

Böbrek Nakilli Hastalarda Greft Sağkalımının Yapay Zeka Yöntemleri ile Tahmin Edilmesi

Predicting Graft Survival in Renal Transplant Patients Using Artificial Intelligence Methods

© Tuba ÖZ¹, © Melek PEHLİVAN², © İbrahim PİRİM¹

¹İzmir Kâtip Çelebi Üniversitesi Tıp Fakültesi, Tıbbi Biyoloji ve Genetik Anabilim Dalı, İzmir, Türkiye

²İzmir Kâtip Çelebi Üniversitesi, Sağlık Hizmetleri Meslek Yüksekokulu, İzmir, Türkiye

Atf: Öz T, Pehlivan M, Pirim İ. Predicting Graft Survival in Renal Transplant Patients Using Artificial Intelligence Methods. Forbes J Med 2023;4(1):1-7

ÖZ

Günümüzde, böbrek nakli son dönem böbrek yetmezliği olan hastaların sağkalımını ve yaşam kalitesini artıran en uygun tedavi yöntemi olarak kabul edilir. Başarılı bir böbrek nakli için potansiyel risk faktörlerinin belirlenmesi son derece önemlidir. Böbrek nakli yapılan hastalarda greft sağkalımını etkileyen risk faktörlerini belirlemek için yapay zekayı 'artificial intelligence' (AI) kullanan çalışmaların sayısı gün geçtikçe artmaktadır. Bu çalışmalarda AI, patolojik değerlendirmeden immünsupresif ilaç dozlarına kadar geniş bir yelpazede kullanılmaktadır. AI algoritmalarından makine öğrenimi tabanlı modeller, geleneksel istatistiksel metodlara kıyasla greft sağkalımının tahmininde daha iyi performans gösterirler ve verilerin hızlı değerlendirilmesini sağlarlar. Son yıllarda, AI'nin böbrek naklinde kullanımını artırmak için çok sayıda kapsamlı araştırma yapılmıştır. Bu derlemedeki amacımız, böbrek transplantasyonunda greft sağkalımını tahmin etmek için AI algoritmalarını incelemektir.

Anahtar Kelimeler: Yapay zeka, makine öğrenimi, böbrek nakli

ABSTRACT

Renal transplantation is now widely regarded as the best treatment option for patients with end-stage renal failure in terms of survival and quality of life. It is of extremely importance to identify the potential risk factors for successful renal transplantation. The number of studies related to artificial intelligence (AI) applications in renal transplant patients grows by the day. In these studies, AI is used a wide range from pathological evaluation to immunosuppressive drug doses. Machine learning-based models that are AI algorithms perform to be superior to the traditional statistical method for predicting graft survival and rapidly provides analyzing of data. In recent years, the number of studies is increased using AI for renal transplants. In this review we aimed to examine the AI algorithms for predicting graft survival in renal transplantation.

Keywords: Artificial intelligence, machine learning, renal transplantation

GİRİŞ

Böbrek hastalığı, toplumun %10'undan fazlasını etkileyen küresel sağlık sorunudur. Böbrek nakli, son dönem böbrek hastaları için en iyi tedavi seçeneği olarak kabul edilmektedir. Ancak günümüzde greft fonksiyonunda ve sağkalımında önemli gelişmeler olmasına rağmen, nakledilen birçok böbrek grefti reddedilmektedir. Greft sağkalımını etkileyen faktörler nedeniyle, nakil sonuçlarının

tahmini için geleneksel istatistiksel metodların kullanımı zordur. Yapay zeka 'artificial intelligence' (AI) yöntemleri gibi yeni yaklaşımlar, çok sayıda faktörü ve bu faktörler arasındaki karmaşık etkileşimleri analiz ederek böbrek nakli sonuçlarının doğru tahmin edilmesini sağlamaktadır.

Günümüzde AI'nin kullanımı çok hızlı bir şekilde artmakta ve tıpın her alanında veri sağlamaya devam etmektedir. Son yıllarda, AI'nin böbrek naklindeki etkisini kapsamlı

Geliş/Received: 21.03.2022

Kabul/Accepted: 26.05.2022

Sorumlu Yazar/
Corresponding Author:

Tuba ÖZ,

İzmir Kâtip Çelebi Üniversitesi Tıp
Fakültesi, Tıbbi Biyoloji ve Genetik
Anabilim Dalı, İzmir, Türkiye

✉ tuba.oz@ikc.edu.tr

ORCID: 0000-0003-4366-8927



bir şekilde incelemek için çok sayıda bilimsel çalışma devam etmektedir. Böbrek nakli olan hastalardan elde edilen veriler kullanılarak; immünsupresif dozunun optimize edilmesi^{1,2}, greft fonksiyonunun tahmini³, insan lökosit antijen 'human leukocyte antigen' (HLA) yanıtı⁴ ve Koronavirüs hastalığı-2019 pandemisi⁵ sırasında böbrek nakli riskinin değerlendirilmesi gibi çeşitli komplikasyonlarda AI teknikleri kullanılmaktadır. Bu nedenle, böbrek naklinde AI'yi kullanmak ve sonuçlarını değerlendirebilmek son derece önemlidir. Bu derlemede, AI hakkında bilgi verilerek AI yöntemlerinin ne olduğu, tıpta AI yöntemlerinin nasıl kullanıldığı, avantajları ve dezavantajlarının ne olduğu, özellikle böbrek naklinde AI yöntemleri kullanılarak greft sağkalım süresinin tahmin edilmesine ilişkin güncel literatür hakkında bilgi verilmiştir.

Yapay Zeka Algoritmaları

John McCarthy'in, 1955'te AI terimini ortaya koymasının ardından, gelişen teknoloji ile AI çalışmaları çok hızlı bir şekilde ilerlemiştir. AI kapsamlı bilgisayar teknolojisiyle insan zekasını taklit eden algoritmalarıdır. Bu nedenle genel olarak insanlar tarafından gerçekleştirilen analizleri, 'akıllı' olarak nitelendirilecek bir şekilde otomatikleştirme ve geliştirme yeteneği olarak tanımlanır.⁶ AI bir sistemdeki verileri algılamayı, bu verilere dayalı olarak belirli hedeflere ulaşmayı ve bu sürecin tekrarlanarak sürekli olarak güncelleştirilmesini amaçlar.⁷ Böylelikle, AI günümüzde dijital verilerin analiz edilmesini ve kullanımını önemli ölçüde değiştirmiştir. Bu özelliklerinden dolayı AI sağlık alanında da sıklıkla hastalıkların tahmini, teşhisi ve tedavisi için kullanılmaya başlanmıştır.⁸

AI; Makine öğrenimi 'machine learning' (ML), derin öğrenme 'deep learning' (DL) genetik algoritmalar, genetik programlama gibi alt dallar içermektedir. Bu alt dallardan en önemlisi, ML'dir.⁹ ML teknikleri, karmaşık veri kümelerini yönetme yeteneğine ve klasik istatistiksel yöntemlerin aksine çok sayıda değişkene sahiptir. ML algoritmaları, belirli bir klinik olgunun sonucunu tahmin etmek için iki değişkenin ilişkilerini değerlendirmek, temel özelliklere dayalı tahminler oluşturmak, karşılaştırılabilir modellerle nesnelere tanımlamak ve konuları belirli kriterlere dahil etmek gibi birçok sorunun çözümlenmesinde kullanabilmektedir.¹⁰ Bu özellikler, ML'yi klasik hesaplama yaklaşımlarından farklı kılmaktadır. ML hedeflere göre denetimli, denetimsiz ve takviyeli öğrenme olmak üzere üç paradigmada sınıflandırılır. Etiketler, denetimli öğrenmede veri kümesine dahil edilir ancak denetimsiz öğrenmeye dahil edilmez. Takviyeli öğrenme, herhangi bir verinin önceden sağlanmasını gerektirmez; ancak çevreden öğrenme bilgilerini alır ve model parametrelerini günceller. Denetimli öğrenme algoritmaları, tahmine dayalı hedefler ile temel gerçek arasındaki tahmin

hatasını azaltmak için programlanır. Bu algoritmalar, etiket özelliklerine göre sınıflandırma ve regresyon olmak üzere iki kategoriye ayrılmıştır. ML algoritmalarının en sık kullanılan örnekleri; rassal orman 'random forest' (RF), destek vektör makinesi 'support vector machine' (SVM), Yapay sinir ağları 'artificial neural networks' (ANN), K-en yakın komşuluk 'K-nearest neighbor' (KNN), karar ağacı 'decision tree' (DT), gradyan artırma 'gradient boost' (GB), naive bayes'dir (NB).¹¹ ANN sınıflandırma veya tahmin süreçlerinde yer alan karmaşık işlevleri yaklaşık olarak tahmin edebilen, katmanlar halinde düzenlenmiş bir dizi yapay nörona dayalı denetimli veya denetimsiz bir ML algoritmasıdır. Ayrıca, çok sayıda görevi gerçekleştirebilen karmaşık hesaplama sistemleridir. ANN'ler daha az istatistiksel eğitim gerektirmeleri, doğrusal olmayan ilişkileri saptayabilmeleri gibi özellikleriyle geleneksel istatistik metodlara göre avantajlıdır.¹²

İnsan beyninin biyolojik yapısını taklit etme fikrinden esinlenen DL, ANN'ye dayalı ML'nin bir alt alanıdır. DL, özellik çıkarma ve dönüştürme için çok sayıda doğrusal olmayan işlem katmanına sahip, genellikle görüntü tanıma konusunda uzmanlaşmış, denetimli veya denetimsiz bir ML algoritmasıdır. DL modelleri, son yıllarda biyomedikal alanında giderek artan bir şekilde, genomik ve ilaç keşfi gibi diğer birçok alanı içeren organ nakil sürecini önemli ölçüde etkilemiştir.¹³

RF entegre algoritmaların kapsamlı uygulamasına dayanan, kesin bir tahmin veya sınıflandırma elde etmek için birden çok DT oluşturan denetimli bir ML algoritmasıdır. RF, veriler eksik olsa bile iyi performans gösteren hızlı bir algoritmadır.¹¹ SVM'ler farklı kategorilere ait verilerin doğrusal olarak ayrıldığı uyarlanmış hiper düzlemler oluşturarak verileri sınıflandırabilen ve aykırı değerleri tespit edebilen denetimli bir ML algoritmasıdır.¹¹

Lojistik regresyon 'logistic regression' (LR), istatistiklere dayalı uzun bir geçmişi olan pratik bir teknolojidir. NB, çoğu veri setini tahmin etmede etkili olan koşullu olasılığa dayalı analitik bir yöntemdir.

Analizlerde tek bir tekniği kullanmak her zaman yüksek doğruluğu garanti etmez. Her tekniğin fonksiyonlarına göre üstün ve zayıf yönleri vardır. Klinik uygulamalar için bazı ML modelleri veri sınıflandırması için diğerlerine göre daha uygundur, bu nedenle belirli bir klinik soru için uygun ML modelinin seçilmesi veya kombinasyonu gereklidir. En iyi model genellikle örnek veri setine ve belirli bir senaryodaki analizin amacına bağlıdır.

Böbrek Nakli İmmünolojisi

Böbrek naklinde greft rejeksiyonu, nakilden sonra oluşabilecek ciddi bir komplikasyondur. Dünya Sağlık Örgütü'ne göre, 2020 yılında dünya çapındaki 129.681

organ naklinin %62,4'ü böbrek nakli ve bunların %31,7'si canlı donörlerdir.¹⁴ Çok sayıda böbrek nakli, öncelikle donör ile alıcı arasındaki yetersiz eşleşmeye bağlı kronik greft rejeksiyonu nedeniyle başarısız olur.¹⁵

Greft rejeksiyonu, zamana (hiperakut, akut veya kronik) ve mekanizmaya (hücre aracılı, antikor aracılı) bağlı olarak sınıflandırılmaktadır. Hiperakut rejeksiyon, nakilden kısa bir süre sonra ortaya çıkmaktadır. Akut rejeksiyona T ve B lenfositleri aracılık etmekte, nakilden sonraki ilk yıl içinde meydana gelmektedir. Kronik rejeksiyon ise greft yetmezliğinin önde gelen nedenidir ve nakilden yıllar sonra gerçekleşmektedir. Ek olarak, hücre aracılı ve antikor aracılı rejeksiyon, karakteristik histolojik özelliklere ve alıcı serumunda anti-donör antikorların saptanmasına dayanır.¹⁶

Bağışıklık sisteminde görev alan T hücrelerinin bir antijene karşı oluşturacağı yanıtın gerçekleşebilmesi için bu antijenin antijen sunan hücreler 'antigen presenting cells' (APC) tarafından alınması ve yüzeylerinde bulunan majör doku uygunluk kompleksine 'major histocompatibility complex' (MHC) bağlanarak T hücrelerine sunulması gerekmektedir. Böbrek naklinde, donör greft antijenlerinin MHC moleküllerinin alıcı T hücreleri tarafından tanınması rejeksiyonun temel nedenlerinden biridir. MHC reseptörlerini içeren HLA, vücuttaki hemen hemen tüm çekirdekli hücrelerde bulunmaktadır. MHC sınıf I reseptörünün işlevi, peptitleri T lenfositlerine sunmaktır. MHC reseptörleri patojen türevli bir peptit sunduğunda, sitotoksik T hücreleri enfekte olmuş hücreyi hedeflemeye yardımcı olurlar. Dokular uyumsuz HLA ile nakledildiğinde, grefte karşı çok güçlü bir sitotoksik T hücresi immün tepkisi ortaya çıkmaktadır. Ek olarak, non-HLA'lar nakil olanlara karşı T hücresi immün tepkilerini de tetikleyebilmektedir. Bu nedenle HLA genotipi, donör-alıcı arasında tam bir eşleşme gösterse bile, non-HLA'lardaki farklılıklar greft rejeksiyonuna neden olacak güçlü bir T hücre tepkisine neden olabilmektedir.¹⁶

Böbrek nakli sonrasında gözlenen bu karmaşık immün değişiklikler nedeniyle, greft rejeksiyonunu etkileyen faktörleri incelemek için büyük veri kümeleri oluşturmaya yönelik çok sayıda uluslararası araştırma yapılmaktadır. Sağlıkla ilgili alanlarda geniş çaplı veri toplamanın önemi giderek arttığından, nakil konusunda farklı bilgilerin depolandığı böbrek hastalıkları ve böbrek nakline özel birçok veri tabanı girişimi olmuştur.¹⁷ Geleneksel istatistiksel metodlar bu veri tabanları tarafından toplanan verileri kullanıp analiz etmede sınırlı bir yeteneğe sahiptir. Buna karşın, klinik çalışmalarda karmaşık etkileşimler göz önüne alındığında, AI algoritmalarını kullanarak yapılan analiz etme ve tahmin modelleme yöntemlerinin başarısı son yıllarda dikkat çekmektedir.¹⁸

Böbrek Naklinde Yapay Zeka

Organ naklinin başlangıcından beri, veri toplama konusu titiz bir yaklaşım olmuştur. Bu oldukça organize yaklaşım, önemli gözlemsel çalışmaların yapılmasına izin vermiş ve araştırma yöntemleri için sayısız veri sağlamıştır.⁵ Böbrek nakillerinde ML tabanlı tahmin modelleri, nakilde greft sağkalımını tahmin etmek için donör ve alıcı faktörleri arasındaki temel ilişkileri bağımsız olarak incelemekte ve aynı anda birden fazla nakil şemasını test etmekte kolaylık sağlamaktadır. Bu nedenle ML yöntemleri kullanılarak greft sağkalımı tahminine yönelik çok sayıda çalışma yapılmıştır (Tablo 1).

Lofaro ve ark.,¹⁹ böbrek nakli olan 80 hastanın retrospektif analizinde, nakilden sonraki 5 yıl içinde kronik greft nefropatisini tahmin etmek için iki farklı sınıflandırma ağacı kullanmışlardır. CAN olarak adlandırılan ilk sınıf, transplantasyondan sonraki 5 yıl içinde kronik greft nefropatisi geliştirme riski taşıyan hastaları içermektedir. no-CAN olarak tanımlanan ikinci sınıf, kronik greft nefropatisi geliştirme riski olmayan hastalardan oluşmaktadır. Çalışma sonucunda, CAN'ın geleneksel istatistiksel metodlara göre iyi bir alternatif olduğunu bildirmişlerdir. CAN gibi hastalıkları nicel veri değerlendirmesinden tahmin edebilen çok faktörlü modeller, özellikle klinik uygulamaya büyük fayda sağlamaktadır. Bu model yalnızca hızlı tahmine dayalı veri madenciliği sağlamakla kalmaz, aynı zamanda risk faktör etkileşimlerinin anında değerlendirilmesine olanak sağlamaktadır.

ANN, bağımlı ve bağımsız değişkenler arasındaki doğrusal olmayan karmaşık ilişkileri ve değişkenler arasındaki tüm olası etkileşimleri tespit edebilir. Öte yandan LR, değişkenlerinin yeterli bir örneklem büyüklüğü olduğunda ve sonuçların doğrudan yorumlanması gerektiğinde tercih edilmektedir. Bu nedenle, bir veri kümesini analiz etmede bu iki yöntemin performansını kullanmak ve karşılaştırmak önemlidir. Lin ve ark.,²⁰ Ocak 1995-Aralık 2002 yılları arasında böbrek nakli olan 57.389 hastada greft sağkalımı tahmini için LR, ANN, Cox modellerini karşılaştırmışlardır. Bu çalışmada, LR'nin ANN'ye benzer performans elde edebildiğini göstermişlerdir. Tang ve ark.,²¹ Temmuz 1985 ile Aralık 2002 arasındaki dönemde sistemik lupus eritematozus olan 4.754 böbrek nakilli hastalarda 3 yıllık greft sağkalımının değerlendirilmesi için, sınıflandırma ağaçları, LR ve ANN'leri kullanmışlardır. Tang ve ark.,²¹ LR ve sınıflandırma ağaçlarının performansının ANN'nin performansı ile benzer olduğunu bildirmişlerdir. Simic-Ogrizovic ve ark.,²² böbrek naklinden sonra gelişen kronik rejeksiyonu ANN metodu ile tahmin etmek üzere klinik ve patolojik olarak doğrulanmış 27 hasta ve 33 değişkenden elde edilen verileri incelemişlerdir. Çalışma sonucunda, ANN'nin kronik rejeksiyonu tahmin etmede

Tablo 1. Böbrek naklinde greft sağkalımı için AI çalışmaları								
Yıl	Veri	Hasta	Çalışma	Ülke	AI/ML	Amaç	Sonuç	Kaynak
1999	Karışık	27	R	Yugoslavya	ANN	Kronik böbrek rejeksiyonu ile ilişkili değişkenleri seçmek için ANN kullanılması	ANN, kronik böbrek rejeksiyon tahmininde geleneksel istatistiksel yöntemlere göre güvenilirdir.	22
2008	USRDS + UNOS (1995-2002)	57.389	R	Amerika Birleşik Devleti	LR, Cox modelleri, tek-çıktı ANN, çoklu-çıktı ANN	Greft başarısızlığını tahmin etmek için LR, ANN, Cox modellerinn karşılaştırılması	LR, ANN ile karşılaştırılabilir performans elde edebilir.	20
2010	Karışık	194	R	İtalya	DT	5 yıllık greft kaybının tahmini için denetimli ML modelinin kullanılması	ML, çeşitli risk faktörleri arasındaki etkileşimlerin analizine izin verebileceğinden, geleneksel istatistiklere göre uygun bir alternatif olabilir.	24
2010	Tek merkezli (1996-2003)	80	R	İtalya	C4.8 algoritmasına dayalı iki farklı DT (CAN, no-CAN)	DT ile kronik greft nefropatisinin tahmin edilmesi için CAN ve no-CAN modelinin kullanılması	DT kullanımı, kronik greft risk faktörlerinin değerlendirilmesinde geleneksel istatistiklere geçerli bir alternatif sunar.	19
2011	USRDS (1985-2002)	4.754	R	Amerika Birleşik Devleti	ANN, LR, DT	Sistemik lupus eritematozuslu hastalarda 3 yıllık greft sağkalımını tahmin etmek için veri yöntemlerinin karşılaştırılması	ANN, LR ve DT performansını iyileştirmek için büyük miktarlarda veri kümesi gerekiyor.	21
2017	Üç merkezli (1997-2012)	3.117	R	Güney Kore	DT, RF	Denetimli ML algoritmalarının tahmin gücünün değerlendirilmesi ve sonuçların geleneksel istatistiksel modellerle karşılaştırılması	ML tarafından oluşturulan bir DT gelişmiş ML tekniklerinin uygulanmasını destekleyerek, geleneksel istatistiksel modellere göre greft sağkalımını tahmin etme doğruluğu göstermiştir.	25
2017	Nemazee Hastanesi, Şiraz, Güney İran (2008-2012)	717	P	İran	ML-ANN, LR, SVM	Böbrek nakli yapılan hastalarda greft sağkalımını tahmin etmek için LR ile ML karşılaştırılması	ANN ve SVM böbrek nakli alıcılarında sağkalım tahminini belirlemek için verimli bir şekilde kullanılabilir.	23
2019	UNOS/ OPTN (1987-2017)	100.000	R	Amerika Birleşik Devleti	RF	Böbrek nakli sonuçları tahmin etmede ML modeli için farklı yöntemler kullanılması	Geleneksel istatistik modelleriyle eşleştirilen ML tahminleri, EPTS'den daha iyi performans göstermiştir.	26

Tablo 1. Devamı								
Yıl	Veri	Hasta	Çalışma	Ülke	AI/ML	Amaç	Sonuç	Kaynak
2020	SRTR/ OPTN (2005-2016)	133.431	R	Amerika Birleşik Devleti	RF,GB	ML'nin böbrek naklinde sonuçlarını tahmin etmede geleneksel regresyona dayalı metodlarla karşılaştırılması	ML regresyona dayalı modellerden daha iyi performans göstermemiştir.	27
2020	COTRS (2015-2018)	531	R	Çin	SVM, LR, RF	Böbrek nakli sonrası ağır pnömoni ihtimalini tahmin etmek için ML modellerinin kullanılması	RF nakil sonrası ağır pnömoni ihtimalini tahmin etmek için iyi performans göstermiştir.	12
2020	iki merkez (2015-2017)	443	R	Brezilya	ANN, SVM, DT, KNN	Böbrek greft fonksiyonunu tahmin etmek için ML ve lojistik regresyon modellerinin kullanılması	Donör bakımıyla ilgili bazı değişkenler gecikmiş greft işleviyle ilişkilendirilmiştir, bu durum zayıf klinik ve hemodinamik durumun greft fonksiyonu üzerinde potansiyel bir etkisi olduğunu düşündürmektedir.	28
2021	15 merkezden toplanmış (2000-2016)	14.132	P	Fransa	-	Böbrek naklinden sonra glomerüler filtrasyon hızı ve son evre böbrek hastalığı ilerleme yörüngelerinin analizi	Böbrek naklinde son evre böbrek hastalığı ilerleme yörüngelerinin analizi için önerilebilir.	30

USRDS: The United States Renal Data System, ABD böbrek veri sistemi, UNOS: United Network for Organ Sharing, Organ paylaşımı için birleşik ağ, OPTN: Organ Procurement and Transplantation Network, Organ nakli ve transplantasyon ağı, COTRS: China Organ Transplant Response System, Çin organ nakli yanıt sistemi, SRTR: Scientific Registry of Transplant Recipients, Nakil alıcıları bilimsel kayıt sistemi, EPTS: Estimated Post-Transplant Survival, Tahmini nakil sonrası sağkalım, RF: Random Forest, Rassal orman, SVM: Support Vector Machine, Destek vektör makinesi, ANN: Artificial Neural Networks, Yapay sinir ağları, KNN: K-Nearest Neighbor, K-en yakın komşuluk, DT: Decision Tree, Karar ağacı, DL: Deep learning, Derin öğrenme, GB: Gradient Boost, Gradyan artırma, NB: Naive Bayes, LR: Logistic Regression, Lojistik regresyon, R: Retrospektif, P: Prospektif

geleneksel istatistiksel metodlara göre daha güvenilir olduğunu bildirmişlerdir. Luo ve ark.,¹² böbrek nakli olan hastalarda ağır pnömoni ihtimalini tahmin etmek için ML modellerinden SVM, LR, RF'yi kullanmışlardır. Ocak 2015'ten Aralık 2018'e kadar nakil olan 531 hastanın retrospektif analizinde, böbrek nakli sonrası pnömoni ihtimalini tahmin etmede %67 duyarlılık ve %97 özgüllük ile RF'nin iyi bir alternatif olabileceğini bildirmişlerdir. Nematollahi ve ark.,²³ tahmin modelleri oluşturmak için ANN, LR ve SVM'leri kullanarak 2008 ve 2012 yılları arasında İran'da böbrek nakli olan 717 hastada 5 yıllık greft sağkalımını incelemişlerdir. Çalışma sonucunda SVM, MLP-ANN, LR sırasıyla %98,2, %97,3, %97,5 duyarlılık ve %49,6, %26,1, %17,4 özgüllük performansı göstermiştir. Nematollahi ve ark.,²³ greft sağkalım tahmini için SVM ve ANN modellerinin kullanılabileceğini bildirmişlerdir.

Greco ve ark.,²⁴ yaptıkları çalışmada greft yetmezliğinin tahmini için böbrek nakli olan 194 hastayı 5 yıl boyunca takip etmişlerdir. Bu çalışmada DT'leri kullanarak hastalarda; yaş, cinsiyet, diyalizde geçirilen süre, donör tipi, donör yaşı, HLA uyumsuzlukları, gecikmiş greft fonksiyonu, vücut kitle indeksi incelenmiştir. Klinik uygulamada karar ağaçlarının geleneksel istatistiksel metodlara %88,2 duyarlılık ve %73,8 özgüllük ile alternatif olabileceğini bildirmişlerdir. Yoo ve ark.,²⁵ böbrek nakli olan 3.117 hastanın retrospektif analizinde greft sağkalımını tahmin etmek için ML modellerini kullanmışlardır. Yoo ve ark.,²⁵ nakilden 1 yıl sonra gelişen akut rejeksiyonunun önemli ölçüde artmış greft yetmezliği riski ile ilişkili olduğunu ve ML yöntemlerinin greft sağkalımını tahmin etmek için esnek ve pratik olduğunu bildirmişlerdir. Mark ve ark.,²⁶ greft sağkalımını tahmin etmek için farklı ML modeli yöntemlerini birleştirmişlerdir. Mark ve ark.,²⁶

ML modelinin Amerika'da böbrek naklinde kullanılan modelden 'estimated post-transplant survival' (EPTS) daha iyi bir performans gösterdiğini öne sürmüşlerdir. Bae ve ark.,²⁷ 2005-2017 yılları arasında böbrek nakli olan 133.431 hastada nakil sonuçlarını tahmin etmek için ML metodlarını geleneksel regresyon analizi ile karşılaştırmışlardır. Çalışmada, geleneksel regresyona dayalı yaklaşımlar çeşitli böbrek nakli sonuçlarını tahmin etmede ML'den daha iyi performans göstermiştir. Costa ve ark.,²⁸ böbrek nakli olan 531 hastanın retrospektif analizinde, nakilden sonra greft fonksiyonunu tahmin etmek için ML ve LR modellerini kullanmışlardır. Çalışma sonucunda, bazı değişkenler gecikmiş greft fonksiyonuyla ilişkilendirilmiştir.

Glomerüler filtrasyon hızı (eGFR) böbrek kan dolaşımındaki atıkları ne kadar iyi filtrelediğini ölçerek dakikada glomerüllerden süzülen kan miktarını ifade etmektedir. Rashidi Khazae ve ark.,²⁹ böbrek nakli olan hastalarda eGFR değerlerini tahmin etmek için ANN tabanlı bir model geliştirmişlerdir. ANN tabanlı model, verilere dayalı olarak eGFR değerini öngörmüştür. Ayrıca, Raynaud ve ark.,³⁰ farklı ML teknikleri kullanarak 14.132 hastanın eGFR ölçümünü analiz etmişlerdir. Raynaud ve ark.,³⁰ sonuçlarının risk sınıflandırması ve izleme açısından böbrek nakli hastalarının eGFR ölçümüne dayalı bir değerlendirmesi için temel oluşturduğunu öne sürmüşlerdir. Literatürdeki bu verilerden de anlaşıldığı üzere AI'nin böbrek naklinde greft sağkalımının tahminine yönelik kullanımı giderek artmakta ve umut vaad edici sonuçlar doğurmaktadır.

SONUÇ

Günümüzde, AI farklı disiplinler arasında önemli bir işlev göstermektedir ve gelecekte tıbbın ayrılmaz bir parçası olacaktır. Tıpta AI teknolojilerinin yardımıyla radyolojik^{31,32}, patolojik^{33,34}, endoskopik^{35,36}, ultrasonografi³⁷ ve biyokimyasal³⁸ incelemeler yapılmaktadır. AI algoritmaları, klasik modellerle karşılaştırılabilir doğrulukla sonuç vermekte ve organ naklinden immünosupresyon ilaç dozuna kadar her adımda klinisyenlere yardımcı olmaktadır. Yapılan çalışmalar, AI'nin hastalıkların risk değerlendirmesinde kullanılabileceğini göstermekte, prognoz ve klinik stratejiler üzerinde önemli rol oynadığını belirtmektedir. Çoğu ülkenin halihazırda sahip olduğu ilkel veri tabanlarının standart bir sete dönüştürülmesi, AI bulgularına büyük ölçüde fayda sağlayacağından, üzerinde çalışılması gereken bir alandır. Ülkeler AI'yi kullanarak bir veri tabanı geliştirdiğinde, artan sayıdaki veri kümeleri daha iyi AI modeli oluşturmayı mümkün kılacağından, çalışmalar daha iyi ve daha güvenilir bulgular sağlayacaktır. Buna rağmen AI'nin bazı dezavantajları bulunmaktadır. AI sistemleri, yalnızca denemek üzere tasarlandıkları veya programlandıkları görevleri yerine getirebilirler,

bunun dışında ciddi bir arka plan olabilecek ilgisiz çıktılar verebilirler. Ayrıca eleştirel düşünme, iletişim becerileri, duygusal zeka ve yaratıcılık gibi belirli insan özellikleri AI yöntemleri tarafından bilinemez. AI algoritmaları olağandışı olguları tespit etmekte zorlanabileceğinden, bu olgular için klinisyenlerin onayı önemlidir. Bu sonuçlar birlikte ele alındığında, AI yöntemleri kısa ve uzun süreli böbrek greft sağkalımını tahmin eden modeller, donör ve alıcılar arasında mümkün olan en iyi eşleşmeyi en üst düzeye çıkarmada bir araç olarak kullanılabilir. Nakillerde greft sağkalımının tahmini, klinik olarak önemli ancak zorlu bir problemdir, bu sebeple AI organ naklinin başarısına yönelik önemli bir adım olacaktır.

Etik

Hakem Değerlendirmesi: Editörler kurulu ve editörler kurulu dışında olan kişiler tarafından değerlendirilmiştir.

Yazarlık Katkıları

Konsept: T.Ö., M.P., İ.P., Dizayn: İ.P., Veri Toplama veya İşleme: T.Ö., Analiz veya Yorumlama: T.Ö., M.P., İ.P., Literatür Arama: T.Ö., Yazan: T.Ö., M.P., İ.P.

Çıkar Çatışması: Yazarlar bu makale ile ilgili olarak herhangi bir çıkar çatışması bildirmemiştir.

Finansal Destek: Çalışmamız için hiçbir kurum ya da kişiden finansal destek alınmamıştır.

KAYNAKLAR

1. McMichael J, Irish W, McCauley J, et al. Evaluation of a novel "intelligent" dosing system for optimizing FK 506 therapy. *Transplant Proc.* 1991;23:2780-2.
2. Gören S, Karahoca A, Onat FY, Gören MZ. Prediction of cyclosporine A blood levels: an application of the adaptive-network-based fuzzy inference system (ANFIS) in assisting drug therapy. *Eur J Clin Pharmacol.* 2008;64:807-14.
3. Decruyenaere A, Decruyenaere P, Peeters P, et al. Prediction of delayed graft function after kidney transplantation: comparison between logistic regression and machine learning methods. *BMC Med Inform Decis Mak.* 2015;15:83.
4. Vittoraki AG, Fylaktou A, Tarassi K, et al. Patterns of 1,748 Unique Human Alloimmune Responses Seen by Simple Machine Learning Algorithms. *Front Immunol.* 2020;11:1667.
5. Massie AB, Boyarsky BJ, Werbel WA, et al. Identifying scenarios of benefit or harm from kidney transplantation during the COVID-19 pandemic: A stochastic simulation and machine learning study. *Am J Transplant.* 2020;20:2997-7.
6. Ginley B, Lutnick B, Jen KY, et al. Computational Segmentation and Classification of Diabetic Glomerulosclerosis. *J Am Soc Nephrol.* 2019;30:1953-7.
7. Park SH, Mazumder NR, Mehrotra S, Ho B, Kaplan B, Ladner DP. Artificial Intelligence-related Literature in Transplantation: A Practical Guide. *Transplantation.* 2021;105:704-8.
8. Connor KL, O'Sullivan ED, Marson LP, Wigmore SJ, Harrison EM. The Future Role of Machine Learning in Clinical Transplantation. *Transplantation.* 2021;105:723-5.

9. Thongprayoon C, Kaewput W, Kowuru K, et al. Promises of Big Data and Artificial Intelligence in Nephrology and Transplantation. *J Clin Med*. 2020;9:1107.
10. Xie G, Chen T, Li Y, Chen T, Li X, Liu Z. Artificial Intelligence in Nephrology: How Can Artificial Intelligence Augment Nephrologists' Intelligence? *Kidney Dis (Basel)*. 2020;6:1-6.
11. Niel O, Bastard P. Artificial Intelligence in Nephrology: Core Concepts, Clinical Applications, and Perspectives. *Am J Kidney Dis*. 2019;74:803-10.
12. Luo Y, Tang Z, Hu X, et al. Machine learning for the prediction of severe pneumonia during posttransplant hospitalization in recipients of a deceased-donor kidney transplant. *Ann Transl Med*. 2020;8:82.
13. Briceño J. Artificial intelligence and organ transplantation: challenges and expectations. *Curr Opin Organ Transplant*. 2020;25:393-8.
14. World Health Organization (WHO) Global Observatory on Donation and Transplantation. Last Accessed date: 23.05.2022. Available from: <http://www.transplant-observatory.org>
15. Topuz K, Zengul FD, Dag A, Almehtmi A, Yildirim MB. 2018. Predicting graft survival among kidney transplant recipients: A Bayesian decision support model. *Decision Support Systems*. 2018;106:97-109.
16. Benedict LP, Chris C. The immunology of organ transplantation. *Surgery (Oxford)*. 2020;38:353-60.
17. Castillo-Astorga R, Sotomayor CG. Toward Advancing Long-Term Outcomes of Kidney Transplantation with Artificial Intelligence. *Transplantation*. 2021;2:118-8.
18. Naqvi SAA, Tennankore K, Vinson A, Roy PC, Abidi SSR. Predicting Kidney Graft Survival Using Machine Learning Methods: Prediction Model Development and Feature Significance Analysis Study. *J Med Internet Res*. 2021;23:e26843.
19. Lofaro D, Maestriperi S, Greco R, et al. Prediction of chronic allograft nephropathy using classification trees. *Transplant Proc*. 2010;42:1130-3.
20. Lin RS, Horn SD, Hurdle JF, Goldfarb-Rumyantzev AS. Single and multiple time-point prediction models in kidney transplant outcomes. *J Biomed Inform*. 2008;41:944-52.
21. Tang H, Poynton MR, Hurdle JF, Baird BC, Koford JK, Goldfarb-Rumyantzev AS. Predicting three-year kidney graft survival in recipients with systemic lupus erythematosus. *ASAIO J*. 2011;57:300-9.
22. Simic-Ogrizovic S, Furuncic D, Lezaic V, Radivojevic D, Blagojevic R, Djukanovic L. Using ANN in selection of the most important variables in prediction of chronic renal allograft rejection progression. *Transplant Proc*. 1999;31:368.
23. Nematollahi M, Akbari R, Nikeghbalian S, Salehnasab C. Classification Models to Predict Survival of Kidney Transplant Recipients Using Two Intelligent Techniques of Data Mining and Logistic Regression. *Int J Organ Transplant Med*. 2017;8:119-2.
24. Greco R, Papalia T, Lofaro D, Maestriperi S, Mancuso D, Bonofiglio R. Decisional trees in renal transplant follow-up. *Transplant Proc*. 2010;42:1134-6.
25. Yoo KD, Noh J, Lee H, et al. A Machine Learning Approach Using Survival Statistics to Predict Graft Survival in Kidney Transplant Recipients: A Multicenter Cohort Study. *Sci Rep*. 2017 21;7:8904.
26. Mark E, Goldsman D, Gurbaxani B, Keskinocak P, Sokol J. Using machine learning and an ensemble of methods to predict kidney transplant survival. *PLoS One*. 2019;14:e0209068.
27. Bae S, Massie AB, Caffo BS, Jackson KR, Segev DL. Machine learning to predict transplant outcomes: helpful or hype? A national cohort study. *Transpl Int*. 2020;33:1472-80.
28. Costa SD, de Andrade LGM, Barroso FVC, et al. The impact of deceased donor maintenance on delayed kidney allograft function: A machine learning analysis. *PLoS One*. 2020;15:e0228597.
29. Rashidi Khazae P, Bagherzadeh J, Niazkhani Z, Pirnejad H. A dynamic model for predicting graft function in kidney recipients' upcoming follow up visits: A clinical application of artificial neural network. *Int J Med Inform*. 2018;119:125-3.
30. Raynaud M, Aubert O, Reese PP, et al. Trajectories of glomerular filtration rate and progression to end stage kidney disease after kidney transplantation. *Kidney Int*. 2021;99:186-7.
31. Sorrentino FS, Jurman G, De Nadai K, Campa C, Furlanello C, Parmeggiani F. Application of Artificial Intelligence in Targeting Retinal Diseases. *Curr Drug Targets*. 2020;21:1208-15.
32. Gong J, Liu JY, Sun XW, Zheng B, Nie SD. Computer-aided diagnosis of lung cancer: the effect of training data sets on classification accuracy of lung nodules. *Phys Med Biol*. 2018;63:035036.
33. Hart SN, Flotte W, Norgan AP, et al. Classification of Melanocytic Lesions in Selected and Whole-Slide Images via Convolutional Neural Networks. *J Pathol Inform*. 2019;10:5.
34. Kosaraju SC, Hao J, Koh HM, Kang M. Deep-Hipo: Multi-scale receptive field deep learning for histopathological image analysis *Methods*. 2020;179:3-13.
35. Gulati S, Emmanuel A, Patel M, et al. Artificial intelligence in luminal endoscopy. *Ther Adv Gastrointest Endosc*. 2020;13:2631774520935220.
36. Hwang Y, Lee HH, Park C, et al. Improved classification and localization approach to small bowel capsule endoscopy using convolutional neural network. *Dig Endosc*. 2021;33:598-607.
37. Nguyen DT, Pham TD, Batchuluun G, Yoon HS, Park KR. Artificial Intelligence-Based Thyroid Nodule Classification Using Information from Spatial and Frequency Domains. *J Clin Med*. 2019;8:1976.
38. Tomita K, Nagao R, Touge H, et al. Deep learning facilitates the diagnosis of adult asthma. *Allergol Int*. 2019;68:456-61.