

BÖLÜM 1

ORTOPEDİK CERRAHİDE DERİN ÖĞRENME

Gökhan GÜZEL¹

GİRİŞ

İkinci dünya savaşının başlaması sonrası bilim insanlarının savaşta şifreleme sistemlerini çözme çabası, bilgisayar sistemlerinin modernleşmesi ve "Makineler düşünebilir mi?" kuramıyla Alan Turing tarafından ortaya atılan teori yapay zekâ kavramı için bir başlangıç olmuştur. İlk olarak dama ve satranç oyunlarında çeşitli yapay zekâ çalışmaları sonrası, 1959'da Arthur Samuel'in programlanma olmaksızın öğrenme kabiliyeti kazanma şeklinde yapay zekâ kavramını bir ileri aşamaya götürmesi makine öğrenmesinin temellerini atmıştır. Günümüze kadar yapay zekâ kavramı makine öğrenmesi, derin öğrenme şeklinde modern teknoloji çağının gerekliliklerine uygun olarak ilerlemiştir. Derin öğrenme ile ilgili günümüzde kavramsal karmaşıklıklar mevcutken, Frank Rosenblatt'ın 1962 yılında modern derin öğrenme ile ilgili tüm bileşenleri tanımladığını ve araştırdığını gösteren çalışmaları temel kabul edilir (1). Derin öğrenmenin tanımlanması ve bu yıllardan sonra derin öğrenme ve insan nöron yapısı benzeri sinir ağı sistemleri üzerindeki çalışmalar günümüze kadar devam edip son halini almıştır. Aslında derin öğrenme algoritmaları 21. yy'da modern yaşamın birçok alanında Google gibi arama motorları, Twitter gibi sosyal medya alanları, Amazon benzeri alışveriş sistemlerinde kullanılan öneri sistemleriyle hayatımızın içinde bulunuyor. Askeri alan başta olmak üzere, ilaç ve banka endüstrisinde, çeşitli reklam endüstrilerinde, tıp alanında (özellikle tıbbi görüntü alanında), android teknolojilerinde sıkça kullanılmaya başlanmıştır. Tıbbi görüntü alanında ilk çalışmalar dermatoloji alanında (cilt lezyonlarının değerlendirilmesi) başlarken (2), bilgisayarlı tomografi ve manyetik rezonans görüntüleme (MRG) ile radyoloji ve X-ray ile ortopedi ve travmatoloji alanında geliştirilerek ilerlemiştir. Ortopedi alanında popülerite kazanması son 5 yılda olurken, 3 yıl içinde literatürde 1000'den fazla çalışma olmasıyla yoğunlaşmıştır. Bu makaleyi yazma amacımız teknoloji çağında evimize ve telefonlarımıza kadar girmiş olan yapay zekâ ve derin öğrenme sistemlerinin kısaca çalışma prensipleri, ortopedi ve travmatoloji branşında kullanım alanları ve pratik uygulamada kullanılabilirliği hakkında fikir sahibi olmaktır.

¹ Uzm. Dr., Aksaray Tıp Fakültesi Ortopedi ve Travmatoloji AD., dr.g.guzel@gmail.com

YAPAY ZEKÂ VE MAKİNE ÖĞRENMESİ

20. yüzyılda bilgisayar sistemlerinin modernleşmesi ve 2. dünya savaşının getirdiği gereklilikler sonrası “yapay zekâ” kavramı ortaya çıkmıştır. 1951’de Alan Turing Mind dergisinde “Makineler düşünebilir mi?” kuramını ortaya atarak, modern yapay zekâ kavramının fikir babası olarak kabul edilir.

Yapay zekâ; insan zekâsına has, yüksek bilişsel durumlar ve otonom davranışları insan beyni ve öğrenme kabiliyetini rol model kabul ederek sergilemeyi amaçlayan yapay bir işletim sistemidir. Yapay zekâ, tipik olarak insan bilgisi gerektiren görevleri, insanların sorunları nasıl çözdüğünü örnek alarak benzer şekilde gerçekleştiren herhangi bir makineyi ifade edebilir. Genel olarak makine öğrenimini kapsayan bir şemsiye terminoloji olarak kullanılır. Makine öğrenimi, makinenin giriş ve çıkış verileri arasındaki ilişkiyi nasıl yapılacağı açıkça söylenmeden “öğrenmesini” sağlayan bir dizi matematiksel algoritmayı ifade eder (3). Başka bir ifadeyle verilerden otomatik olarak kalıpları veya özellikleri çıkarmayı ve bu tür veri eğilimlerini deneyim biçiminde kullanmayı amaçlayan bir yapay zekâ dalıdır. Bu şekilde makine öğrenimi, zamanla gelişen ölçülebilir bir performansla bilinçli kararlar verebilir. 1959 yılında Arthur Samuel makine öğrenmesini “programlanmaya gerek duyulmadan yapay zekaya öğrenme yeteneği verebilme” olarak tanımladı (4). Böylece ilk olarak satranç ve dama oyunlarında makine öğrenmesinin kullanılmasına öncülük etti. Makine öğrenmesi ile başlayan bu süreç derin öğrenme, insan nöronal yapısının öğrenme kabiliyetini taklit etme ve evrimsel sinir ağları (convolutional neural network [CNN]) ile hız kazanarak günümüze kadar ilerleyerek geldi.

DERİN ÖĞRENME

Yapay zekanın son zamanlardaki gelişimi göz önüne alındığında birçok gereklilik ortaya çıktı. Kendini çevreleyen dünyayı bağımsız olarak anlayacak ve önsel özellik tanımlamak olmaksızın anlamlı bilgilerin çıkarılmasını sağlayacak akıllı sistemlerin ihtiyacı doğmuştur. Bu anlamlı bilgi kavramlara benzetilebilir. Genellikle hiyerarşik şekilde yapılandırılmıştır; karmaşık kavramlar, birçok basit kavramın farklı soyutlanma seviyelerinde kaynaşması olarak yorumlanır (5). Bu sinir ağı adı verilen bir algoritma kullanımına dayanan öğretici derin öğrenmenin temel fikrini oluşturur. Sinir ağlarının tasarımında, beyindeki nöronlardan ve karmaşık bilişsel görevleri yerine getirirken çalışma mantığından yola çıkılmıştır. Sinir ağlarının, evrensel yaklaşım teoremine uydukları ve matris çarpma işlemleri yoluyla girdi özelliklerinin çıktılara eşleşmesine izin vermeleri derin öğrenme kavramını ortaya çıkarmıştır. Başka bir ifadeyle teorem, yeterli nöron ve doğrusal olmayan akti-

vasyon fonksiyonları oluşturulduğunda sinir ağlarının herhangi bir ayrık uzaydan diğerine haritalayan fonksiyona yaklaşabileceğini belirtir (6).

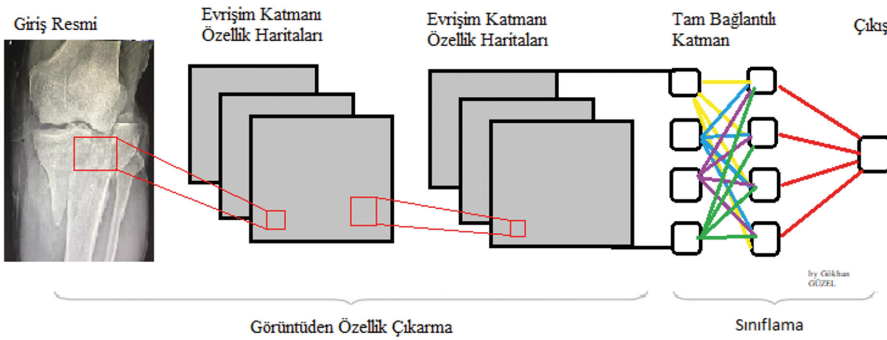
Derin öğrenme; ham girdiden daha yüksek seviyeli özelliklere ulaşmak için seviyeli katmanlar kullanan öğrenme algoritması olarak tanımlanabilir (7). Çoklu işleme katmanında toplanan hesaplama modellerinin çoklu soyutlama düzeyiyle verilerin temsillerini öğrenmesini sağlar. Derin öğrenme yöntemleri, her biri bir düzeydeki temsili (ham girdiden başlayarak) daha yüksek ve biraz daha soyut bir düzeyde temsile dönüştüren basit ancak doğrusal olmayan modüller oluşturularak elde edilen, birden çok temsil düzeyine sahip öğrenme yöntemleridir. Bu tür dönüşümlerin sayısı arttıkça ve yeterli seviyeye ulaştığında çok karmaşık fonksiyonlar dahil öğrenilebilir (8).

Ortopedi alanında derin öğrenmede görüntü tanıma ve görmede kullanılan ana derin öğrenme algoritması evrişimsel sinir ağı (CNN) dir. Yüksek düzeyde algoritmaya sahip bir CNN iki farklı işlevi yerine getirebilirken iki ana bölümde değerlendirilir. İlki görüntüden öznitelikleri çıkarırken diğer bölüm sınıflandırma yapar. Öznitelik çıkarma belirli özellikleri saptamak için büyük görüntünün küçük bir alt kümesinde öğrenilen çekirdek olarak adlandırılan filtrelerini aynı özelliği farklı noktalarda algılayabilmek için büyük görüntüdeki diğer kısımlarda kullanılma fikrine dayanır. Bu küçük çekirdekleri görüntünün bütününde dönüştürerek, görüntü alt kümeleri uzamsal ilişkiyi korurken, görüntünün farklı bölgelerinde özelliğin varlığı ve yokluğu tespit edilebilir. Bu sayede bir” özellik haritası” oluşturulur (9). Bir grup filtre ile, o evrişim katmanındaki diğer filtrelerle aynı giriş görüntüsünün kendi özellik haritasını oluşturduğu “ evrişim katmanı” oluşur. Bir CNN genellikle birden çok evrişim katmanından oluşur. Girdi görüntüsünden hemen sonra ilk evrişim katmanından CNN içinde bulunan daha derin evrişim katmanlarına geçerken giderek daha karmaşık bir yapıda olan özellik haritasıyla sonuçlanır. Daha basit anlatımla, bir CNN bir girdi görüntüsündeki basit özellikleri arayarak onları daha üst özelliklere çıkarmak için ardışık olarak birleştirir.

CNN’de bulunan sınıflandırma kısmı tamamen bağlantılı bir katmandan oluşur. Bu katman tüm karmaşık ve üst özellik haritalarını birleştirerek bunları bir sınıflandırma puanı vermek amacıyla kullanır. Sınıflandırma puanı eğitim setinde bulunan sınıfların girdi görüntüsünün olasılığını belirtir. Şekil 1’de bir CNN yapısı ve çalışma prensibi basit bir şekilde gösterilmektedir.

Örneğin; ortopedi ve travmatoloji için derin öğrenme algoritmasının girdisi röntgen, çıktı ise kırık ya da kırık değil şeklinde belirtilmesi olarak ele alınabilir. Algoritma eğitim aşamasında girdi ve çıktı eşleşmeleri ile beslenerek radyografiyi nasıl yorumlayacağı öğretilir. Bu amaçla kırık veya kırık değil şeklinde manuel

veri tabanı oluşturulmuş ve sınıflanmış olan radyografiler kullanılır. Veri tabanı bir dermatologda cilt görüntüleri, bir radyologda BT kesitleri, bir ortopedistte ise radyografi olabilir. Veri tabanının genişliği, niteliği ve çeşitliliği modellenen derin öğrenme algoritmasının başarı oranını etkileyen en önemli faktörlerden biridir. Veri tabanı oluşturulması ve algoritmanın öğrenme süreci sonrası hazırlanmış olan test verileri ile doğruluk değeri hesaplanması yapılmalıdır. Bu hesaplama gerçek doğruluğu tam olarak ortaya koymasa da algoritma hakkında bir yol gösterici olur. F1- puanı olarak adlandırılan duyarlılık ve kesinlik değerlerinin ortalaması daha güvenilir olarak görülür (10).



Şekil 1. CNN (evrimsel sinir ağı) çalışma prensibi

ORTOPEDİK CERRAHİ VE DERİN ÖĞRENME

Bütün branşlarda olduğu gibi Ortopedi ve Travmatoloji alanında da kişinin uzmanlık derecesine ve eğitimine bağlı olarak görüntüyü analiz etme ve buna bağlı klinik yorumlaması farklılık göstermektedir. Derin öğrenmenin bu aşamada en büyük avantajı bir Uzm. veya insana göre daha büyük verileri analiz etme ve süreklilik olarak değerlendirilebilir. Ortopedi disiplini, klinik zekayı, iyi cerrahi beceriyi hepsinden önemlisi teknolojiyi takip edip gelişmeler karşısında sürekli bir yenilenmeyi gerektirir. “Akıllı makine öğrenimi ortopedik görüntüleme devrim yaratacak mı?” sorusuyla Berg 2017 yılında ortopedi alanında derin öğrenmeyle ilgili ilk çalışmalara öncülük etmiştir (11). Önceleri bu hayalperest düşünce yerini genel tıbbi alanda çeşitli alanlarda kullanılması sonrası, tıbbi görüntülerin detaylı sınıflandırılması, hastanın risk değerlendirilmesinden, prognoz takibine, cerrahi tedaviye karar verme, klinik duruma karar verme, hasta bakımı ve maliyet hesaplamalarına kadar bir çok çalışma alanımızda bize yardımcı olmaya başlamıştır. Bu alanların çoğunda derin öğrenme algoritmalarının insanlara yakın veya daha iyi bir performans gösterdiği izlenmiştir (12). Ortopedik cerrahide derin öğren-

menin en büyük uygulama alanı görüntüye bağlı sınıflamadır. Görüntüye bağlı bu uygulamalar insan hata payını azaltmak, teşhis ve tedavi planlaması üzerinde ön görüş belirlenmesi, acil servislerde ortopedi alanında daha az tecrübeye ait hekimler için bir yol gösterici olmak, ortopedik prognozu ve risk değerlendirilmesini belirlemek gibi belli başlı amaçlar için kullanılmaktadır. Derin öğrenme osteoartrit derecelendirilmesi, tedavi prognozu, kemik kırığı tespiti, metastatik veya primer kemik tümör lezyonu tespiti, spor yaralanmasında bağ lezyonları ve sınıflandırılması, artroplasti cerrahisinde prognoz ve implant gevşemesi, omurga cerrahisi gibi birçok ortopedi alanında uygulanmaktadır (13). Operasyon öncesi hasta riskinin değerlendirilmesi, hasta sonuçlarının değerlendirilmesi, spor cerrahisi, ortopedik travma, ortopedik onkoloji, omurga cerrahisi, eklem ve osteoartrit en sık bu uygulamaların kullanıldığı ortopedik cerrahi alanlarıdır. Modern çağımızın konusu derin öğrenmenin ortopedik cerrahi alanında anlaşılması ve uygulanabilirliği, kullanım alanlarını tek tek ele alıp klasik tıbbi yaklaşımı kabul ederken yeniliklere karşı bakış açımızı değiştirmekten geçmektedir. Bu konuyu tek bir başlık altında değerlendirmek yerine, sık ortopedi kullanım alanlarını konuşmak çoğu literatürümüze yeni girmiş olan bu konunun daha anlaşılır olmasını sağlayabilir.

HASTA RİSK DEĞERLENDİRİLMESİ

Literatürde çeşitli ortopedik cerrahi prosedürler sonrası komplikasyonu öngörmede ve cerrahi prosedürler için uygun adayı belirlemede kullanılan birçok yöntem bulunmaktadır. ASA (The American Society of Anesthesiologists classification) daha çok anestezi uzmanları tarafından hasta risk değerlendirilmesi amacıyla kullanılırken (14), mFI-5(5- factor modified frailty index) gibi komorbiditeye bağlı hasta risk değerlendirilmesi cerrahlar tarafından kullanılmaktadır (15). Literatürde derin öğrenme ile yapılan hasta risk değerlendirmesinin klasik risk değerlendirme modellerinden (ASA- mFI-5) daha başarılı sonuçlar verdiğini gösteren birçok çalışma mevcut (16).

Varun ve ark. (17) anterior servikal diskektomi ve füzyon (ACDF) sonrası postoperatif komplikasyonlarını tahmin etmek amacıyla makine öğrenimi modellerini kullandılar. Hazırlanan modeller ACDF uygulanmış çok merkezli bir veri seti üzerinden eğitilmiştir. Eğitim sonrası ASA ile karşılaştırılmış, 20,879 hasta üzerinden oluşturulan veri seti eğitim için 14,615 hasta ayrılırken, test amacıyla 6,264 hasta ayrılmıştır. Oluşturulan algoritma modellerinin venöz tromboemboli, yara komplikasyonu, mortalite gibi her komplikasyonda ASA'ya göre daha başarılı performans gösterdiği izlenmiştir. Kim ve ark. (18) omurga deformitesi bulunan eriş-

kin hastalarda yaptığı benzer çalışmada, modellemelerin ASA değerlendirmesine göre daha başarılı olduğunu göstermiştir. Osteoporotik hastalarda kalça kırığı risk değerlendirmesi için yapılan çalışmalarda, kemik dansitometri ölçümlerinin başarı oranı %65 olarak belirtilirken, derin öğrenme ile %90 doğruluk payına çıktığı gösterilmiştir (19).

Artroplasti alanında çok popüler olan bu konuda; postoperatif risk değerlendirilmesi amacıyla yapılan total diz artroplastisi ve total omuz artroplastisi çalışmaları makine öğrenmesinin, standart risk değerlendirmelerine göre daha iyi performans gösterdiği belirtilmiştir (20,21).

Bevevino ve ark. (22)'nin savaşa bağlı açık kalkaneus kırığı olan hastalarda ekstremitayı kurtarmayı öngören ve risk değerlendirmesi yapan çalışması bu alanda en dikkat çeken çalışmalardan biridir. 155 savaşa bağlı açık kalkaneus kırığının amputasyon ihtimalini tahmin etmek için bir derin öğrenme modeli ve standart regresyon modeli kullanılmış ve derin öğrenme modelinin standart regresyon modeline göre daha başarılı olduğu ve klinik kullanıma daha uygun olduğu görülmüştür. Veri setinin küçük olması doğruluk payını düşündürürken, veri setinin büyümesi halinde biz ortopedistlerin amputasyon ve ekstremitayı koruma arasında karar verme durumunda kaldığımız birçok savaş yaralanmasında bu modelleme yardımcı olabilir. Robert ve ark. (23) ayak bilek kırığı sebebiyle açık redüksiyon ve internal fiksasyon yapılmış 16,500 hastanın derin öğrenme veri tabanını oluşturmuştur. Postoperatif erken dönem risk değerlendirilmesinin derin öğrenme ile yüksek oranda başarılı olduğu gösterilmiştir.

HASTA SONUÇLARININ DEĞERLENDİRİLMESİ

Son yıllarda ortopedik cerrahide; hasta tarafından bildirilen sonuç ölçütleri (PROM) ortopedik onkolojik mortalite ve sağkalımı, maliyet, hastanede kalış süresi gibi sonuç değerlendirmesinde büyük veri datalarını analiz edebilen derin öğrenmeyle ilgili çalışmalar hız kazanmıştır. PROM sağlık hizmeti kalitesini ve değerini ölçmenin önemli bir göstergesi olarak gösterilmektedir (24).

Menendez ve ark. (25) total omuz artroplastisi yapılmış hastalarda derin öğrenme kullanılarak olumsuz geri dönüşlerin içeriği, bunlarla ilişkili faktörleri ve bunların postoperatif sonuçlarının hasta memnuniyet anketleri ile ilişkisini ortaya koymuşlardır. Total omuz artroplastisi sonrası hasta memnuniyetini, hasta bakım periyodu için bir öngörü olarak belirtmişlerdir.

Onkoloji alanında kondrosarkomlu hastaların 5 yıllık sağkalım durumunu öngörebilen bir derin öğrenme algoritması oluşturularak hastanın tümör yapısı, tedavisi, sonuç verileri üzerinde makine öğrenmesi yöntemleri kullanıldı. Yazar-

lar bu çalışmada geniş veri tabanına ait derin öğrenmenin olduğundan daha uzun sağkalım sonuçları verdiğini, fakat veri tabanı küçültülmesi sonrası bu sağkalımın doğru değer verdiğini belirtmiştir (26). Derin öğrenme algoritmaları elektif yapılacak bir ortopedi cerrahisinden önce bir hastanın ameliyatının ne kadar sürebileceği ne kadar maliyeti olacağı, hastanede yatış süresini tahmin etmede kullanılabilir. Navarro ve ark. (27) total kalça ve total diz artroplastisi sonrasında hastanede kalış süresi, operasyon maliyeti tahmini için büyük veri tabanları kullanarak yaptıkları çalışmada derin öğrenme tekniklerinin hastanede kalış süresinde mükemmele yakın sonuç verdiğini belirtmişlerdir. Makine öğrenmesi ve derin öğrenme tekniklerinin ortopedik onkoloji, PROM, hastanede kalış süresi ve maliyet tahmininde faydalı olduğu gösterilmiştir. Ortopedik onkolojide sağkalım açısından mükemmelleştirilirse de hastanede kalış süresi, PROM, maliyet açısından etkili olduğu kanıtlanmıştır. Bu algoritmalar kullanılarak ortopedistlere bir ön fikir sunularak daha iyi hasta bakımına ve kaynakların daha verimli kullanılmasına olanak sağlanabilir (28).

GÖRÜNTÜLEME

Radyografi, BT (bilgisayarlı tomografi), MRG (manyetik rezonans görüntüleme) ortopedik tanı ve tedavide en önemli araçlardır. Bir radyografi ile kırık tedavisi planlanırken, bir MRG ile diz yaralanması hakkında fikir sahibi olunabilir. Bu sebeple derin öğrenmeyle ilgili çalışmaların çoğunluğu görüntüleme ile yapılmıştır.

TRAVMA

Derin öğrenme algoritmaları, görüntüleme yöntemleriyle kırık tespitine yardımcı olmak amacıyla kullanılmaktadır. Diğer tıp branşındaki hekimlere oranla kırık tespiti ortopedistler için tanı koyması daha kolay bir hastalıktır. Derin öğrenmenin travma alanında ana kullanımını acil servislerde işleyişi hızlandırmak ve ortopedi tecrübesi daha az olan hekimler için bir uyarı sistemi olarak değerlendirmek daha doğru olacaktır.

Literatürde kırık tespiti ile ilgili en geniş veri tabanına sahip olan çalışmalardan biri olan Olczak ve ark. (29) 256,000 el, el bileği ve ayak bileği radyografileri kullanarak oluşturdukları veri tabanı derin öğrenme ile kırıklarda %83 başarı sağlarken, diğer parametrelerde bu oran %90'a kadar çıkmıştır. Femur boyun kırıklarının teşhisi ve doğru sınıflandırılmasıyla ilgili Simukai ve ark.'nın yaptığı çalışmada 550 femur boyun kırığı olan hasta ve 1050 radyografi değerlendirilmiş. Garden sınıflaması kullanılarak yapılan çalışmada derin öğrenme algoritmasının %92 doğruluk ile kırık tespiti ve sınıflama yaptığı izlenmiştir (30). Tanı konması ve

radıyografik belirteçlerinin gözlemlenmesi diğer kırıklara göre daha zor olan skafoıd kırıklarında Yoon ve ark. (31) geniş bir veri seti kullanarak derin öğrenmeyle %79 duyarlılık ve %72 duyarlılık raporlamışlardır. Çalışmada insan gözlemciler tarafından atlanmış olan 22 gizli skafoıd kırığının 20'si derin öğrenme algoritması tarafından tespit edilmiştir. Ortopedistler tarafından dahil tanı konmasında zorluklar olan skafoıd kırıklarının ve diğer küçük kemik kırıklarının tespitinde yardımcı bir yöntem olarak kullanılması yazarlar tarafından önerilmiştir. Ülkemizde el kırıkları ve kalça kırıkları tespiti için yapılan derin öğrenme çalışmalarında %85 oranında doğruluk ve duyarlılık ile umut verici şekilde yorumlanmıştır (10,32).

EKLEM CERRAHİSİ VE OSTEOARTRİT

Osteoartrit eklem kırıkdađ dejenerasyonu ile karakterize oldukça yaygın bir hastalıktır. X-ray ile düşük maliyette, basit bir şekilde tanı konabilirken, eklem kırıkdađındaki ince morfolojik deęişiklikler MRG ile daha hassas tespit edilebilir (33). Çoęunlukla ortopedik literatürde eklem ve osteoartrit konusunda görüntüleme çalışmaları kalça ve diz osteoartriti tanısı amacıyla yapılmıştır. Son zamanlarda eklem koruyucu cerrahi endikasyonları ve artroplasti cerrahisi alanında derin öğrenme çalışmaları hız kazanmıştır. Xue ve ark. (34) kalça osteoartritinde derin öğrenmenin tanısal deęerini araştırmak için kalça osteoartriti otomatik olarak teşhis edebilecek derin evrişimli sinir ağı (CNN) eğitmişlerdir. 420 kalça X-ray görüntüsü üzerinde test edilen CNN'in %92,8 doğruluk deęeri verdięi gösterilmiş. Çalışmada CNN modeli performansının 10 yıllık deneyimli bir ortopedist ile karşılaştırılabileceęi belirtilmiştir. Ashinsky ve ark. (35) klinik olarak semptomatik diz osteoartritindeki ilerlemeyi medial femoral kondilin MRG T2 aęırlıklı kesitlerinde tahmin etmek için bir derin öğrenme algoritması kullandı. Derin öğrenme algoritması, osteoartritin başlangıcını %75 doğrulukla tahmin edebildi. Bayramoęlu ve ark. (36) diz lateral grafilelerinde patellofemoral osteoartriti deęerlendirme amacıyla yaptıkları derin öğrenme çalışmalarında izole patellar bölge üzerine eğitilmiş CNN'in dięer derin öğrenme algoritmalarına göre daha iyi performans gösterdięini belirtmişlerdir.

Yüksek tibial osteotomi (YTO) diz osteoartritinin tedavisinde etkili bir prosedürdür. Her ortopedistin hemfikir olduęu konu ise YTO için hasta seçiminin ne kadar önemli olduęudur. Huang ve ark. (37) diz osteoartriti bulunan ve YTO endikasyonu olabilecek hastalarda, hastada varus deformitesi olup olmadıęını, deformitenin yeri ve ciddiyetini, osteoartritin evresini, kemik durumunu kapsamlı bir şekilde deęerlendirebilecek bir derin öğrenme algoritması üzerinde çalışmışlardır. Aktivite durumu, hasta kilosu, yaşı, eklem aktivitesi gibi kişiye özel faktörleri düşündüğümüzde YTO için literatüre oranla daha az doğruluk payı

beklerken, literatürle derin öğrenme performansının benzer olduğu belirtilmiş. Kişiyi özelleşmiş ve hasta seçiminin bir o kadar zor olduğu yüksek tibial osteotomi hastalarını göz önüne alarak diz ve kalça osteoartritinde görüntüye bağlı derin öğrenmenin gelecekte yüksek bir potansiyele sahip olduğu görülmektedir.

ORTOPEDİK ONKOLOJİ

Ortopedik onkolojide, metastatik kemik hastalıklarının yönetimi patolojik kırık ve oluşabilecek patolojik kırık riski ile ilgilidir. Ortopedik onkologlar metastaza bağlı patolojik kırıkları derin öğrenme kullanarak yakalayabilir. Böylece hastalar profilaktik olarak tedavi edilebilir ve hasta sonuçları iyileştirilebilir. Oh ve ark. (38) akciğer kanserinde metastatik femur kırıklarını tahmin etmek için BT görüntüleme ve klinik özelliklerini içeren makine öğrenmesi kullandı. Bu modeli sadece BT görüntüleme kullanan model ile karşılaştırdılar. Sonuç olarak klinik özellikleri de içeren modelin diğer modele oranla daha başarılı olduğu izlendi. Zhen ve ark. (39) kemik metastazı tespit etmek amacıyla kullanılan kemik sintigrafisi görüntüleme yöntemiyle derin öğrenme analizleri yaptılar. Çeşitli kanser tiplerine ait hastaların 12.000'e yakın kemik sintigrafisiyle yapılan derin öğrenme çalışmasında kemik metastazın saptanmasında derin öğrenmenin konunun Uzm.ı bir doktor kadar iyi performans sergilediği tespit edilmiştir. Çalışmalar çoğunlukla metastatik hastalarda yapılırken primer kemik ve yumuşak doku tümörlerinde çalışmalar bir hayli azdır. Çoğu yazar bu durumu primer malignitelerin metastazlara oranla daha az görülmesi ve derin öğrenme için yeterli bir veri tabanı oluşturulamamasına bağlamaktadır.

OMURGA CERRAHİSİ

Omurga cerrahisinde teknoloji robotik cerrahi, bilgisayar destekli vertebra navigasyonu, artırılmış gerçeklik kullanımı ile ilerledi. Bu uygulamaların hepsinde BT veya MRG görüntülemelerinden omurganın rekonstrüksiyonu gerekmektedir. Bu sebeple literatürde çoğu çalışma derin öğrenmenin tespit ve etiketleme açısından doğruluğunu sağlamak amacıyla yapılmıştır. Forsberg ve ark. (40) lomber ve servikal vertebraları tespit etmek ve etiketlemek amacıyla bilgi içerikleri bulunan MRG kullanarak derin öğrenmeyi kullandılar. Pestei ve ark. (41) perkütan spinal için optimal vertebra seviyesini ve enjeksiyon açısını tespit etmek amacıyla USG görüntüleri ile eğitilmiş CNN kullanmışlardır. Bu çalışma doğruluğunun %95 ve maksimum kesinliğin %97 olduğunu göstermiştir. Ayrıca BT görüntülerinde lomber kırıkların derin öğrenme ile tespitinde insan performansına yakın olduğunu gösteren çalışmalar mevcuttur (42).

Etiketleme ve özellik gerektirmeyen başka çalışmada T2 sagittal MRG görüntülerini değerlendirmek, disk mesafesi, spondilolistezis, santral kanal stenozu gibi dejeneratif değişikliklerin derecelendirilmesi ve Uzm. radyologlar ile karşılaştırmak amacıyla derin öğrenme kullanıldı. Derin öğrenme özellikle spondilolistezis tahmininde radyologlar kadar iyi performans göstermiş. Bu modelin etiketleme ve özellik açıklaması gerektirmedikinden, koronal ve aksiyel görüntülerin eklenmesiyle modelin daha fazla doğruluk ve güvenilirlik kazanacağına inanılıyor (43).

SONUÇ

Ortopedik cerrahide derin öğrenme, omurga patolojisi tespiti, protez kontrolü, yürüme analizi ve sınıflandırmasında, osteoartrit tespiti ve kırık tespitinde başarılı sonuçlar vermiştir. Bu sonuçlar, bilgisayarların birçok tanıda ortopedistlere yakın performans gösterebileceğini doğrulamıştır. Genel olarak derin öğrenme araştırmalarının genişletilmesiyle ortopedik tedavi ile ilgili daha etkili tanıl ve prognostik kullanımlara sahip olunabilir. Teknolojiye bağlı artan ilgiyle derin öğrenme ortopedik risk değerlendirmesi, sonuç değerlendirme ve görüntülemelerde ortopedi klinik süreçte kullanılabilir. İlerleyen süreçte ortopedik hasta seçimi ve klinik sonucu iyileştirmek için biz ortopedistlerin derin öğrenmeyle ilgili eğitim alması gerekliliğini ortaya çıkarıyor. “Makineler öğrenebilir mi?” ile başlayan yapay zekâ kavramı, “Akıllı makine öğrenimi ortopedik görüntülemelerde devrim yaratacak mı?” ile ortopedi alanında teknoloji rüzgarı ile devam etti. Acaba gelecekte, derin öğrenmiş mekanik robotlar ortopedistlerin yerini alabilecek mi?

KAYNAKLAR

1. Tappert, C. C. (2019, December). Who is the father of deep learning? In *2019 International Conference on Computational Science and Computational Intelligence (CSCI)* (pp. 343-348). IEEE.
2. Litjens, G., Kooi, T., Bejnordi, B. E., Setio, A. A. A., Ciompi, F., Ghafoorian, M., ... & Sánchez, C. I. (2017). A survey on deep learning in medical image analysis. *Medical image analysis*, *42*, 60-88.
3. Borjali A, Monson K, Raeymaekers B. Predicting the polyethylene wear rate in pin-on-disc experiments in the context of prosthetic hip implants: deriving a data-driven model using machine learning methods. *Tribol Int*. 2019; 133:101–110
4. Samuel, A. L. (1967). Some studies in machine learning using the game of checkers. II—Recent progress. *IBM Journal of research and development*, *11*(6), 601-617.
5. Kijowski, R., Liu, F., Caliva, F. (2020). Deep learning for lesion detection, progression, and prediction of musculoskeletal disease. *Journal of Magnetic Resonance Imaging*, *52*(6), 1607-1619.
6. Lu, Z., Pu, H., Wang, F., Hu, Z. (2017). The expressive power of neural networks: A view from the width. *Advances in neural information processing systems*, 6231-6239
7. Deng, L., & Yu, D. (2014). Deep learning: methods and applications. *Foundations and trends® in signal processing*, *7*(3–4), 197-387.(dx.doi.org/10.1561/2000000039)
8. LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *nature*, *521*(7553), 436-444. (doi: 10.1038/nature14539)

9. Borjali A, Chen AF, Muratoglu OK, Learning in Orthopedics: How Do We Build Trust in the Machine? *Healthcare Transformat* 2020(doi: 10.1089/heat.2019.0006)
10. Salih B , Şahika B.Y , Uğur D. Derin öğrenme ile otomatik kalça kırığı tanısı. *TOTBİD Dergisi* 2022;21:32-39 (doi.org/10.5578/ totbid .dergisi.2022.07)
11. Berg, Hans E. Will Intelligent Machine Learning Revolutionize Orthopedic Imaging? *Acta-Orthopaedica*. 2017;88(6), 577–577. (doi: 10.1080/17453674.2017.1387732.)
12. Miller DD, Brown EW. Artificial Intelligence in Medical Practice: The Question to the Answer? *Am J Med* 2018; 131: 129-133 [PMID: 29126825 (doi: 10.1016/j.amjmed.2017.10.035)]
13. Lalehzarian, S. P., Gowd, A. K., & Liu, J. N. (2021). Machine learning in orthopaedic surgery. *World Journal of Orthopedics*, 12(9), 685. (doi: 10.5312/wjo.v12.i9.685)
14. Irlbeck, T, Zwissler, B., & Bauer, A. ASA classification: Transition in the course of time and depiction in the literature. *Anaesthesist* [Internet]. 2017 [cited 2019 Dec 9]; 66 (1): 5-10. (doi: 10.1007/s00101-016-0246-4.)
15. Subramaniam, S., Aalberg, J. J., Soriano, R. P., & Divino, C. M. (2018). New 5-factor modified frailty index using American College of Surgeons NSQIP data. *Journal of the American College of Surgeons*, 226(2), 173-181.(doi: 10.1016/j.jamcollsurg.2017.11.005)
16. 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: 452-460 (doi: 10.1097/CORR.0000000000000601)
17. Arvind, V., Kim, J. S., Oermann, E. K., Kaji, D., & Cho, S. K. (2018). Predicting surgical complications in adult patients undergoing anterior cervical discectomy and fusion using machine learning. *Neurospine*, 15(4), 329. (doi: 10.14245/ns.1836248.124)
18. Kim, J. S., Arvind, V., Oermann, E (2018). Predicting surgical complications in patients undergoing elective adult spinal deformity procedures using machine learning. *Spine deformity*, 6(6), 762-770. (doi: 10.1016/j.jspd.2018.03.003)
19. Galassi, A., Martín-Guerrero, J. D., Villamor, E., Monserrat, C., & Rupérez, M. J. (2020). Risk assessment of hip fracture based on machine learning. *Applied Bionics and Biomechanics*, 2020. (doi: 10.1155/2020/8880786)
20. Devana, S. K., Shah, A. A., Lee, C., Roney, A. R., van der Schaar, M., & SooHoo, N. F. (2021). A novel, potentially universal machine learning algorithm to predict complications in total knee arthroplasty. *Arthroplasty today*, 10, 135-143.(doi: 10.1016/j.artd. 2021.06.020)
21. Gowd AK, Agarwalla A, Amin NH., Construct validation of machine learning in the prediction of short-term postoperative complications following total shoulder arthroplasty. *J Shoulder Elbow Surg* 2019; 28: e410-e421 (doi: 10.1016/j.jse.2019.05.017)
22. Bevevino AJ, Dickens JF, Potter BK, Dworak T, Gordon W, Forsberg JA. A model to predict limb salvage in severe combat-related open calcaneus fractures. *Clin Orthop Relat Res* 2014; 472: 3002- 3009 (doi: 10.1007/s11999-013-3382-z)
23. Merrill, R. K., Ferrandino, R. M., Hoffman, R., Shaffer, G. W., & Ndu, A. (2019). Machine learning accurately predicts short-term outcomes following open reduction and internal fixation of ankle fractures. *The Journal of Foot and Ankle Surgery*, 58(3), 410-416.(DOI: 10.1053/j.jfas.2018.09.004)
24. Fontana MA, Lyman S, Sarker GK Can Machine Learning Algorithms Predict Which Patients Will Achieve Minimally Clinically Important Differences From Total Joint Arthroplasty? *Clin Orthop Relat Res* 2019; 477: 1267-1279 [doi: 10.1097/CORR.0000000000000687]
25. Menendez ME, Shaker J, Lawler SM, Ring D, Jawa A. Negative Patient-Experience Comments After Total Shoulder Arthroplasty. *J Bone Joint Surg Am* 2019; 101: 330-337 (DOI: 10.2106/JBJS.18.00695)
26. Thio QCBS, Karhade AV, Ogink PT, Raskin KA, De Amorim Bernstein K, Lozano Calderon SA, Schwab JH. Can Machine-learning Techniques Be Used for 5-year Survival Prediction of Patients With Chondrosarcoma? *Clin Orthop Relat Res* 2018; 476: 2040-2048 doi: 10.1097/CORR.0000000000000433]

27. Navarro SM, Wang EY, Haeberle HS, Mont MA, Krebs VE, Patterson BM, Ramkumar PN. Machine Learning and Primary Total Knee Arthroplasty: Patient Forecasting for a Patient-Specific Payment Model. *J Arthroplasty* 2018; 33: 3617-3623 (DOI: 10.1016/j.arth.2018.08.028)
28. Lalehzarian, S. P., Gowd, A. K., & Liu, J. N. (2021). Machine learning in orthopaedic surgery. *World Journal of Orthopedics*, 12(9), 685. (doi: 10.5312/wjo. v12.i9.685)
29. Olczak J, Fahlberg N, Maki A, Razavian AS, Jilert A, Stark A, Sköldenberg O, Gordon M. Artificial intelligence for analyzing orthopedic trauma radiographs. *Acta Orthop* 2017; 88: 581-586 [DOI: 10.1080/17453674.2017.1344459]
30. Mutasa, S., Varada, S., Goel, A., Wong, T. T., & Rasiej, M. J. (2020). Advanced deep learning techniques applied to automated femoral neck fracture detection and classification. *Journal of Digital Imaging*, 33(5), 1209-1217. (DOI: 10.1007/s10278-020-00364-8)
31. Yoon, A. P., Lee, Y. L., Kane, R. L., Kuo, C. F., Lin, C., & Chung, K. C. (2021). Development and validation of a deep learning model using convolutional neural networks to identify scaphoid fractures in radiographs. *JAMA network open*, 4(5), e216096-e216096.(DOI: 10.1001/jama-networkopen.2021.6096)
32. Üreten, K., Sevinç, H. F., İğdeli, U., Onay, A., & Maraş, Y. (2022). Use of deep learning methods for hand fracture detection from plain hand radiographs. *Turkish Journal of Trauma and Emergency Surgery*, 28(2), 196-201.(DOI: 10.14744/tjtes.2020.06944)
33. Braun HJ, Gold GE. Diagnosis of osteoarthritis: imaging. *Bone* 2012; 51: 278-288 (DOI: 10.1016/j.bone.2011.11.019)
34. 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: e0178992 (DOI: 10.1371/journal.pone.0178992)
35. Ashinsky BG, Bouhrara M, Coletta CE, Lehallier B, Urish KL, Lin PC, Goldberg IG, Spencer RG. Predicting early symptomatic osteoarthritis in the human knee using machine learning classification of magnetic resonance images from the osteoarthritis initiative. *J Orthop Res* 2017; 35: 2243-2250 (DOI: 10.1002/jor.23519)
36. Bayramoglu, N., Nieminen, M. T., & Saarakkala, S. (2021). Automated detection of patellofemoral osteoarthritis from knee lateral view radiographs using deep learning: data from the Multicenter Osteoarthritis Study (MOST). *Osteoarthritis and Cartilage*, 29(10), 1432-1447.(doi: 10.1016/j.joca.2021.06.011.)
37. Huang, Y., Liu, J., Wang, X. S., & Xu, H. J. (2020). Deep learning indications for high tibial osteotomy. *Zhonghua wai ke za zhi [Chinese Journal of Surgery]*, 58(6), 420-424.(DOI: 10.3760/cma.j.cn112139-20200228-00149)
38. Oh E, Seo SW, Yoon YC, Kim DW, Kwon S, Yoon S. Prediction of pathologic femoral fractures in patients with lung cancer using machine learning algorithms: Comparison of computed tomographybased radiological features with clinical features vs without clinical features. *J Orthop Surg (Hong Kong)* 2017; 25: 2309499017716243 (DOI: 10.1177/2309499017716243)
39. Zhao, Z., Pi, Y., Jiang, L., Xiang, Y., Wei, J., Yang, P., ... & Cai, H. (2020). Deep neural network based artificial intelligence assisted diagnosis of bone scintigraphy for cancer bone metastasis. *Scientific reports*, 10(1), 1-9.(DOI: 10.1038/s41598-020-74135-4)
40. Forsberg D, Sjöblom E, Sunshine JL. Detection and Labeling of Vertebrae in MR Images Using Deep Learning with Clinical Annotations as Training Data. *J Digit Imaging* 2017; 30: 406-412 (DOI: 10.1007/s10278-017-9945-x)
41. Pesteie M, Abolmaesumi P, Ashab HA, Lessoway VA, Massey S, Gunka V, Rohling RN. Real-time ultrasound image classification for spine anesthesia using local directional Hadamard features. *Int J Comput Assist Radiol Surg* 2015; 10: 901-912 (DOI: 10.1007/s11548-015-1202-59)
42. Al-Helo S, Alomari RS, Ghosh S, Chaudhary V, Dhillon G, Al-Zoubi MB, Hiary H, Hamtini TM. Compression fracture diagnosis in lumbar: a clinical CAD system. *Int J Comput Assist Radiol Surg* 2013; 8: 461-469 (DOI: 10.1007/s11548-012-0796-0)
43. Jamaludin A, Lootus M, Kadir T, Zisserman A, Urban J, Battié MC, Fairbank J, McCall I; Genodisc Consortium. ISSLS PRIZE IN BIOENGINEERING SCIENCE 2017: Automation of reading of radiological features from magnetic resonance images (MRIs) of the lumbar spine without human intervention is comparable with an expert radiologist. *Eur Spine J* 2017; 26: 1374-1383 (DOI: 10.1007/s00586-017-4956-3)