

NÜKLEER TIPTA YAPAY ZEKÂ UYGULAMALARI

Ahmet SALAN¹

Canlıların akılcı davranışlarını yapay olarak taklit ederek problem çözmeye yönelik oluşturulan sistemlere yapay zekâ sistemleri denmektedir. Bu sistemlerin, tahmin, sınıflandırma, kümeleme, tanımlama gibi birçok uygulama alanları mevcuttur. Yapay zekâ sistemlerinin alt yapısında genetik algoritmalar, optimizasyon yöntemleri, bulanık mantık, yapay sinir ağı, makine öğrenmesi, derin öğrenme, eğitmenli öğrenme ve eğitmensiz öğrenme gibi teknikler kullanılmaktadır. Makine öğrenmenin en yaygın şekli ister derin olsun ister derin olmasın eğitmenli öğrenmedir. Eğitmenli öğrenmede ki eğitim gerçek değerler ile tahmin edilen değerler arasında ki hatanın en düşük düzeye getirilmesine yönelik şekilde model değişkenlerinin ayarlanması olarak tanımlanabilir. Hatta bu ayarlama bazen yazılım içinde güncellenebilme özelliğine de sahiptir. Bunların dışında karınca kolonisi, parçacık sürü ve yapay arı gibi algoritmalar da doğayı taklit ederek geliştirilen yapay optimizasyon teknikleri olarak kullanılan akıllı yöntemlerdendir. Bu yöntemlerin uygulanması ile bilgisayar yazılımı verilerden yola çıkarak sanki bir insanmış gibi düşünme, öğrenme, tepki ve karar verme sonucuna ulaşabilmektedir.

Yapay zekâyâ olan ilginin hızı yirminci yüzyılın ikinci yarısıyla giderek artmıştır. Ancak bu gelişimi ve genişlemeyi yavaşlatan bazı engeller vardır. Bu bağlamda yapay zekânın uygulama alanının genişlemesini engelleyen önemli bir etken güçlü bir bilgisayar teknolojisinin olmamasıdır. Bu engelin aşılabilmesi ancak bilgisayarlı görü, örüntü tanıma ve mikro elektronikte ki gelişmelerin sonucu ile mümkün olmuştur. Diğer önemli bir engel de geçmişte elimizde yeterli verinin bulunmamasıdır. Bu engelin aşılabilmesi de öğrenme algoritmalarında ki iyileşmeler ile “big data” veya “büyük veri” adı verilen gerçek hasta görüntüleri ve kayıtlarının çok yüksek bir dijital arşiv hacmine ulaşması sonucu sağlanabil-

¹ Dr. Öğretim Üyesi, Kahramanmaraş Sütçü İmam Üniversitesi, Tıp Fakültesi Nükleer Tıp AD

çıkarak gelecekte en hızlı şekilde Nükleer Tıp ve moleküler görüntüleme verilerinden oluşan büyük bir veri tabanı oluşturulması kişiselleştirilmiş tıp açısından son derece önemli bir gereksinimdir. Nükleer tıp uzmanlarının multidisipliner olarak daha fazla bilgi ile donanmaları ve klinik tablodan hareketle yapay zekâ yazılımlarının da yardımı ile moleküler görüntülemeyi hasta bazında en yüksek doğrulukla yorumlama yeteneğini kazanmaları da önemlidir. Nükleer Tıp uzmanları görüntülerden yorum yapabilmek için mümkün olan en yüksek düzeyde biyolojik verileri elde edebilmelidir. Artık geri dönüşümsüz biçimde yol aldığımız bu konuda yalnızca ulusal Nükleer Tıp derneklerinin değil, geniş bir iş birliği ile tüm dünyada söz sahibi olan Nükleer Tıp derneklerinin ortak bir anlayış geliştirerek çalışma grupları ve yeni yönergeler oluşturarak söz konusu sorunlar ve gelecekte olası sorunların çözülmesi için üst düzey bir çaba sarf etmeleri bir zorunluluk olarak önümüzde durmaktadır.

KAYNAKLAR

1. Aktolun C. Artificial intelligence and radiomics in nuclear medicine: potentials and challenges. 2019 Eur J Nucl Med Mol Imaging <https://doi.org/10.1007/s00259-019-04593-0>
2. Atalay M, Çelik E. Büyük Veri Analizinde Yapay Zekâ Ve Makine Öğrenmesi Uygulamaları. DOI: 10.20875/makusobed.2017;(22):155-177
3. Avendi M, Kheradvar A, Jafarkhani H. A combined deep-learning and deformable-model approach to fully automatic segmentation of the left ventricle in cardiac MRI. Med Image Anal. 2016;(30):108–19.
4. Charbonnier J-P, Van Rikxoort EM, Setio AA, Schaefer-Prokop CM, van Ginneken B, Ciompi F. Improving air way segmentation in computed tomography using leak detection with convolutional networks. Med Image Anal. 2017;(36):52–60.
5. Chaudhary K, Poirion OB, Lu L, Garmire L. Deep Learning based multi-omics integration robustly predicts survival in liver cancer. Clin Cancer Res. 2017. <https://doi.org/10.1158/1078-0432.CCR-17-0853>.
6. Chen H, Dou Q, Yu L, Heng P-A. Voxresnet: Deep voxelwise residual networks for volumetric brain segmentation. NeuroImage 2018; (170): 446–455
7. Choi H. Deep Learning in Nuclear Medicine and Molecular Imaging: Current Perspectives and Future Directions. Nucl Med Mol Imaging 2018 (52):109–118
8. Choi H, Ha S, Im HJ, Paek SH, Lee DS. Refining diagnosis of Parkinson's disease with deep learning-based interpretation of dopamine transporter imaging. Neuroimage Clin. 2017 (16) 586–594
9. Choi H, Jin KH. Fast and robust segmentation of the striatum using deep convolutional neural networks. J Neurosci Methods. 2016;(274):146–53.
10. Choi H, Jin KH. Predicting cognitive decline with deep learning of brain metabolism and amyloid imaging. Behavioural Brain Research. 2018; (344):103-109
11. Choi H, Na KJ. A risk stratification model for lung cancer based on gene coexpression network. bioRxiv. 2017. <https://doi.org/10.1101/179770>.
12. Collins FS, Varmus H. A new initiative on precision medicine. N Engl J Med. 2015;(372):793–5.

13. De Brebisson A, Montana G, editors. Deep neural networks for anatomical brain segmentation. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition Workshops; 2015.
14. Ghafoorian M, Karssemeijer N, Heskes T, vanUden IW, Sanchez CI, Litjens G, et al. Location sensitive deep convolutional neural networks for segmentation of white matter hyperintensities. *Sci Rep.* 2017;7. <https://doi.org/10.1038/s41598-017-05300-5>.
15. Gillies RJ., Kinahan PE., Hricak H Radiomics: Images Are More than Pictures, They Are Data *Radiology:* 2016; (278); 563-77 radiology.rsna.org
16. Han D, Yu J, Yu Y, Zhang G, Zhong X, Lu J, et al. Comparison of 18 F-fluorothymidine and 18 F-fluorodeoxyglucose PET/CT in delineating gross tumor volume by optimal threshold in patients with squamous cell carcinoma of thoracic esophagus. *Int J Radiat Oncol Biol Phys.* 2010;(76):1235–41.
17. Han X. MR-based synthetic CT generation using a deep convolutional neural network method. *Med Phys.* 2017;(44):1408–19.
18. Jiao J, Ourselin S. Fast. PET reconstruction using Multi-scale Fully Convolutional Neural Networks. *arXiv:170407244.* 2017.
19. Jin KH, McCann MT, Froustey E, Unser M. Deep convolutional neural network for inverse problems in imaging. *IEEE Trans Image Process.* 2017;26:4509–22.
20. Kim J, Kwon Lee J, Mu Lee K, editors. Accurate image superresolution using very deep convolutional networks. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition; 2016.
21. Kleesiek J, Urban G, Hubert A, Schwarz D, Maier-Hein K, Bendszus M, et al. Deep MRI brain extraction: a 3D convolutional neural network for skull stripping. *NeuroImage.* 2016;(129):460–9.
22. Lam A, Bui K, Rangel EH, Nguentat M, Fernando D, Nelson K, Abi-Jaoudeh N, Radiogenomics and IR. *J Vasc Interv Radiol* 2018;(29):706–713 <https://doi.org/10.1016/j.jvir.2017.11.021>
23. Le Cun Y, Bengio Y, Hinton G. Deep learning. *Nature.* 2015;(521): 436–44.
24. Mamoshina P, Vieira A, Putin E, Zhavoronkov A. Applications of deep learning in biomedicine. *Mol Pharm.* 2016;(13):1445–54.
25. Nie D, Trullo R, Petitjean C, Ruan S, Shen D. Medical Image Synthesis with Context-Aware Generative Adversarial Networks. *Med Image Comput Comput Assist Interv.* 2017. 417–425
26. Oke JL., Pickup LC., Declerck J., Callister ME, Baldwin D, , et al . Development and validation of clinical prediction models to risk stratify patients presenting with small pulmonary nodules: a research protocol Diagnostic and Prognostic Research (2018) 2:22 <https://doi.org/10.1186/s41512-018-0044-3>
27. Pereira S, Pinto A, Alves V, Silva CA. Brain tumor segmentation using convolutional neural networks in MRI images. *IEEE Trans Med Imaging.* 2016;(35):1240–51.
28. Suk H-I, Lee S-W, Shen D. Initiative As DN. Latent feature representation with stacked auto-encoder for AD/MCI diagnosis. *Brain Struct Funct.* 2015;(220):841–59.
29. Trebeschi S, van Griethuysen JJ, Lambregts DM, Lahaye MJ, Parmer C, Bakers FC, et al. Deep learning for fully-automated localization and segmentation of rectal cancer on multiparametric MR. *Sci Rep.* 2017;7
30. Tyłski P, Stute S, Grotus N, Doyeux K, Hapdey S, Gardin I, et al. Comparative assessment of methods for estimating tumor volume and standardized uptake value in 18F-FDG PET. *J Nucl Med.* 2010;(51):268–76.
31. Van De Vijver MJ, He YD, Van't Veer LJ, Dai H, Hart AA, Voskuil DW, et al. A gene-expression signature as a predictor of survival in breast cancer. *N Engl J Med.* 2002;(347):1999–2009.
32. Wang H, Zhou Z, Li Y, Chen Z, Lu P, Wang W, et al. Comparison of machine learning methods for classifying mediastinal lymph node metastasis of non-small cell lung cancer from 18 F-FDG PET/CT images. *EJNMMI Res.* 2017;7:11.

33. Xiang L, Qiao Y, Nie D, An L, Wang Q, Shen D. Deep auto-context convolutional neural networks for standard-dose PET image estimation from low-dose PET/MRI. *Neurocomputing*. 2017;(267):406-416
34. Zhang W, Li R, Deng H, Wang L, Lin W, Ji S, et al. Deep convolutional neural networks for multi-modality isointense infant brain image segmentation. *Neuro Image*. 2015;(108):214-24.