



19. BÖLÜM

KLİNİK LABORATUVARLARDA YAPAY ZEKA

Sevda Ünallı ÖZMEN¹

GİRİŞ

Önümüzdeki yıllarda Tıp reaktif olmaktan daha çok proaktif hale geçecek olup laboratuvar tıbbını temelden değiştirecek şekilde ortaya çıkan teknolojik gelişmelerden birisi yapay zekadır (1). Yapay zeka, klinik karar destekleri oluşturmak, gizli hastalık alt tiplerini, ilişkileri ve prognostik belirteçleri ortaya çıkarmak ve yeni test edilebilir hipotezler oluşturmak için otomasyondan gelen veri setlerinden yararlanacaktır. Bu gelişmeler, patolojiye ve laboratuvar tıbbına reaktif ilahtan proaktif ilaca geçişi sağlayacak araçları sağlayacaktır.

Yapay zekanın tıbbı uygulanması yeni değil aslında, bu çalışma alanı otuz yıldan daha eskilere dayanmaktadır (2). Bununla birlikte, yapay zekanın anlamlı uygulamaları klinik laboratuvarlarda henüz başlangıç aşamasında olup önümüzdeki dekatlarda temel, etkin bir teknoloji olmaya devam edecektir.

Orijinal yapay zeka fikri, ünlü İngiliz matematikçi Alan Turing'e atfedilir. 1950'deki "Taklit Oyunu" - bir insanla bir makine arasındaki bir aldatma oyunu - anlatırken şöyle düşünmüştü: "Eğer adam makine gibi davranmaya çalışsardı, açıkça çok zayıf bir gösteri olurdu." Makineler, insan gibi düşünüp ama bir insanın yaptığından çok farklı olan bir şeyi yapamaz mı? "(3). Aslında, sağlık hizmetlerinde yapay zekanın potansiyeli, bilgisayarların karmaşık, doğrusal olmayan ilişkileri ortaya çıkarması, daha iyi prognostik denklemler oluşturması ve büyük veri kümelerine yeni yaklaşımlar kullanarak görüntülerdeki alt görsel bilgileri ortaya çıkarmasıdır. Yapay zeka esasen iki alana ayrılır. Makine öğrenimi ve derin öğrenme. "Makine Öğrenimi", "Bilgisayarların insanlar gibi öğrenmesini ve hareket etmesini sağlama, gözlemlerle gerçek dünya etkileşimleri

¹ Uzm. Dr., Bursa Şehir Hastanesi, Tıbbi Biyokimya, ozmendr@hotmail.com

ları genellikle literatürden toplanır veya laboratuvar testi üretici önerilerinden uyarlanır.

SONUÇ

Yapay zeka modellerinin laboratuvar verilerine potansiyel uygulaması uygundur, ancak henüz tam olarak gerçekleştirilmemiştir. ML yöntemlerinin daha iyi bilinir hale geldikçe maliyetleri düşürmek, klinik karar vermeyi desteklemek ve sonuçları iyileştirmek için uygulanmasını beklemek makul olsa da, bu yöntemlerin laboratuvar tıbbında daha geniş bir şekilde benimsenmesi ve kullanılması önündeki ana engelleri ele almak için daha fazla araştırma yapılması gereklidir. En iyi ML uygulamalarının, laboratuvar tıbbına avantajlı bir şekilde aktarılıp aktarılamayacağını anlamak için daha fazla çalışmaya ihtiyaç vardır (44).

Sağlık alanında hastalıkların erken tanısında makine öğrenmesi yöntemlerinin kullanımı artmıştır. Farklı ağ mimarileri ve öğrenme algoritmaları ile büyük verinin analizinde başarılı olan bu yöntemler sağlık alanında da hem hastalıkların erken tanısında hem de hastalığın erken tedavisinde sağlık çalışanlarına yardımcı olacağı görülmektedir. Sağlık alanında bu yöntemlerin kullanılması ölümcül sonuçlara yol açan süreçlerin önceden tahmin edilmesinde ve hastalığın hangi evrede olduğunu belirlebilmesi için faydalı olacaktır.

Bugüne kadar yapay zekayla ilgili yapılan çalışmalar dikkatle incelendiğinde, gelecek yılların yapay zeka teknikleri kullanarak geliştirilecek teknolojilerle çığır açacak gelişmelere gebe olduğu söylenebilir. Yapılacak çalışmalar sonucu keşfedilecek olan yeni yazılım teknikleri sayesinde, uzman sistemler ve yapay zeka uygulamalarında büyük atılımlar yapılacaktır. Kısaca özetlemek gerekirse, yapay zeka uygulamaları bilimin her alanında kendine yer bulacak ve yakın gelecekte sosyal hayatın normlarının yeniden şekillenmesine sebep olabilecek gelişmeler yaşanacaktır.

KAYNAKLAR

1. Hood L, Friend SH. Predictive, personalized, preventive, participatory (P4) cancer medicine. *Nat Rev Clin Oncol*. 2011;8:184–187.
2. Peek N, Combi C, Marin R, et al. Thirty years of artificial intelligence in medicine (AIME) conferences: a review of research themes. *Artif Intell Med*. 2015;65: 61–73.
3. Turing AM. Computing machinery and intelligence. *Mind*. 1950; 59:433–460.
4. <https://www.techemergence.com/what-is-machinelearning/>. 2019.
5. Mohammed EA, Far BH, Naugler C. Applications of the MapReduce programming framework to clinical big data analysis: current landscape and future trends. *BioData Min*. 2014;7:22.

6. The Platform for Big Data and the Leading Solution for Apache Hadoop in the Enterprise - Cloudera. <https://www.cloudera.com/>. 2019.
7. DataStax. 2019. (<http://www.datastax.com/>)
8. MAPR. 2019. (<https://mapr.com/products/>)
9. Christopher Nauglera,b,c and Deirdre L. Church. Automation and artificial intelligence in the clinical laboratory. *CRITICAL REVIEWS IN CLINICAL LABORATORY SCIENCES* 2019, VOL. 56, NO. 2, 98–110.
10. Dolley S. Big data's role in precision public health. *Front Public Health*. 2018;6:68.
11. Kleiman RS, LaRose ER, Badger JC, et al. Using machine learning algorithms to predict risk for development of calciphylaxis in patients with chronic kidney disease. *AMIA Summits Transl Sci Proc*. 2018; 2017:139–146.
12. Croxatto A, Marcelpoil R, Orny C, et al. Towards automated detection, semi-quantification and identification of microbial growth in clinical bacteriology: a proof of concept. *Biomed J*. 2017;40:317–328.
13. Belle A, Thiagarajan R, Soroushmehr SMR, et al. Big data analytics in healthcare. *Biomed Res Int*. 2015; 2015:1. DOI:10.1155/2015/370194
14. Goldstein BA, Navar AM, Carter RE. Moving beyond regression techniques in cardiovascular risk prediction: applying machine learning to address analytic challenges. *Eur Heart J*. 2017;38:1805–1814.
15. Ghaibeh AA, Kasem A, Ng XJ, et al. Gaining insights on nasopharyngeal carcinoma treatment outcome using clinical data mining techniques. *Stud Health Technol Inform*. 2018;247:386–390.
16. Camaggi CM, Zavatto E, Gramantieri L, et al. Serum albumin-bound proteomic signature for early detection and staging of hepatocarcinoma: sample variability and data classification. *Clin Chem Lab Med*. 2010;48:1319–26.
17. Madabhushi A, Doyle S, Lee G, et al. Integrated diagnostics: a conceptual framework with examples. *Clin Chem Lab Med*. 2010;48:989–98.
18. Horowitz GL. The power of asterisks. *Clin Chem*. 2015;61: 1009–11.
19. Connelly DP. Embedding expert systems in laboratory information systems. *Am J Clin Pathol*. 1990;94(4 Suppl 1):S7–14.
20. Lippi G, Bassi A, Bovo C. The future of laboratory medicine in the era of precision medicine. *J Lab Precis Med*. 2016;1:7.
21. Komatireddy R, Topol EJ. Medicine unplugged: the future of laboratory medicine. *Clin Chem*. 2012;58:1644–7.
22. Eysenbach G. Medicine 2.0: social networking, collaboration, participation, apomediation, and openness. *J Med Internet Res*. 2008;10:e22.
23. Poole S, Schroeder LF, Shah N. An unsupervised learning method to identify reference intervals from a clinical database. *J Biomed Inform*. 2016;59:276–84.
24. Lindbury BA, Richardson AM, Badrick T. Assessment of machinelearning techniques on large pathology sets to address assay redundancy in routine liver function test profiles. *Diagnosis*. 2015;2:41–51.
25. Jha AK, Chan DC, Ridgway AB, et al. Improving safety and eliminating redundant tests: cutting costs in U.S. hospitals. *Health Aff*. 2009;28:1475–84.
26. Diri B, Albayrak S. Visualization and analysis of classifiers performance in multi-class medical data. *Expert Syst Appl*. 2008;34:628–34.
27. Nelson DW, Rudehill A, MacCallum RM, et al. Multivariate outcome prediction in traumatic brain injury with focus on laboratory values. *J Neurotrauma*. 2012;29:2613–24.
28. Lin C, Karlson EW, Canhao H, et al. Automatic prediction of rheumatoid arthritis disease activity from the electronic medical records. *PLoS One*. 2013;8:e69932.
29. Liu KE, Lo CL, Hu YH. Improvement of adequate use of warfarin for the elderly using decision tree-based approaches. *Methods Inf Med*. 2014;53:47–53.

30. Razavian N, Blecker S, Schmidt AM, et al. Population-level prediction of type 2 diabetes from claims data and analysis of risk factors. *Big Data*. 2015;3:277–87 33.
31. Putin E, Mamoshina P, Aliper A, et al. Deep biomarkers of human aging: application of deep neural networks to biomarker development. *Aging*. 2016;8:1021.
32. Demirci F, Akan P, Kume T, et al. Artificial neural network approach in laboratory test reporting. *Am J Clin Pathol*. 2016;146:227–37.
33. Yuan C, Ming C, Chengjin H. UrineCART, a machine learning method for establishment of review rules based on UF-1000i flow cytometry and dipstick or reflectance photometer. *Clin Chem Lab Med*. 2012;50:2155–61.
34. Goldstein BA, Navar AM, Carter RE. Moving beyond regression techniques in cardiovascular risk prediction: applying machine learning to address analytic challenges. *Eur Heart J*. 2017;38:1805–14.
35. Capobianco E. Systems and precision medicine approaches to diabetes heterogeneity: a Big Data perspective. *Clin Transl Med*. 2017;6:23.
36. Anderson JP, Parikh JR, Shenfeld DK, et al. Reverse engineering and evaluation of prediction models for progression to type 2 diabetes: an application of machine learning using electronic health records. *J Diabetes Sci Technol*. 2016; 10:6–18.
37. Anand RS, Stey P, Jain S, et al. Predicting mortality in diabetic ICU patients using machine learning and severity indices. *AMIA Jt Summits Transl Sci Proc*. 2018;2017:310–319.
38. Dagliati A, Marini S, Sacchi L, et al. Machine learning methods to predict diabetes complications. *J Diabetes Sci Technol*. 2018;12:295–302.
39. Kasthurirathne SN, Dixon BE, Grannis SJ. Evaluating methods for identifying cancer in free-text pathology reports using various machine learning and data preprocessing approaches. *Stud Health Technol Inform*. 2015;216:1070.
40. Chen J, Tang H, Lv L, et al. Development and validation of new glomerular filtration rate predicting models for Chinese patients with type 2 diabetes. *J Transl Med*. 2015;13:300–17
41. Surinova S, Choi M, Tao S, et al. Prediction of colorectal cancer diagnosis based on circulating plasma proteins. *EMBO Mol Med*. 2015;7:1166–78.
42. Wang HY, Hsieh CH, Wen CN, et al. Cancers screening in an asymptomatic population by using multiple tumour markers. *PLoS One*. 2016;11:e0158285.
43. Richardson A, Signor BM, Lidbury BA, et al. Clinical chemistry in higher dimensions: machine-learning and enhanced prediction from routine clinical chemistry data. *Clin Biochem*. 2016;49:1213–20.
44. Luo Y, Szolovits P, Dighe AS, et al. Using machine learning to predict laboratory test results. *Am J Clin Pathol*. 2016;145:778–88.
45. Somnay YR, Craven M, McCoy KL, et al. Improving diagnostic recognition of primary hyperparathyroidism with machine learning. *Surgery*. 2017;161:1113–21.
46. Tomasev N, Glorot X, Rae JW, et al. A clinically applicable approach to continuous prediction of future acute kidney injury. *Nature*. 2019;572(7767):116–119.
47. Henny J, Vassault A, Boursier G, et al. Recommendation for the review of biological reference intervals in medical laboratories. *Clin Chem Lab Med*. 2016;54:1893–900.
48. Cabitza F, Rasoini R, Gensini GF. Unintended consequences of machine learning in medicine. *J Am Med Assoc* 2017;318:517–8.