip bilgisayar sistemleri aracılığıyla yazılım düzeyinde modellemeyi ifade eder. Makine öğrenimi (MÖ) ise temelde eski verilerde bulunan anlamlı ilişkileri matematiksel denklemler ve olasılıksal yaklaşımlar kullanarak analiz edip geliştirilebilir modeller oluşturmayı amaçlar.^[2] Bu modeller, eğitim veri kümesi olarak adlandırılan probleme özgü verilerle eğitilir ve bu sayede veri analizi yapılır. Birden fazla MÖ modeli mevcuttur; bunlar arasında karar ağaçları, destek vektör makineleri, regresyon analizi ve Bayes ağları gibi yöntemler vardır.^[3] Ayrıca, derin öğrenme (DÖ) olarak adlandırılan MÖ alt alanı da geliştirilmiştir. Bu alt alan, yapay sinir ağları (YSA) modellerini içerir. Bu modellerin avantajı, verilerin önceden etiketlenmesine ihtiyaç duymadan ham girdileri analiz edebilmeleridir.

Ortopedi ve travmatoloji alanında YZ ve MÖ şu iki ana kategoride uygulanmaktadır:

A. İdari ve Klinik Karar Destek Uygulamaları: Bu kategori, hastane yönetimi ve hasta tedavi süreçlerini geliştirmeye yönelik YZ/MÖ uygulamalarını içerir. Bu uygulamalar şunları içerebilir:^[4]

a. Maliyet analizi: Yapay zekâ/MÖ, tedavi maliyetlerini tahmin etmek ve optimize etmek için kullanılabilir. Böylece hastane yönetiminin bütçe planlamasını iyileştirebilir.

b. Taburculuk/kalış süresi tahmini: Makine öğrenimi, hastaların taburcu edilme zamanını tahmin etmek için kullanılması hastanede yatış sürelerini daha iyi planlamayı sağlayabilir.

c. Hasta seçimi ve planlaması: Yapay zekâ/MÖ, hangi hastaların hangi tedavi yöntemlerine daha iyi yanıt verebileceğini tahmin etmek için kullanılabilir.

d. Yeniden yatış ve yeniden ameliyat riski tahmini: Makine öğrenimi, hastaların tedavi sonrası yeniden yatış veya yeniden ameliyat olasılıklarını tahmin etmek için kullanılabilir. Böylece hasta memnuniyetini artırabilir.

B. Ameliyat Sonrası Komplikasyon Hızı ile İyileşme Oranının Tahmini

Bu kategori, cerrahi müdahalelerin sonuçlarını ve potansiyel komplikasyonları tahmin etmeye odaklanır. Bu uygulamalar şunları içerebilir:^[4]

a. Cerrahi sonuç tahmini: Makine öğrenimi, belirli bir cerrahi operasyonun başarısını ve sonuçlarını tahmin etmek için kullanılabilir.

b. Komplikasyon riski tahmini: Yapay zekâ/MÖ sayesinde önleyici önlemler alınabilir.

c. Tedavi sonrası izleme: Hastaların ameliyat sonrası izleme süreçleri YZ/MÖ tarafından yönlendirilebilir, böylece potansiyel sorunlar erken teşhis edilebilir ve tedavi edilebilir.

Bu uygulamalar, ortopedi ve travmatoloji alanında hastaların daha iyi tedavi edilmesini, hastane yönetiminin daha verimli çalışmasını ve tedavi sonuçlarının iyileştirilmesini amaçlamaktadır.

A. İdari ve Klinik Karar Destek Uygulamaları

Klinik karar destek (KKD) algoritmaları temelde tahmin modelleridir. Bu algoritmalar, hastaların sonuçlarını hesaplamak veya belirli girdi değişkenlerine dayalı olarak hastaları risk açısından sınıflandırmak için kullanılırlar. Bu tahminler, genellikle olasılık biçiminde sunulur. Örneğin; hastanın yaşı, eş zamanlı hastalıkları veya laboratuvar sonuçları gibi faktörlere dayalı olarak bir hastanın belirli bir sonucu yaşama olasılığını hesaplanabilirler.^[4]

Mevcut klinik karar verme sorunlarına çözüm arayışında çeşitli çalışma tasarımları kullanılmaktadır ve bu tasarımlardan elde edilen veriler, MÖ kullanarak öngörü modelleri oluşturmak için kullanılabilir. Geriye dönük (retrospektif), ileriye dönük (prospektif), ulusal kayıt verileri ve iç içe (*nested*) vaka-kontrol çalışmaları için prediktif modellemeler daha uygunken, kesitsel ve vaka-kontrol çalışma tasarımları tanısız modellemeye daha iyi uyar. Makine öğreniminin faydaları, özellikle daha büyük ve düzenli olarak güncellenen veri kümeleri üzerinde daha iyi fark edilir. Genellikle en az 200 olay ve en az 200 olumsuz durumu içeren verilerin kullanılması önerilir.^[5] Bu algoritmalar, olasılıksal bir yaklaşımı benimser ve belirli bir teşhisi daha olası veya daha az olası olarak değerlendirirken aynı zamanda belirsizliği belirli bir derecede korur. Bu olasılıksal perspektif, kanıta dayalı teşhisin ve Bayesçi teşhis akıl yürütmenin temelini oluşturur.^[5]

Yapay zekâ destekli KKD uygulamalarının ortopedi ve travmatoloji cerrahisinde geniş bir yelpazede kullanım alanları bulunmaktadır. Bu alanlar arasında kırık tespiti ve sınıflandırılması, kemik boyutlarının ölçülmesi, artroplasti ameliyatları için ameliyat öncesi ölçümler, kemik iliği hastalıklarının teşhisi ve kemik tümörlerinde tedavi yanıtının izlenmesi sayılabilir (Tablo 1).^[4] Bu uygulamalar, klasik karar verme süreçlerini yakın gelecekte ciddi şekilde değiştirme potansiyeline sahiptir.

Tablo 1. Yapay zekânın ortopedide sunduğu özel uygulamalar^[4]

Uygulama	Açıklama
İskelet radyograflerinin doğru analizi	<ul style="list-style-type: none"> Görüntü işleme tabanlı yapay zekâ teknikleri, iskelet radyografisinde görüntünün en küçük ayrıntılarını gösterebilir. Tedaviden sonra bir kırığın iyileşme sürecini karşılaştırabilir.
Cerrahi eğitim	<ul style="list-style-type: none"> Tıp öğrencilerinin cerrahi eğitimi, gerçek hastaları dâhil etmeden simüle edilebilir. Kırık bir kemiğin verilen verilerinin yardımıyla en iyi tedavi yöntemleri hakkında bilgi edinilir.
Tedavi ve koordinasyon	<ul style="list-style-type: none"> Teşhis ve tedavi sırasında hastaların verilerini saklayabilir. Hasta ve cerrah arasında mükemmel koordinasyonu sağlayabilir. Ağrı, muayene, hastalığın nedeni ve diğer tıbbi problem türleri hakkında uyarı verebilir.
Robot yardımcı ortopedi cerrahisinin daha iyi performans göstermesi	<ul style="list-style-type: none"> Ortopedi cerrahlarının performansı operasyon sırasında analiz edilip kontrol edilebilir ve beceri geliştirme için önerilerde bulunabilir. Cerrahi aletlerin optimal kullanımını yoluyla robot yardımcı cerrahiye daha iyi gerçekleştirme potansiyeline sahiptir.
Hastanede kalış süresini ve takip ziyaretlerini azaltma	<ul style="list-style-type: none"> Cerrahi sonuçları iyileştirir ve böylece hastanede kalış süresini azaltır. Bir cerrahın ortopedi ve travma cerrahisi yaparken hataları en aza indirmesine yardımcı olur. Hastaneye gereksiz ziyaretleri azaltmak için hastayla ilgili tüm gerekli bilgileri sağlar.
Problem çözme	<ul style="list-style-type: none"> Yapay zekâ, doktorların/cerrahların daha iyi teşhis, tedavi ve ameliyat sağlamalarına yardımcı olur. Planlama, öğrenme, konuşma ve problem çözme yeteneğine sahip tıbbi cihazlarda/makinelerde/aletlerde zekâ oluşturur.

Klinik karar verme sürecine yardımcı olmak için üç ana türde MÖ yöntemi kullanılmaktadır. Bunlardan ilki doğal dil işleme (DDİ)'dir ve bilgisayarın insan dilini anlama ve analiz etme yeteneğine dayanır.^[5] Doğal dil işlemenin amacı bir hastanın tıbbi kayıtlarını ya da ameliyat raporlarını verilere dönüştürmek ve belirli bir teşhis veya bulgu hakkında sorgular yapmak için kullanmaktır. İkinci tür, klinik tahmin olarak adlandırılır, tanısal ve öngörülse sonuç uygulamalarını içerir.^[6] Üçüncü tür ise sonuç hesaplayıcısıdır ve risk tabakalaması yoluyla tedavi tutarsızlıklarını ele alabilir ve hastaların fonksiyonel sonuçlarını iyileştirebilirken sağlık maliyetlerini azaltabilir. Bu nedenle, yüksek hasta hacmi gerektiren bakımlar-

da, günlük karar verme süreçlerinde küçük ancak anlamlı değişiklikler, genel halk sağlığını önemli ölçüde iyileştirebilir. Ortopedi ve travmatolojide, MÖ ile türetilmiş karar araçları, artroplastik, travma, onkoloji ve omurga bozuklukları gibi alanlarda kullanılmış ve cerrahlara tedavi sonuçlarında yardımcı olmak amacıyla geliştirilmiştir. Başka bir kullanım alanı ise DÖ'nün bir alt alanı olan kırık tanımlamasıdır. Kırık tedavisi gibi tanısal karar verme süreçlerine yardımcı olmak için faydalı olabilir. Evrimsel sinir ağlarının bu amaç için etkili olduğu kanıtlanmıştır. Ancak, YZ teknolojisinin bazı sınırlamaları da mevcuttur ve klinik uygulamalarda göz önünde bulundurulmalıdır (Tablo 2).^[4]

Tablo 2. Yapay zekânın sınırlamaları^[4]

Uygulama	Açıklama
Sadece verilen verilerden öğrenir.	<ul style="list-style-type: none"> Yapay zekâ yalnızca hastanın verilen verilerinden öğrenir. Ameliyatın doğruluğu yakalanan verilere bağlıdır.
Kullanılan YZ/MÖ algoritmasının doğruluk payı	<ul style="list-style-type: none"> Önemli dezavantajlardan biri, tedavi ve hatta daha fazlası için çok önemli olan, kullanılan MÖ/YZ algoritması tarafından yapılan tahminin doğruluk yüzdesidir. Muhtemel tahmin sonucu, bir YZ rolünün mutlak bir yol olup olmadığı veya zaman içinde daha fazla veriye ve eğitime ihtiyaç duyup duymadığına dair cevap olacaktır.
Duygusuzdur.	<ul style="list-style-type: none"> Duygusuzdur; insan düşüncesini ve doğru karar verme nedenlerini anlamaz. Bu teknoloji yalnızca programlandığı şeyi yapar. Doğru sonucu yansıtmaktan başka bilgisi yoktur.
Uygun denetim gerektirir.	<ul style="list-style-type: none"> Tedavi sırasında uygun gözetim ve veri toplama gerektirir; aksi takdirde doktorlar ve cerrahlar güvenilir sonuçlar elde edemezler. Yalnızca güvenilir veriler yeterli sonuçlar sağlar.
Yaratıcı düşünme sağlamaz.	<ul style="list-style-type: none"> Ortopedide yaratıcı düşünme ihtiyacını insan gibi yerine getiremez çünkü insan hissedebilir, düşünebilir ve makinenin yapamayacağına dair değerli kararlar verebilir. Bu teknoloji ile veri olmadan yeni kararlar alınmaz.

YZ: Yapay zekâ, MÖ: Makine öğrenimi.

Hastalıklar, kurullarla açıklanamayacak ve yorumlanamayacak kadar karmaşıklık gösterirler. Ancak sürekli büyüyen veri bankaları sayesinde hastaların verileri daha fazla erişilebilir hâle gelmiştir. Böylece YZ modellerinin gerçek zamanlı tahminler ve öneriler sunabilmesi sağlanmıştır. ABD’de 2009 yılında kabul edilen Sağlık Bilgi Teknolojileri Ekonomi ve Klinik Sağlık Yasası ile elektronik sağlık kayıt (ESK) sistemlerinin benimsenmesi, hasta verilerinde inanılmaz bir artışa yol açmıştır. Yapay zekâ, bu ESK sistemlerinden elde edilen verilere otomatik olarak erişebilir. Böylece manuel veri arama ve giriş işlemlerine gerek kalmadan verilere erişim sağlanır ve klinik karar verme sürecinde önemli bir engeli ortadan kaldırır. İleriye dönük karşılaştırmalı bir çalışmada, “MySurgeryRisk” isimli makine öğrenimi algoritmasının doktorlardan daha yüksek doğrulukla ameliyat sonrası olası komplikasyonları tahmin ettiği gösterilmiştir.^[7]

Cerrahi karar verme sürecine YZ’nin başarılı bir şekilde entegrasyonu için veri standardizasyonu, modelin yorumlanabilmesi, dikkatli uygulama ve izleme, etik zorluklara dikkat etme ve karar verme sürecinde yatak başı değerlendirmenin ve insan sezgisinin korunması gibi birtakım faktörlere dikkat edilmesi gerekir. Yapay zekâ modelleri, prospektif klinik uygulamaya geçmeden önce titiz bir geriye dönük analiz ve harici doğrulama gerektirir. Aynı zamanda, deneyimli cerrahlar ve veri bilimcileri tarafından yakından gözlemlenmelidir. Yapay zekâ, ameliyat kararlarını destekleyerek, bilgilendirilmiş onam sürecini güçlendirerek, değiştirilebilir risk faktörlerini belirleyerek ve azaltarak, komplikasyonları tanımlayarak ve yöneterek, kaynak kullanımı konusunda paylaşılan kararlar alarak cerrahi tedaviyi iyileştirebilir.

Makine öğrenimi algoritmalarının tahmin performansı Steyerberg’un yapılandırılmış ABCD yaklaşımına göre değerlendirilir:

A) Model Intercept: Modelin büyük ölçekte kalibrasyonunu ifade eder.

B) Kalibrasyon Eğimi: Modelin kalibrasyonunu değerlendirir.

C) Ayırt Etme: Modelin ayırt etme yeteneğini bir uyum istatistiğiyle değerlendirir.

D) Klinik Kullanışlılık: Karar eğrisi analizi ile modelin klinik kullanılabilirliğini değerlendirir. Ayrıca, genel model performansı Brier skoru kullanılarak değerlendirilip boş model Brier skoru ile karşılaştırılır.^[8]

B. Ameliyat Sonrası Komplikasyon Hızı ile İyileşme Oranının Tahmini

Ameliyat sonrası tahmin kategorileri beş alt başlıkta toplanabilir; ameliyat sonrası komplikasyonlar, ağrı

şiddeti, mortalite hızı, klinik sonuçlar ve sürekli opioid kullanımı. Makine öğrenimi modelleri, özellikle ameliyat sonrası komplikasyonları öngörme, bu komplikasyonları önleme veya yönetme, hastanın sonuçlarını optimize etme ve kişiselleştirilmiş ameliyat sonrası yönetim protokolleri oluşturmada önemli bir rol oynayabilirler. Ancak, diğer klinik araştırma biçimleri gibi hâlâ bazı ön yargılara açıktırlar.^[9] Bu ön yargılar şunlar olabilir:

1. Rastlantısal olmayan eksik veriler: Veri setlerinde eksik veya rastlantısal olmayan verilerin bulunması model sonuçlarını etkileyebilir ve ön yargılara yol açabilir.

2. Aşırı uyum (Overfitting): Modelin eğitim verilerine aşırı uyum sağlaması yeni verilere genelleme yapma yeteneğini sınırlayabilir.

3. Sınırlı örneklem büyüklüğü: Modelin eğitiminde kullanılan veri örneklem büyüklüğünün sınırlı olması, modelin doğruluğunu ve genelleştirilebilirlik yeteneğini etkileyebilir.

4. Hastalık sınıflandırmasının yanlış yapılması

5. Gözlemciler arası/içi ölçümde uyumsuzluk

6. Değişken sayısı: Modelin hangi değişkenleri kullanacağı, araştırmacının inançlarına veya veri toplama yeteneğine bağlı olabilir.

7. Veri kaynakları: Bazı ulusal veri setleri, ayrıntılı veri sağlayamayacağı gibi araştırma dışı amaçlar için oluşturulmuş verilerden oluşabileceği için hatalara yol açabilir.

8. Örneklem büyüklüğü ve nüfus: Modelin eğitildiği örneklem büyüklüğü ve nüfus, genelleştirilebilirlik yeteneğini etkiler.

9. Cinsiyet ve etnik köken bilgileri: Makine öğrenme modellerinde cinsiyet ve etnik köken bilgilerinin kullanımı, veriye dayalı tahmin modellerinde ön yargı konusunda etik kaygılara neden olabilir ve adil olmayan sonuçlara yol açabilir.

Bu nedenle, MÖ modellerinin oluşturulması ve kullanımını dikkatli bir şekilde yapılmalıdır. Verilerin doğru ve dengeli olması, modelin sağlam bir şekilde eğitilmesi, ön yargıların azaltılması ve etik kaygıların göz önünde bulundurulması önemlidir.

Klinik uygulamaya geçmeden önce algoritmanın performansını ve genelleştirilebilirlik yeteneğini değerlendirmek için harici doğrulama büyük bir öneme sahiptir. Harici doğrulama, algoritmanın eğitim verileri dışındaki veri setleri üzerinde test edilmesi anlamına gelir. Bu, modelin sadece eğitildiği verilere değil, farklı popülasyonlardan veya farklı zaman dilimlerinden gelen verilere de nasıl tepki verdiğini değerlendirmeyi sağlar. Harici doğrulamanın faydaları şunlar olabilir:

1. Genelleştirilebilmeyeyle modelin farklı popülasyonlar arasında veya farklı coğrafi bölgelerde ne kadar iyi performans gösterdiğini belirler.

2. Daha güvenilir sonuçlar sağlar. Modelin sadece eğitildiği verilere dayanarak alınan sonuçlar, genellikle yanıltıcı olabilir.

3. Zaman içinde veya farklı coğrafi bölgelerde kullanılabilme yeteneğini değerlendirmek için kullanışlıdır.

ORTOPEDİ ve TRAVMATOLOJİ ALT BRANŞLARINDA YAPAY ZEKÂ DESTEKLİ ÖRNEK UYGULAMALAR

Tahmine dayalı analizlere örnek olarak Ramkumar ve ark.'nın yaptıkları çalışma gösterilebilir. Yaş, etnik köken, cinsiyet ve komorbiditeler gibi hasta özelliklerine göre total diz ve kalça artroplastisinin ardından kalış süresini ve maliyeti doğru bir şekilde tahmin etmek için Bayes yaklaşımını kullanmışlardır.^[10] Bir diğer çalışmada Harris ve ark. eklem replasman cerrahisi sonrası 30 günlük mortalite ve kardiyak komplikasyon hızını tahmin etmek için *Least Absolute Shrinkage and Selection Operator* (LASSO) modelini kullanmışlardır.^[11] Cerrahi sonrası anlamlı kazanımlar elde edememe riski taşıyan hastaların belirlenmesine odaklanan ve metodolojik olarak oldukça karmaşık olmasına karşın çok ilginç bulguların sunulduğu bir diğer çalışmada destek vektör makinesi (DVM), LASSO ve rastgele orman algoritmaları (*random forest*) karşılaştırılmış ve hepsinin benzer orta-iyi tahmin gücüne sahip olduğu bulunmuştur.^[12] *Least Absolute Shrinkage and Selection Operator* ve DVM yaklaşımlarının birleştirilmesi ameliyat öncesi iş akışını kolaylaştırarak YZ tabanlı ameliyat öncesi planlamayı önemli ölçüde iyileştirmektedir.^[13]

Omurga patolojilerini teşhis etmek, omurga cerrahisinde YZ araştırmalarının temel odak noktalarından birisidir. Omurga patolojilerinin teşhisinde MÖ'nün kullanımı 1980'lere kadar dayanır. Görüntüleme ile omurga patolojilerinin tanısında "eğer-ise" gibi aynı kuralları takip eden yapay zekâ algoritmaları ya da Bayes sınıflandırıcıları gibi temel makine öğrenimi teknikleri ile kullanılabilir. Bu yöntemler, bilgisayarlı tomografideki Hounsfield birimi ya da manyetik rezonans görüntülemeindeki sinyal yoğunluğu olarak tanımlanan görüntü piksel değerlerini kullanır. İntervertebral diskleri dejenere veya normal olarak sınıflandırmak üzere DVM tabanlı bir modeli eğitmek için görüntü piksel değeri ve doku bilgisine ek olarak diskin şekli gibi morfolojik bilgilerin de kullanıldığı bir çalışmada %92'ye varan doğruluk tespit edilmiştir.^[14] Pfirrmann sınıflandırmasına göre disk dejenerasyonunun sınıflandırılmasında nöral ağ kullanımını eğitmek ve test etmek için lomber omurga manyetik rezonans görüntülerinin (MRG) kullanıldığı bir diğer çalışmada ise %93 özgüllük ve %83 duyarlılık bildirilmiştir.^[15]

Ortopedik onkolojide YZ kullanımına yönelik temel uygulama, tümörlerin görüntüleme tabanlı teşhisi olmuştur. Evrişimli sinir ağları kullanılarak 1.060 olgunun T1- ve T2-ağırlıklı ameliyat öncesi MRG kesitinin kullanıldığı ve iyi huylu ve kötü huylu birincil kemik tümörlerini ayırt etmek için eğitildiği bir çalışmada radyologlarınki ile aynı olan %73 doğruluk oranı bildirilmiştir.^[16] Bu tür algoritmaların geliştirilmesi, ara vakalar için görüntü tabanlı teşhise yardımcı olabilir, dolayısıyla invaziv teşhis prosedürlerine olan ihtiyacı azaltabilir. Onkolojinin bir diğer önemli alanı da arda kalan yaşam beklentisini doğru bir şekilde tahmin etmektir. Han ve ark., sinoviyal sarkomlu hastaların hayatta kalma oranlarını tahmin etmek için DÖ'yü kullanmışlardır. Tümör boyutu, konumu, ilk metastaz ve tedavi yöntemi gibi demografik ve klinik verileri kullanan eğitilmiş bir sinir ağı modelinin, sırasıyla 0,63'e kıyasla 0,81'lik eğri altında kalan alan (AUC) ile Cox orantılı tehlike modeline kıyasla daha gelişmiş performans gösterdiği bulunmuştur.^[17]

Makine öğrenimi algoritmaları, primer kemik tümörlerinin cerrahi tedavi sonrası lokal nüks oranının tahmininde de kullanılabilir. Örneğin, proksimal tibia tutulumu, genç yaş, düzensiz kenarlar veya boya fırçası-sınır işareti ve bitişik yumuşak doku invazyonu gibi faktörler, dev hücreli kemik tümörü nüks oranının artmasıyla ilişkilendirilmiştir.^[18] Evrişimli sinir ağları modelinin kullanıldığı bu çalışmada nüksü doğru tahmin etmede %78,6'lık bir doğruluk oranı bildirilmiştir.^[19]

Yapay zekânın en önemli uygulamalarından bir diğeri de görüntü bölümleridir. Bu algoritmaların ana faydası, tümör yükü analizi veya dilim dilim segmentasyonla manuel olarak yapılması gereken tüm vücut segmentasyonu gibi görevlerin çok daha kısa sürede gerçekleştirilebilmesidir. Ortopedik onkolojide, neoadjuvan kemo-radyoterapi planlaması ve ameliyat sonrası tedavi etkinliğinin değerlendirilmesi gibi klinik karar vermeye yönelik bir dizi nicel bilgi sağlamak için görüntü segmentasyonları kullanılabilir. Bu alandaki araştırmaların çoğu, kemik yapılarının görüntülenmesi için yüksek kontrastı ve uzaysal çözünürlüğü nedeniyle BT'ye odaklanmıştır. Zhang ve ark., 23 osteosarkom hastasında tümör dokusunu BT ile segmentlere ayırmak için çoklu denetimli artık ağı kullanmışlar ve bu ağ ile radyolog tarafından sağlanan segmentasyonlar karşılaştırıldığında %89,2'lik Sorenson-Dice benzerlik katsayısı elde etmişlerdir.^[20]

SONUÇ

Makine öğrenme yöntemlerine karşı ön yargılar kalktığında ve klinik etkinliği gösterildiğinde hasta tedavi süreçleri olumlu etkilenecektir. Makine öğrenme destekli uygulamalar planlama, risk analizi gibi tahmin analitik-

leriyle bilgisayar görüşü ve artırılmış gerçeklik gibi teknolojilerle cerrahların verimliliğini arttıracaktır.

KAYNAKLAR

- Toosi A, Bottino AG, Saboury B, Siegel E, Rahmim A. A brief history of AI: How to prevent another winter (a critical review). *PET Clin* 2021;16(4):449-69. [Crossref](#)
- Hamet P, Tremblay J. Artificial intelligence in medicine. *Metabolism* 2017;69S:36-40. [Crossref](#)
- Harrison CJ, Sidey-Gibbons CJ. Machine learning in medicine: A practical introduction to natural language processing. *BMC Med Res Methodol* 2021;21(1):158. [Crossref](#)
- Haleem A, Vaishya R, Javaid M, Khan IH. Artificial Intelligence (AI) applications in orthopaedics: An innovative technology to embrace. *J Clin Orthop Trauma* 2020;11(Suppl 1):80-1. [Crossref](#)
- Murugesan U, Subramanian P, Srivastava S, Dwivedi A. A study of Artificial Intelligence impacts on Human Resource Digitalization in Industry 4.0. *DA* 2023;7:100249. [Crossref](#)
- Cai T, Giannopoulos AA, Yu S, Kelil T, Ripley B, Kumamaru KK, et al. Natural language processing technologies in radiology research and clinical applications. *Radiographics* 2016;36:176-91. [Crossref](#)
- Veronezi CC, de Azevedo Simões PW, Dos Santos RL, da Rocha EL, Melão S, de Mattos MC, et al. Computational analysis based on artificial neural networks for aiding in diagnosing osteoarthritis of the lumbar spine. *Rev Bras Ortop* 2015;46(2):195-9. [Crossref](#)
- Brennan M, Puri S, Ozrazgat-Baslanti T, Feng Z, Ruppert M, Hashemighouchani H, et al. Comparing clinical judgment with the MySurgeryRisk algorithm for preoperative risk assessment: A pilot usability study. *Surgery* 2019;165(5):1035-45. [Crossref](#)
- Steyerberg EW, Vergouwe Y. Towards better clinical prediction models: Seven steps for development and an ABCD for validation. *Eur Heart J* 2014;35:1925-31. [Crossref](#)
- 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](#)
- Ramkumar PN, Navarro SM, Haerberle HS, Karnuta JM, Mont MA, Iannotti JP, et al. Development and validation of a machine learning algorithm after primary total hip arthroplasty: Applications to length of stay and payment models. *J Arthroplasty* 2019;34(4):632-7. [Crossref](#)
- Harris AHS, Kuo AC, Weng Y, Trickey AW, Bowe T, Giori NJ. Can machine learning methods produce accurate and easy-to-use prediction models of 30-day complications and mortality after knee or hip arthroplasty? *Clin Orthop Relat Res* 2019;477(2):452-60. [Crossref](#)
- Fontana MA, Lyman S, Sarker GK, Padgett DE, MacLean CH. Can machine learning algorithms predict which patients will achieve minimally clinically important differences from total joint arthroplasty? *Clin Orthop Relat Res* 2019;477(6):1267-79. [Crossref](#)
- Lambrechts A, Wirix-Speetjens R, Maes F, Van Huffel S. Artificial intelligence based patient-specific preoperative planning algorithm for total knee arthroplasty. *Front Robot AI* 2022;9:840282. [Crossref](#)
- Shijie Hao, Jianguo Jiang, Yanrong Guo, Hong Li. Active learning based intervertebral disk classification combining shape and texture similarities. *Neurocomputing* 2013;101:252-7. [Crossref](#)
- Berg-Johansen B, Han M, Fields AJ, Liebenberg EC, Lim BJ, Larson PE, et al. Cartilage endplate thickness variation measured by ultrashort echo-time mri is associated with adjacent disc degeneration. *Spine (Phila Pa 1976)* 2018;43(10):E592-E600. [Crossref](#)
- Eweje FR, Bao B, Wu J, Dalal D, Liao WH, He Y, et al. Deep learning for classification of bone lesions on routine MRI. *EBioMedicine* 2021;68:103402. [Crossref](#)
- Han I, Kim JH, Park H, Kim HS, Seo SW. Deep learning approach for survival prediction for patients with synovial sarcoma. *Tumour Biol* 2018;40(9):1010428318799264. [Crossref](#)
- He Y, Wang J, Rui W, Lin J, Yuan F, Du L, et al. Retrospective investigation of "paint brush borders" sign in association with local recurrence of giant cell tumor of bone after intralesional curettage. *J Bone Oncol* 2017;10:41-8. [Crossref](#)
- He Y, Wang J, Zhang J, Yuan F, Ding X. Erratum to: A prospective study on predicting local recurrence of giant cell tumour of bone by evaluating preoperative imaging features of the tumour around the knee joint. *Radiol Med* 2017;122(7):556. [Crossref](#)
- Zhang R, Huang L, Xia W, Zhang B, Qiu B, Gao X. Multiple supervised residual network for osteosarcoma segmentation in CT images. *Comput Med Imaging Graph* 2018;63:1-8. [Crossref](#)