



ÜROLOJİDE YAPAY ZEKANIN YERİ VE ÖNEMİ

Mevlüt KELEŞ¹

Yapay zeka (YZ); insan gibi davranışlar sergileme, sayısal mantık yürütme, hareket, konuşma ve ses algılama gibi birçok yeteneğe sahip yazılımsal ve do-nanımsal sistemler bütünüdür. Başka bir deyişle yapay zeka; bilgisayarların insanlar gibi düşünmesini sağlar. Yapay zekayı tek başlık altında ele almak yanlış olur. Makine öğrenimi (MÖ), Derin öğrenme (DÖ) gibi kavramlar yapay zekayı oluşturan kapsayıcı terimlerdir. Makine öğrenimi, yazılım programlarının açık bir şekilde programlanmadan sonuçları tahmin etmede daha doğru olmasını sağlayan bir algoritma kategorisidir. Makine öğrenmesinin temel dayanağı, giriş verisini alabilen algoritmalar oluşturmak ve çıktıları yeni veriler ortaya çıktıktan sonra güncellerken bir çıktıyı tahmin etmek için istatistiksel analiz kullanmaktadır. Derin öğrenme ise, yapay sinir ağlarının ve insan beyninden ilham alan algoritmaların veriden öğrendiği bir makine öğreniminin alt kümesidir. İnsanların tecrübe-rinden öğrendiklerine benzer olarak, derin öğrenme algoritması, sonucu iyileş-tirmek adına her defasında biraz değişiklik yaparak daha iyi bir iş çıkarmaktadır. Derin öğrenme, düşünce gerektiren herhangi bir problem hakkındaki çözümü gerçekleştirebilir.

Yapay zeka tıp alanında geniş bir kullanım alanına sahiptir. Yapay zekanın tıp alanındaki kullanımının yaygınlığı ve önemini 16-18 Ocak 2020 ta-rilerinde ülkemizde düzenlenen Uluslararası Sağlıkta Yapay Zeka Kongresi ile de yakinen idrak etmiş bulunuyoruz. Günümüzde hemen tüm tıp birimleri gibi ürolojide de yapay zekanın kullanımı kaçınılmazdır. Gerek ürolojik tanışal de-ğerlendirmelerde, gerek ürolojik görüntülemelerin üç boyutlu modellemelere çevrilmesinde, gerek ürolojik cerrahının çeşitli aşamalarında (özellikler robotik cerrahilerde), gerek ürolojik cerrahilerin öğrenilmesinde kullanılan simülasyon modellerinde yapay zeka kullanımının son derece yaygın olduğunu görmekteyiz.

¹ Op. Dr. Sungurlu Devlet Hastanesi Üroloji, drmevlutkeles@gmail.com

Mentor-stajyer güveni, mentorun stajyerin performans kalitesini değerlendirmesi ve stajyerin ameliyatı devam ettirme yeteneğini onaylaması olarak tanımlanır. Cerrahi performasın değerlendirilmesinde diğer bir yol da mentor-stajyer güvenidir. Bu temelde yapılan bir çalışmada, araştırmacılar robot destekli cerrahi sırasında mentor-stajyer güvenini cerrahi stajyerler tarafından gerçekleştirilen prosedürleri gözlemlerken cerrahi mentorun elektroensefalogram kalıplarını kullanarak değerlendirdiler. Yazarlar performans güvenilirliğini ayırt etmede elektroensefalografisinin temel özelliklerini tanımlamak için MÖ'yi kullandılar.

Özetle, ürolojide yapay zeka kullanımı halihazırda kendine geniş bir alan edinmiş olup yıllar içinde bu alanın çok daha genişleyeceği de son derece öngörlülebilir bir durumdur. YZ kullanımını ile ıgili belki de en çarpıcı konulardan birisi biz hekimleri (özellikle cerrahları) yeterlili standardizasyonu açısından çok daha optimum değerlendirmelere tabi tutacak sistemlerin geliştirilebilecek olmasıdır. Bunun yanısıra YZ uygulamalarının artmasının hasta hekim ilişkisine ve tıp etidine etkileri de ayrı birer tartışma ve araştırma konusu olacaktır.

KAYNAKLAR

1. Beam AL, Kohane IS. Big data and machine learning in health care. *JAMA* 2018; 319: 1317–8
2. Kanagasingam Y, Xiao D, Vignarajan J et al. Evaluation of artificial intelligence-based grading of diabetic retinopathy in primary care. *JAMA Netw Open* 2018; 1: e182665
3. Drouin SJ, Yates DR, Hupertan V, Cussenot O, Roupr^et M. A systematic review of the tools available for predicting survival and managing patients with urothelial carcinomas of the bladder and of the upper tract in a curative setting. *World J Urol* 2013; 31: 109–16
4. Hung AJ, Chen J, Gill IS. Automated performance metrics and machine learning algorithms to measure surgeon performance and anticipate clinical outcomes in robotic surgery. *JAMA Surg* 2018; 153: 770–1
5. Kim JK, Yook IH, Choi MJ et al. A performance comparison on the machine learning classifiers in predictive pathology staging of prostate cancer. *Stud Health Technol Inform* 2017; 245: 1273
6. Algohary A, Viswanath S, Shiradkar R et al. Radiomic features on MRI enable risk categorization of prostate cancer patients on active surveillance: preliminary findings. *J Magn Reson Imaging* 2018; 48: 818–28
7. Ginsburg SB, Algohary A, Pahwa S et al. Radiomic features for prostate cancer detection on MRI differ between the transition and peripheral zones: preliminary findings from a multi-institutional study. *J Magn Reson Imaging* 2017; 46: 184–93
8. Merisaari H, Movahedi P, Perez IM et al. Fitting methods for intravoxel incoherent motion imaging of prostate cancer on region of interest level : repeatability and Gleason score prediction. *Magn Reson Med* 2017; 77:1249–64
9. Fehr D, Veeraghavan H, Wibmer A et al. Automatic classification of prostate cancer Gleason scores from multiparametric magnetic resonance images. *Proc Natl Acad Sci USA* 2015; 17: E6265–73
10. Kwak JT, Hewitt SM. Multiview boosting digital pathology analysis of prostate cancer. *Comput Methods Programs Biomed* 2017; 142: 91–9

11. Kwak JT, Hewitt SM. Nuclear architecture analysis of prostate cancer via convolutional neural networks. *IEEE Access* 2017; 5: 18526–33
12. Nguyen TH, Sridharan S, Macias V et al. Automatic Gleason grading of prostate cancer using quantitative phase imaging and machine learning. *J Biomed Opt* 2017; 22: 36015
13. Xu X, Zhang X, Tian Q et al. Three-dimensional texture features from intensity and high-order derivative maps for the discrimination between bladder tumours and wall tissues via MRI. *Int J Comput Assist Radiol Surg* 2017; 12: 645–56
14. Garapati SS, Hadjiiski L, Cha KH et al. Urinary bladder cancer staging in CT urography using machine learning. *Med Phys* 2017; 44: 5814–23
15. Shao CH, Chen CL, Lin JY et al. Metabolite marker discovery for the detection of bladder cancer by comparative metabolomics. *Oncotarget* 2017; 8: 38802–10
16. Zheng H, Ji J, Zhao L et al. Prediction and diagnosis of renal cell carcinoma using nuclear magnetic resonance-based serum metabolomics and self-organizing maps. *Oncotarget* 2016; 7: 59189–98
17. Haifler M, Pence I, Sun Y et al. Discrimination of malignant and normal kidney tissue with short wave infrared dispersive Raman spectroscopy. *J Biophotonics* 2018; 11: e201700188
18. Blum ES, Porras AR, Biggs E et al. Early detection of ureteropelvic junction obstruction using signal analysis and machine learning: a dynamic solution to a dynamic problem. *J Urol* 2018; 199: 847–52
19. Cerrolaza JJ, Peters CA, Martin AD, Myers E, Safdar N, Linguraru MG. Quantitative ultrasound for measuring obstructive severity in children with hydronephrosis. *J Urol* 2016; 195: 1093–9
20. Logvinenko T, Chow JS, Nelson CP. Predictive value of specific ultrasound findings when used as a screening test for abnormalities on VCUG. *J Pediatr Urol* 2015; 11: 176.e1–7
21. Cosma G, Brown D, Archer M, Khan M, Pockley AG. A survey on computational intelligence approaches for predictive modeling in prostate cancer. *Expert Syst Appl* 2017; 70: 1–19
22. Wong NC, Lam C, Patterson L, Shayegan B. Use of machine learning to predict early biochemical recurrence after robot-assisted prostatectomy. *BJU Int* 2019; 123: 51–7
23. Harder N, Athelogou M, Hessel H et al. Tissue phenomics for prognostic biomarker discovery in low- and intermediate-risk prostate cancer. *Sci Rep* 2018; 8: 4470
24. Zhang YD, Wang J, Wu CJ et al. An imaging-based approach predicts clinical outcomes in prostate cancer through a novel support vector machine classification. *Oncotarget* 2016; 7: 78140–51
25. Shiradkar R, Ghose S, Jambor I et al. Radiomic features from retreatment biparametric MRI predict prostate cancer biochemical recurrence: Preliminary findings. *J Magn Reson Imaging* 2018; 48: 1626–36
26. Zhang S, Xu Y, Hui X et al. Improvement in prediction of prostate cancer prognosis with somatic mutational signatures. *J Cancer* 2017; 8:3261–7
27. Lalonde E, Ishkanian AS, Sykes J et al. Tumour genomic and microenvironmental heterogeneity for integrated prediction of 5-year biochemical recurrence of prostate cancer: a retrospective cohort study. *Lancet Oncol* 2014; 15: 1521–32
28. Hung AJ, Chen J, Che Z et al. Utilizing machine learning and automated performance metrics to evaluate robot-assisted radical prostatectomy performance and predict outcomes. *J Endourol* 2018; 32: 438–44
29. Hung AJ, Chen J, Ghodoussipour S et al. A deep-learning model using automated performance metrics and clinical features to predict urinary continence recovery after robot-assisted radical prostatectomy. *BJU Int* 2019 <https://doi.org/10.1111/bju.14735> (Epub ahead of print)
30. Lam KM, He XJ, Choi KS. Using artificial neural network to predict mortality of radical cystectomy for bladder cancer. 2014 International Conference on Smart Computing (SMART-COMP), Hong Kong, 2014:201–7

31. Wang G, Lam KM, Deng Z, Choi KS. Prediction of mortality after radical cystectomy for bladder cancer by machine learning techniques. *Comput Biol Med* 2015; 63: 124–32
32. Sapre N, Macintyre G, Clarkson M et al. A urinary microRNA signature can predict the presence of bladder urothelial carcinoma in patients undergoing surveillance. *Br J Cancer* 2016; 114: 454–62
33. Bartsch Jr G, Mitra AP, Mitra SA et al. Use of artificial intelligence and machine learning algorithms with gene expression profiling to predict recurrent nonmuscle invasive urothelial carcinoma of the bladder. *J Urol* 2016; 195: 493–8
34. Aminsharifi A, Irani D, Pooyesh S et al. Artificial neural network system to predict the postoperative outcome of percutaneous nephrolithotomy. *J Endourol* 2017; 31: 461–7
35. Mannil M, von Spiczak J, Hermanns T, Poyet C, Alkadhi H, Fankhauser CD. Three-dimensional texture analysis with machine learning provides incremental predictive information for successful shock wave lithotripsy in patients with kidney stones. *J Urol* 2018; 200: 829–36 10 © 2019 The Authors *BJU International* © 2019 *BJU International Review*
36. Mannil M, von Spiczak J, Hermanns T, Alkadhi H, Fankhauser CD. Prediction of successful shock wave lithotripsy with CT:a phantom study using texture analysis. *Abdom Radiol (NY)* 2018; 43:1432–8
37. Nouranian S, Ramezani M, Spadiner I, Morris WJ, Salcudean SE, Abolmaesumi P. Learning-based multi-label segmentation of transrectal ultrasound images for prostate brachytherapy. *IEEE Trans Med Imaging* 2016; 35: 921–32
38. Nicolae A, Morton G, Chung H et al. Evaluation of a machine-learning algorithm for treatment planning in prostate low-dose-rate brachytherapy. *Int J Radiat Oncol Biol Phys* 2017; 97: 822–9
39. Guidi G, Maffei N, Vecchi C et al. Expert system classifier for adaptive radiation therapy in prostate cancer. *Australas Phys Eng Sci Med* 2017;40: 337–48
40. Saeed K, Rahkama V, Eldfors S et al. Comprehensive drug testing of patient-derived conditionally reprogrammed cells from castration-resistant prostate cancer. *Eur Urol* 2017; 71: 319–27
41. Nosrati MS, Amir-Khalili A, Peyrat JM et al. Endoscopic scene labelling and augmentation using intraoperative pulsatile motion and colour appearance cues with preoperative anatomical priors. *Int J Comput Assist Radiol Surg* 2016; 11: 1409–18
42. Baghdadi A, Cavuoto L, Hussein AA, Ahmed Y, Guru KA. Modeling automated assessment of surgical performance utilizing computer vision:proof of concept. *J Urol* 2018; 199: e1134–5
43. Ghani KR, Liu Y, Law H et al. Video analysis of skill and technique (Vast): machine learning to assess surgeons performing robotic prostatectomy. *J Urol* 2017; 197: e891
44. French A, Lendvay TS, Sweet RM, Kowalewski TM. Predicting surgical skill from the first N seconds of a task: value over task time using the isogony principle. *Int J Comput Assist Radiol Surg* 2017; 12:1161–70
45. Shafiei SB, Hussein AA, Muldoon SF, Guru KA. Functional brain states measure mentor-trainee trust during robot-assisted surgery. *Sci Rep* 2018;8: 3667
46. Pedersen AB, Mikkelsen EM, Cronin-Fenton D et al. Missing data and multiple imputation in clinical epidemiological research. *Clin Epidemiol* 2017; 9: 157–66
47. Kattan MW. Comparison of Cox regression with other methods for determining prediction models and nomograms. *J Urol* 2003; 170: S6–9
48. ung AJ. Can machine-learning algorithms replace conventional statistics? *BJU Int* 2019; 123: 1
49. Ribeiro MT, Singh S, Guestrin C. Why should I trust you? Explaining the prediction of any classifier. In: Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and data Mining: ACM;2016: 1135–44
50. Graham J. Artificial Intelligence, Machine Learning, and the FDA. 2016. Available at: <https://www.forbes.com/sites/theapotheccary/2016/08/19/artificial-intelligence-machine-learning-and-the-fda/#4aca26121aa1>. Accessed June 2017