

# Endokrinolojide Yapay Zeka Uygulamaları

## Artificial Intelligence Applications in Endocrinology

© Banu Aktaş Yılmaz<sup>1</sup>, © Asım Egemen Yılmaz<sup>2,3,4</sup>

<sup>1</sup>Ufuk Üniversitesi Tıp Fakültesi, İç Hastalıkları Anabilim Dalı, Endokrinoloji ve Metabolizma Hastalıkları Bilim Dalı, Ankara, Türkiye

<sup>2</sup>Ankara Üniversitesi Mühendislik Fakültesi, Elektrik-Elektronik Mühendisliği Bölümü, Ankara, Türkiye

<sup>3</sup>Ankara Üniversitesi Mühendislik Fakültesi, Yazılım Mühendisliği Bölümü, Ankara, Türkiye

<sup>4</sup>Ankara Üniversitesi Fen Bilimleri Enstitüsü, Disiplinler Arası Yapay Zeka Teknolojileri Anabilim Dalı, Ankara, Türkiye

### Öz

Canlıların merkezi sinir sistemlerindeki öğrenme mekanizmalarını taklit etme esasına dayalı bir yaklaşım olan yapay zeka, son yıllarda birçok farklı alanda hayatımıza girmiş durumdadır. Endokrinoloji ve metabolizma hastalıkları da yapay zekanın uygulama alanı bulduğu bir mecradır. Bu makalede yapay zekanın bir taksonomisinin yanı sıra endokrinoloji ve metabolizma hastalıklarındaki mevcut ve potansiyel/olası uygulama alanları sunulmakta ve tartışılmaktadır.

**Anahtar Kelimeler:** Yapay Zeka Taksonomisi, Endokrinoloji, Metabolizma

### Abstract

Artificial intelligence, which is an approach based on mimicking the learning mechanisms inside the central nervous systems of living creatures, has widely spread to our daily life. Endocrinology and metabolism diseases is a field in which artificial intelligence has found considerable number of applications. In this article, in addition to a taxonomy of artificial intelligence, its current and potential/probable applications in endocrinology and metabolism diseases are presented and discussed.

**Key Words:** Artificial Intelligence Taxonomy, Endocrinology, Metabolism

### Giriş

#### Yapay Zeka Nedir?

Yapay zeka canlıların, özellikle de karmaşık organizmaların merkezi sinir sistemlerindeki belirli bir takım öğrenme mekanizmalarını taklit ederek öğrenen ve buna dayalı olarak karmaşık birtakım problemlere çözüm getiren yazılım ve donanımlara verilen genel bir isimlendirmedir. 1950'li yıllardan bu yana yaşamımızda olan bu kavram sayesinde, günlük hayatta karşılaşılmakta olduğumuz, aralarında karmaşık/girift ilişkiler/

ilintiler bulunan birçok değişkene bağımlı zor problemlerin çözümü de mümkün hale gelmiştir/gelmektedir.

Yapay zeka altında önemli bir kavram olan Makine Öğrenmesi, Şekil 1'de de görüldüğü üzere üç temel yaklaşım içermektedir:

- Gözetimsiz veya Denetimsiz Öğrenme (*Unsupervised Learning*)
- Gözetimli veya Denetimli Öğrenme (*Supervised Learning*)
- Pekiştirmeli Öğrenme (*Reinforcement Learning*).

Gözetimsiz veya Denetimsiz Öğrenme, verilen bir veri kümesi içerisinde alt grup veya kümelerin bulunması, bir

Yazışma Adresi/Address for Correspondence: Banu Aktaş Yılmaz

Ufuk Üniversitesi Tıp Fakültesi, İç Hastalıkları Anabilim Dalı, Endokrinoloji ve Metabolizma Hastalıkları Bilim Dalı, Ankara, Türkiye

Tel.: +90 532 302 32 65 E-posta: baktasyilmaz@yahoo.com ORCID ID: orcid.org/0000-0003-1987-486X

Geliş Tarihi/Received: 11.11.2022 Kabul Tarihi/Accepted: 23.11.2022

©Telif Hakkı 2022 Ankara Üniversitesi Tıp Fakültesi

Ankara Üniversitesi Tıp Fakültesi Mecmuası, Galenos Yayınevi tarafından yayınlanmıştır.

Yayınlanan tüm içerik CC BY-NC-ND lisansı altındadır.



başka deyişle Kümeleme/Öbekleme/Demetleme (*Clustering*) olarak anılan işlevin yerine getirilmesinde kullanılmaktadır. Gözetimsiz veya Denetimsiz Öğrenmenin bir başka uygulaması, aralarında karmaşık/girift ilintiler/ilişkiler bulunan çok sayıda değişken içeren problemlerde değişkenler arasındaki ilintilerin/ilişkilerin ortaya çıkarılması, çıktı (yani bağımlı değişken) üzerinde en baskın etkisi olan girdi değişkenlerin (yani bağımsız değişkenlerin) belirlenmesi; dolayısıyla da girdi-çıktı (bağımsız ve bağımlı değişkenler) arasındaki ilişkilerin daha sade ve net bir şekilde ortaya konulmasıdır.

Öte yandan Gözetimli veya Denetimli Öğrenme ise, ilgili konudaki "uzman insanlar (*expert human*)" tarafından "etiketlenmiş (*labeled*)", bir başka deyişle halihazırda tanı konulmuş olan bir veri seti üzerinden makinenin eğitilmesi esasına dayanmaktadır. Duruma dayalı eğitim (*just in case teaching*) yönteminin uygulandığı bu yaklaşımda eğitilen algoritmanın, doğru ve yanlış kararları söz konusu etiketler üzerinden süreç içerisinde öğrenmesi hedeflenir. Tahmin edilecek veya kestirilecek bağımlı değişkenin kategorik/niteliksel bir değişken olması durumunda Sınıflandırma (*Classification*) problemi, söz konusu değişkenin nümerik/niceliksel bir değişken olması durumunda ise Regresyon (*Regression*) problemi olarak adlandırılan problemlerin bu sayede çözülmesi mümkündür.

Son yıllarda büyük ilgi uyandırmakta olan Pekiştirmeli Öğrenme ise, "ajan (*agent*)" olarak adlandırılan ve algoritma içerisinde bulunan sanal bir problem çözücünün, çok sayıda deneme-yanılma sonucunda problem uzayını keşfederek eldeki problemi çözmesi esasına dayanır. Başarısız her bir denemesinden kendince birtakım dersler çıkaran ajan, bir sonraki denemesine daha bilinçli ve bilgili bir şekilde başladığından ötürü belirli bir

süre sonra çözümünü keşfeder. Burada belirtilmesi gereken en önemli husus, ajanın doğru dersler çıkarabilmesi için ödül ve ceza mekanizmalarının iyi tanımlanmış olmasının gerekliliğidir.

Yukarıdaki paragraflarda anılan üç yaklaşımda da yapay zekanın başarısı, insan zekasının sürece etkin bir şekilde dahil olmasını gerektirmektedir:

- Gözetimsiz veya Denetimsiz Öğrenme uygulamalarında, değişkenler arasındaki ilintinin tesadüfi mi, yoksa nedensellik (*causality*) yani sebep-sonuç ilişkisine dayalı olup olmadığının yorumlanması,

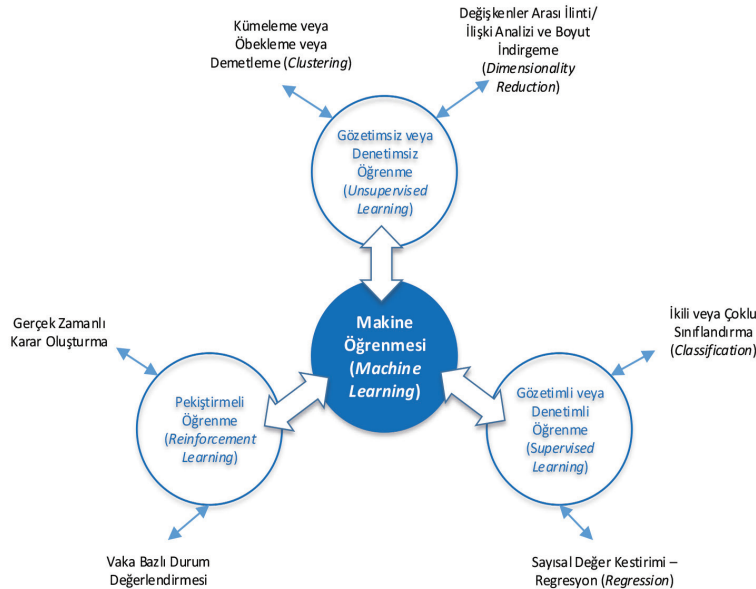
- Gözetimli veya Denetimli Öğrenme uygulamalarında, verinin doğru bir şekilde etiketlenmiş olması, yapay zeka mimarisinin eldeki probleme uygun olacak şekilde oluşturulması,

- Pekiştirmeli Öğrenme uygulamalarında da eldeki problem uzayının doğru bir şekilde tanımlanması/modellenmesi ve ödül-ceza mekanizmalarının doğru bir şekilde tanımlanması.

Dolayısıyla yapay zekanın insanın yerini tamamen alacak olması, ilgili problemlerin çözümünde halihazırda istihdam edilen insanlara artık ihtiyaç kalmayacak olması gibi kaygılar; kısa ve orta vadede yersiz görünmektedir.

## Yapay Zeka ve Endokrinolojideki Olası Uygulamaları

Endokrinoloji ve metabolizma hastalıkları bazında en büyük hasta gruplarından birini diyabet hastaları oluşturmakta olup; bu hastalığın tanı ve tedavisindeki sorunlara çözümler getirebilmek adına yapay zeka temelli çalışmalar halen devam etmektedir. Yukarıda sözü edilen ve Şekil 1'de anılan Makine Öğrenmesi yaklaşımları ve uygulama alt alanları, endokrinoloji



Şekil 1: Makine öğrenmesi ve temel yaklaşımlar

ve metabolizma hastalıkları uzmanlığı özelinde Şekil 2'deki gibi örnekler üzerinden detaylandırılabilir:

#### - Gözetimsiz veya Denetimsiz Öğrenme:

- Kümeleme/Öbekleme/Demetleme (*Clustering*): Bu kapsamda, toplum ve halk sağlığına yönelik birtakım analizler gerçekleştirilebilir. Örneğin, "verilen bir grup içerisinde diyabet gelişme riskine yönelik olarak alt grupların belirlenmesi", endokrinolojideki önemli bir kümeleme problemidir.
- Değişkenler Arası İlinti/İlişki Analizi ve Boyut İndirgeme (*Dimensionality Reduction*): Bu kapsamda, örneğin diyabet tanısına işaret eden değişkenler arasında ilinti analizleri gerçekleştirilebilir. Bu kapsamda yapılabilecek bir başka çalışma da farklı hastalıklara ilişkin ortak bulguların belirlenmesi, yani literatürde "Hastalık Öbekleme (*Disease Clustering*)" olarak da anılan işlemin gerçekleştirilmesidir.

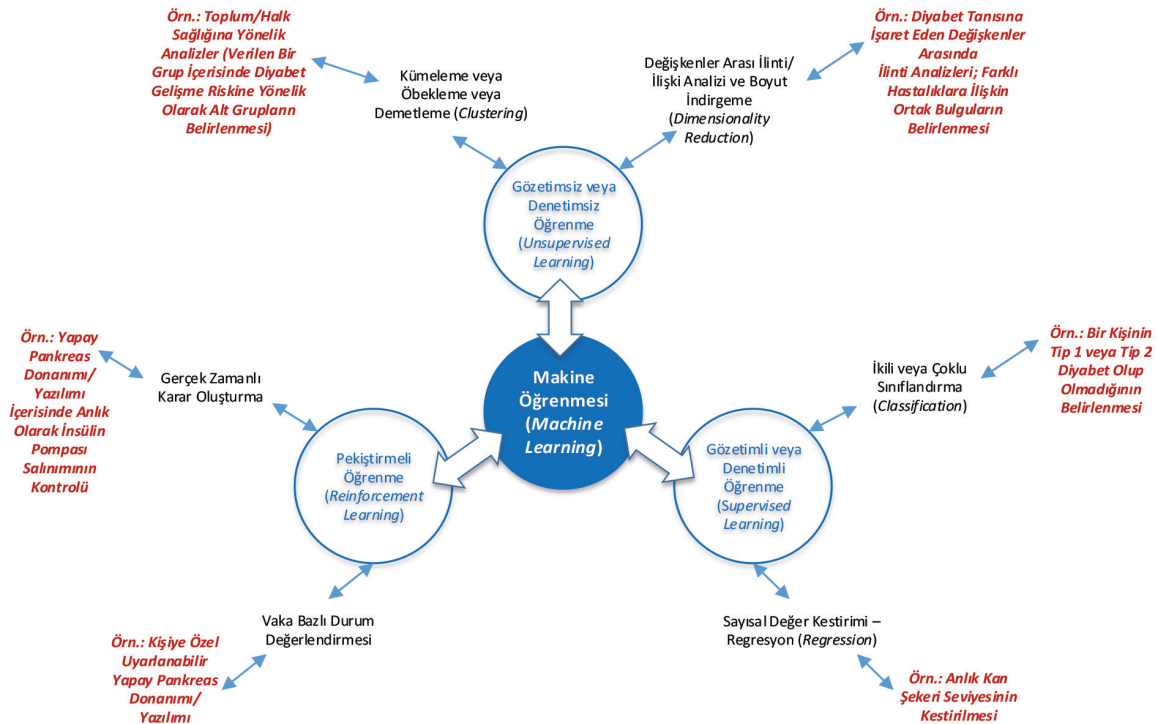
#### - Gözetimli veya Denetimli Öğrenme (*Supervised Learning*):

- Sınıflandırma (*Classification*): Bir kişinin Tip 1 veya Tip 2 diyabet olup olmadığını belirlenmesi; ya da Tip 1 veya Tip 2 diyabet tanısı konulmuş bir kişinin evresinin belirlenmesi gibi problemler, bu kapsamda ele alınabilecek problemlerdendir.

- Sayısal Değer Kestirimi-Regresyon (*Regression*): Bir kişinin anlık kan şekeri değerinin kestirilmesi ise, regresyon sınıfına girmekte olan problemlerdendir.

#### - Pekiştirmeli Öğrenme (*Reinforcement Learning*):

- Gerçek Zamanlı Karar Oluşturma (*Real Time Decision Making*): Klinik karar destek sistemlerinde algoritmalar, çözüm üretmeleri için çoğunlukla belirli bir süre tanınmaktadır. Ancak bazı uygulamalar, kısa süre içerisinde bir kararın alınıp uygulanmasını zorunlu kılmaktadır. Örneğin yapay pankreas (YP) uygulamaları, bunun için güzel bir örnek teşkil etmektedir. YP donanımı/yazılımı içerisinde insülin pompası salınımının anlık ve gerçek zamanlı olarak kontrolü, son yıllarda gerçekleştirilmekte olan Pekiştirmeli Öğrenme temelli çalışmalar sayesinde mümkün hale gelmiştir.
- Olgu Bazlı Durum Değerlendirmesi (*Case Based Reasoning*): Pekiştirmeli Öğrenme'nin çözüm getirdiği bir diğer problem, kişiye özel çözümlerin oluşturulmasıdır. Yine YP uygulamasında, insülin pompasının hangi durumda ne kadar miktar ve ne kadar süre boyunca aktive olacağını belirlenmesi/hesaplanması, ilgili kişiye özel olarak gerçekleştirilmesi gereken bir işlemdir.



Şekil 2: Makine öğrenmesi, temel yaklaşımlar ve endokrinoloji alanındaki örnek uygulamaları

## Yapay Zeka ve Endokrinolojideki Uygulamalarına Dair Somut Örnekler

İnsanlık olarak şimdiye kadar tıbbi pratik uygulamalarımızı yönlendiren bilgileri ağırlıklı olarak, sonuçları istatistiksel yöntemlerle değerlendirilen klinik ve laboratuvar çalışmalardan elde etmiş durumdayız. Bir çalışma sonucunda elde edilen verileri istatistiksel yöntemler kullanarak yorumlamaya çalıştığımızda, değişkenler arasındaki etkileşimlere dayanarak karar vermeye gayret etmekteyiz. Makine öğrenmesindeki amaç ise sonucun doğruluğa en yakın şekilde öngörülmesini sağlamaktır. Bir klinik çalışma planlanırken, araştırmacıların akıllarında olan hipotez, aslında gayet idealleştirilmiş bir ortamda test edilmektedir. Söz konusu olan ideal ortamda, birbirlerine göre farkları net olarak belirtilmiş çalışma ve kontrol grupları, sonuçları etkileyebilecek risk faktörleri net olarak belirlenmektedir. Çalışmanın sonunda da, her parametrenin sonuca olan etkisi, istatistiksel modellerin geçerliliği, parametrelerin modellere olan etkileri istatistiksel yöntemlerle tayin edilmektedir. Makine öğrenmesinin felsefesi ise oldukça farklıdır. Burada yapılan eylem, sisteme soru sormak ve sistemin doğruluğa en yakın şekilde cevap verebilmesini sağlamaktır. Çok fazla değişkenin olduğu, değişkenlerin birbirleri arasında yakın etkileşimlerin olduğu, grupların ya da türlerin net olarak ayrımlarının yapılamadığı durumlarda örneğin mikrobiyotaya ile ilgili araştırmalarda yapay zekanın kullanılması daha uygun olmaktadır (1).

ABD Gıda ve İlaç İdaresi'nin (*Food and Drug Administration-FDA*) kullanım onayı verdiği tanınmış amaçlı ilk yapay zeka uygulaması, "BodyGuardian" isimli bir aritmi tespit yazılımı idi. 2012 yılında FDA onayı almış olan "BodyGuardian", yama görünümümlü bir cihaz olup aritmileri tespit etmek amacıyla geliştirilmişti ve Albased aritmi tespit etme algoritma kurallarına göre çalışmakta idi. FDA, yapay zeka ile ilgili uygulamaların kullanılmasını onaylamak için, cihazların ya da yazılımların bazı şartlara uygun olmasını talep etmektedir. *FDA 510(k) Clearance* veya *FDA 510(k) Premarket Notification* olarak bilinen ve bir ürünün/teknolojinin FDA tarafından onaylanma sürecini tanımlayan bu madde:

- Gerek zaman alıcı bir süreç tanımlıyor olması;
- Gerekse test edilen sistem/ürün tarafından sağlanan hizmetin bire bir "tekrarlanabilir (*repeatable*)" olmasını zorunlu kılması

dolayısıyla yapay zeka temelli sistemler açısından zorlayıcı bir husustur. Yapay zeka temelli sistemlerin olgu gördükçe sürekli öğrenmeleri ve dolayısıyla davranışlarını yeni öğrendikleri doğrultusunda belirli ölçüde değiştirmelerinden ötürü, farklı zamanlarda yapılan testlerde aynı girdilere karşı farklı çıktılar üretmeleri olasıdır. Bu da FDA'nın "tekrarlanabilirlik (*repeatability*)" isteri ile zaman zaman çelişmekte olup, ilgili sistemin/ürünün onay sürecinde sıkıntılar yaşanmasına sebep

olmaktadır. Bunun yanı sıra çok uzun süren onaylama süreci, teknolojik gelişme hızının gerisinde kalabilmekte; sistemin/ürünün içerdiği algoritma ve yöntemlerin özgünlüklerini yitirmesine de yol açabilmektedir.

Yapay zekanın endokrinoloji ve metabolizma hastalıklarındaki en yaygın ve olgun uygulama alanı, şüphesiz ki diyabete ilişkin çalışmalardır. Diyabetli hastaların yönetiminde yapay zeka, şu alanlarda kendisine bir yer bulmuştur:

- Diyabetik retinopati taramaları,
- Hastanın kendi kendisini değerlendirmesinin sağlanması,
- Hipoglisemi gibi önemli risklerin tahmin edilmesi.

Diyabetik retinopatinin, diyabetik hastalar arasındaki prevalansının %35 olduğu bildirilmiştir (2). Diyabetik retinopatiye bağlı olan görme bozukluklarının prevalansının; diyabetik hastaların sağ kalım sürelerinin artmasına bağlı olarak artması beklenmektedir (3). Retinopatinin varlığını tespit açısından yapılan taramalarda, olguların %14'ünün yeni tanı almış diyabet olması da endişe vericidir (4). Çalışma çağı olarak kabul edilen 20-79 yaşlar arasındaki görme kaybının en önemli nedeni diyabetik retinopatidir. Uluslararası Diyabet Federasyonu (*International Diabetes Federation-IDF*), 2021 yılında 537 milyon olan diyabetik birey sayısının, 2030 yılında 643 milyona ulaşacağını belirtmiştir. Buz dağıının görünmeyen kısmı için de IDF, 2021 yılında her üç diyabetli bireyden birisinin tanı almadığını ve diyabet gelişmesi açısından oldukça riskli olan 541 milyon kişinin bozulmuş glukoz toleransının olduğunu belirtmiştir (5). Diyabet prevalansının yapılan tahminlerden daha hızlı gelişmesi de göz önüne alındığında, diyabetik retinopati taramalarını yapması beklenen oftalmolog sayısı yetersiz kalmaktadır. Ayrıca her 4 diyabetliden 3'ünün sosyo-ekonomik düzeyi kötü olan memleketlerde yaşadığı da göz önüne alındığında hastaların oftalmologlara ulaşım konusunda oldukça şanssız olduğu da görülmektedir. FDA, 2018 yılında, birinci basamak sağlık hizmetlerinde de uygulanabilecek, daha evvel diyabetik retinopati tanısı almayan 22 yaş üzerindeki hastalarda hafif diyabetik retinopati ve beraberinde maküler ödemi olan ya da olmayan hastaları tespit edilebilen, IDx-DR yapay zeka uygulamasının kullanımını onaylamıştır. Bu sistemin sensitivitesinin ve spesifitesinin sırasıyla %87,2 [%95 güven aralığı (GA), 81,8-%91,2] (>%85) ve %90,7 (%95 GA, 88,3-%92,7) (>%82,5) olduğu belirtilmiştir. Sistemin değerlendirilmesine uygun kalitede retinal fotoğraf çekimi eğitiminin yaklaşık 4 saatlik pratik ile sağlanabildiği belirtilmiştir. Aynı çalışmada sistemin değerlendirilmesine uygun teknikte görüntü alınabilme oranının da %96,1 (%95 GA, 94,6-%97,3) olduğu belirtilmiştir (6). Dolayısıyla, uzman oftalmolog kıtlılığı ve elverişsiz sosyo-ekonomik koşullar söz konusu olduğunda bu yöntemin kullanılarak uzman hekime mutlaka gitmesi gerekli olan hastaların ayırt edilebilmesi, aynı yöntemle yıllık

taranmaya uygun olan hastaların takiplerinin birinci basamak sağlık hizmetlerinde yapılabilmesi hem sağlık sistemini hem de hastaları oldukça rahatlatmaktadır. Dünyanın pek çok ülkesinde diyabetik retinopati taramasında yapay zeka kullanılmasına da başlanmıştır.

İlerleyen teknolojinin hayatımıza getirdiği yeni kavramlardan birisi de "bulut sunucu" sistemlerdir, bir başka deyişle, farklı kaynaklardan gelen bilgilerin sanal ortamda depolanabilmesi ve farklı kişilerce kullanılabilmesi. FDA 2018 yılında, DreaMed Diabetes firması tarafından geliştirilen Advisor Pro yapay zeka uygulamasının kullanılmasını onayladı. Bu sistemde buluta gelen, devamlı kan şekeri monitorizasyonu (DKŞM) verileri ve hastaların kendilerinin yaptıkları kan şekeri monitorizasyonu verileri kullanılarak, uygulanması gereken insülin dozlarının tayini yapılmaktadır. İnsülin dozlarının ayarlanmasında yapay zeka kullanımının, hastaların hedef kan şekeri aralıklarında kalmalarını sağlamada, hipoglisemi durumlarının önlenmesini sağlamada insülin dozlarının hekim tarafından ayarlanmasına göre aşağı olmadığını gösteren çalışmalar da mevcuttur (7). T1DM'li hastalarda yoğun insülin tedavisinin uygulanarak, iyi bir glisemik kontrol sağlandığı takdirde diyabetin komplikasyonlarının gelişmesi önlenmektedir. İyi bir glisemik kontrolün sağlanabilmesi, özellikle genç ve aktif T1DM'li bireylerde, insülin pompa ayarlarında sık değişiklikler yapmak gerekebilmektedir. Hastaların doktorlara ulaşma sıkıntısı yaşamaları, kontrollerini aksatmaları, DKŞM sonuçlarının poliklinik şartlarında bazen yeterince iyi değerlendirilememesi, bazen de hekimlerin pompa kullanımı hakkında yeterince tecrübeli olmamaları nedeni ile gerekli olan sık insülin dozlarındaki değişiklikler yapılamamaktadır. Güvenilirliği gösterilmiş yapay zeka uygulamaları bu açıkları kapatmada yardımcı olabilmektedir.

Hasarlanmamış bir pankreas dokusunun insülin ve glukagon salgılama dinamiklerine en yakın şekilde insülin ve glukagon dozlarını sisteme verebilen en mükemmel YP'nin geliştirilmesi yapay zeka uygulamalarının diyabet tedavisindeki en önemli hedeflerinden birisidir. YP, glukoz sensörü, kapalı devre kontrol algoritması ve insülini sisteme veren pompadan oluşmaktadır. Uygulanması gereken insülin dozlarının hesaplanması gerçek ve sanal hastalarından elde edilmiştir. YP, ideal bir şekilde çalışırsa T1DM'li hastaların da hayatı tehdit eden özellikle hipoglisemi durumlarının ve kronik hiperglisemileri kontrol edilerek kronik komplikasyonlar büyük ölçüde önlenir. Farklı algoritmalar kullanarak, nokturnel hipoglisemiye yol açmadan gece kan şekeri düzenlenmesi, kan şekeri dalgalanmalarının azaltılması amaçlanmaktadır (8,9).

FDA, 2018 yılında insülin dozlarının hesaplanmasında yapay zeka uygulamasının kullanılmasına onay vermeden çok önce aslında T1DM'li pek çok hasta, teknolojinin hızına ayak uydurarak DKŞM verilerini kapalı ve açık ortamlarda paylaşarak pek çok yazılım geliştirmişlerdi. Ancak veri güvenliği kaygıları,

bu tür sistem ve ürünlerin yaygınlaşmasının önünde halen doğal bir engel teşkil etmektedir.

FDA'nın 2018'de onay verdiği diğer uygulama, Medtronic firması tarafından geliştirilen The Guardian Connect System uygulamasıdır.

Akıllı telefonlarla kullanılma kolaylığı sağlayan ve yarım saat ya da 1 saat içinde hipoglisemi gelişmesini öngörebilen sistem hastaya uyarı vermektedir. Uyarı alan hastanın hipoglisemiye karşı önlem alabilmesi için yeterli vakte sahip olması, hasta oldukça avantajlı olmaktadır.

Diyabetes mellitus dünya çapında prevalansı büyük bir hızla artan, kronik komplikasyonları nedeni ile hastalara ciddi komorbidite ve mortalite sunan sendromdur. IDF verilerine göre 2021 yılında dünya genelinde 537 milyon diyabetli erişkin mevcuttu; bu sayının artarak 2030 yılında 643 milyona, 2045 yılında ise 783 milyona ulaşacağı tahmin edilmektedir. T2DM'nin gelişmesinde oldukça etkili olan değiştirilebilir risk faktörleri mevcuttur. Obezite, sedanter hayat, yüksek kalorili batı tipinde beslenme alışkanlığı, sigara alışkanlığı diyabetin gelişmesinde etkili risk faktörleridir. Varsa genetik olarak diyabete yatkınlığımız, değiştiremeyeceğimiz risk faktörleridir. Büyük toplum çalışmalarında uygun hayat tarzı değişikliklerinin sağlanması ile diyabet gelişmesinin önlenebileceği ya da ertelenebileceği gösterilmiştir (10). Sağlıklı yaşam tarzı toplumda yaşayan tüm bireyler için elzemdir, ancak diyabet gelişme riski yüksek olan bireylerde gerekli önlemlerin alınması, önümüzdeki yıllarda bireylerin komorbiditelerini ve mortalitelerini azaltabilecek, sağlık harcamalarında ciddi tasarruf sağlayacaktır. "Hangi bireylerde diyabet gelişecektir?" sorusunun cevabının arandığı yapay zeka çalışmaları 1960 yılında başlamıştır. Takip eden yıllarda, konvansiyonel istatistiksel yöntemlerden biraz daha kesin diyabet gelişme riskini hesaplayan yapay zeka uygulama çalışmaları da yapılmıştır (11). Günümüze kadar çok sayıda değişik popülasyonlarda, hastanede yatan, ayaktan tedavisi yapılan hasta popülasyonlarında önümüzdeki yıllarda diyabetin gelişme riskini hesaplayan çok sayıda çalışma yapılmıştır (12-14).

Yukarıda özetlenmeye çalışılan konular dışında hastaların yaşam tarzı değişikliklerine olan uyumları ile ilgili, egzersiz öncesinde ve sonrasında yapmaları gereken insülin dozları, almaları gereken karbonhidrat miktarlarının hesaplanması, insülin pompası ile ilgili sorunların erkenden algılanmasını sağlayan algoritmalar üzerinde de çok sayıda çalışma mevcuttur (15).

Daha iyi çalışmaların yapılabilmesi için, yapay zeka uygulamalarına verilecek olan bilgilerin hasta dosyalarından aktarılabilmesi gerekmektedir. Bu konuda çalışan uzmanların, hastane dosyalarından bilgi çekmeye çalışırken zorlandıkları bazı noktalar olmaktadır:

- ICD kodlarının düzgün yazılmaması,
- Değişik dillerde tutulan hastane dosyalarından bilgi aktarma zorlukları,
- Hastalar hakkında tutulan notların karışık ve kısaltmalarla yazılmış olması vb.

Dolayısıyla, önümüzdeki yıllarda yapay zeka uygulamalarının daha yaygın kullanılabilmesi için hasta dosyalarını doldururken hekimler olarak sistemler tarafından devamlı uyarılacak olmamız da oldukça muhtemel bir gelişme olacaktır.

## Sonuç

Sonuç olarak, yapay zeka uygulamaları ilerleyen teknolojinin tıpta önemli bir izdüşümü haline gelmiştir. Yapay zeka uygulamaları ve tıpta kullanımlarındaki en temel sorunlarından birisi teknolojinin tasarlayıcısı olan yazılımcılar ile hekimlerin çok farklı eğitim süreçlerinden geçmiş olmalarından ötürü bakış açılarının ve jargonlarının çok farklı olmasıdır. Ortak bir dil oluşturulabilmesi için söz konusu bölümlerin lisans derslerinde en azından bilgilendirme amacı içeren derslerin konulması, bu sorunun giderilmesinde faydalı olabilir. Yapay zeka uygulamalarının, tıbbi uygulamaların temeli olan propedetik uygulamalarının yerine çok yakın bir gelecekte geçmesi de beklenmemelidir. Çok bilinmeyen olan sorunların çözümünde, iyi oluşturulmuş algoritmalar hekimlerin elini güçlendirecektir. Farklı branşlarda ve sağlık basamaklarında, hastalar farklı sebeplerle hekimlere başvurmuş olsalar bile önemli hastalıklar hakkında taranabilirler. Örneğin diz ağrısı nedeni ile ortopedide muayene olan, ancak diyabet gelişmesi açısından risk faktörlerine sahip olan hastalar hakkında sistem uyarı verdiğinde, hastalar risk faktörlerinin değerlendirilmesi ve uygun önlemlerin alınabilmesi için uygun kliniklere refere edilebilirler. T1DM tanısı olan hastaların, değişken hayat seyirlerinde uygun insülin dozlarının hesaplanabilmesi, gelişmesi muhtemel hipoglisemiler açısından hastaların uyarılması hastaların tedavi kalitesini artırdığı gibi, hayat kalitelerini de artırmaktadır.

Yukarıda da belirtildiği üzere, Gözetimsiz veya Denetimsiz Öğrenme uygulamalarında değişkenler arasındaki ilintinin rastlantısal mı, yoksa nedensellik (*causality*) yani sebep-sonuç ilişkisine dayalı olup olmadığının yorumlanması; Gözetimli veya Denetimli Öğrenme uygulamalarında, verinin doğru bir şekilde etiketlenmiş olması ve yapay zeka mimarisinin eldeki probleme uygun olacak şekilde oluşturulması; Pekiştirmeli Öğrenme uygulamalarında da eldeki problem uzayının doğru bir şekilde

tanımlanması/modellenmesi ve ödül-ceza mekanizmalarının doğru bir şekilde tanımlanması, hekimin sürece katılımını zorunlu kılmaktadır. Dolayısıyla yapay zekanın hekimin yerini tamamen alacak olması, ilgili problemlerin çözümünde başvurulan uzman hekimlere artık ihtiyaç kalmayacak olması gibi kaygılar abartılı olup hekimlerin bilgi ve deneyimleri, kendilerinin fiziksel olarak bulunmadıkları/bulunamadıkları ortamlara da yapay zeka sayesinde ulaştırılmış olacaktır.

## Kaynaklar

1. Zeevi D, Korem T, Zmora N, et al. Personalized Nutrition by Prediction of Glycemic Responses. *Cell*. 2015;163:1079-1094.
2. Yau JW, Rogers SL, Kawasaki R, et al. Global prevalence and major risk factors of diabetic retinopathy. *Diabetes Care*. 2012;35:556-564.
3. Leasher JL, Bourne RR, Flaxman SR, et al. Erratum. Global Estimates on the Number of People Blind or Visually Impaired by Diabetic Retinopathy: A Meta-analysis From 1990-2010. *Diabetes Care*. 2016;39:1643-1649.
4. Chang LY, Lee AC, Sue W. Prevalence of diabetic retinopathy at first presentation to the retinal screening service in the greater Wellington region of New Zealand 2006-2015, and implications for models of retinal screening. *N Z Med J*. 2017;130:78-88.
5. Sun H, Saeedi P, Karuranga S, et al. IDF Diabetes Atlas: Global, regional and country-level diabetes prevalence estimates for 2021 and projections for 2045. *Diabetes Res Clin Pract*. 2022;183:109119.
6. Abràmoff MD, Lavin PT, Birch M, Shah N, Folk JC. Pivotal trial of an autonomous AI-based diagnostic system for detection of diabetic retinopathy in primary care offices. *NPJ Digit Med*. 2018;1:39.
7. Nimri R, Battelino T, Laffel LM, et al. Insulin dose optimization using an automated artificial intelligence-based decision support system in youths with type 1 diabetes. *Nat Med*. 2020;26:1380-1384.
8. Phillip M, Battelino T, Atlas E, et al. Nocturnal glucose control with an artificial pancreas at a diabetes camp. *N Engl J Med*. 2013;368:824-833.
9. Tang F, Wang Y. Economic Model Predictive Control of Bihormonal Artificial Pancreas System Based on Switching Control and Dynamic R-parameter. *J Diabetes Sci Technol*. 2017;11:1112-1123.
10. Perreault L, Pan Q, Mather KJ, et al. Effect of regression from prediabetes to normal glucose regulation on long-term reduction in diabetes risk: results from the Diabetes Prevention Program Outcomes Study. *Lancet*. 2012;379:2243-2251.
11. Abbasi A, Peelen LM, Corpeleijn E, et al. Prediction models for risk of developing type 2 diabetes: systematic literature search and independent external validation study. *BMJ*. 2012;345:e5900.
12. Choi BG, Rha SW, Kim SW, et al. Machine Learning for the Prediction of New-Onset Diabetes Mellitus during 5-Year Follow-up in Non-Diabetic Patients with Cardiovascular Risks. *Yonsei Med J*. 2019;60:191-199.
13. Lai H, Huang H, Keshavjee K, et al. Predictive models for diabetes mellitus using machine learning techniques. *BMC Endocr Disord*. 2019;19:101.
14. Kopitar L, Kocbek P, Cilar L, et al. Early detection of type 2 diabetes mellitus using machine learning-based prediction models. *Sci Rep*. 2020;10:11981.
15. Contreras I, Vehi J. Artificial Intelligence for Diabetes Management and Decision Support: Literature Review. *J Med Internet Res*. 2018;20:e10775.