

MEDİKAL GÖRÜNTÜ İŞLEMEDE DERİN ÖĞRENME YÖNTEMLERİ VE KONVOLÜSYONEL SİNİR AĞLARI

Adem DOĞANER¹

Teknolojinin hızlı bir gelişme göstermesi sağlık alanında birçok konvansiyonel yöntemin dijital dönüşüme uğramasına öncülük etmiştir. Yaşanan bu hızlı dönüşüm, sağlık hizmetlerinde pek çok kazanımı beraberinde getirmiştir. Sağlık hizmetlerinde genellikle dijital dönüşüm denildiğinde, hastane içerisindeki otomasyon sistemleri, teletıp veya evde sağlık hizmetleri alanında yaşanan teknolojik gelişmeler düşünülmektedir. Teknolojinin gelişimi ile koruyucu hekimliğin yanı sıra, tedavi edici hekimlikte, özellikle tanı işlemlerinde uygulanan birçok konvansiyonel yöntem, yerini dijital yöntemlere bırakmaktadır. Hastalık tanılarda dijital dönüşümün gelişimi, son yıllarda adını sıkça söz ettiren yapay zeka ve derin öğrenme yöntemlerine bağlı olarak gerçekleşmiştir. Yapay zeka ve derin öğrenme, son on yılda hızlı bir gelişme göstererek tüm bilim alanlarında aktif şekilde kullanılabilir hale ulaşmıştır. Yapay zeka, çok büyük veri kitlelerinde, veriler içerisindeki örüntüyü öğrenerek veya işlem aşamalarını yineleyerek kendini geliştiren, insanın biyolojik öğrenme mekanizmasını taklit eden yöntemlerden oluşmaktadır. Bugün birçok çalışma alanında yapay zeka uygulamaları, çalışanların işlerini kolaylaştırmaktadır. Savunma sanayinde, sağlık sektöründe, finansal iş kurumlarında, endüstriyel şirketlerde ve birçok benzer iş sahasında yapay zeka yöntemleri güçlü bir şekilde uygulanmaktadır. Klinik karar destek sistemlerinin temelinde yer alan derin öğrenme yöntemleri, tanı ve tedavi aşamasında birçok uygulamanın içerisinde kullanılmaktadır.

Medikal görüntüleme yöntemleri, hastanın klinik bulgularının ortaya konulmasındaki en önemli araçlardan biridir. Lezyonların belirlenmesinde, tanıya karar verilmesinde ve tedavi prosedürünün belirlenmesinde medikal görüntüleme yöntemleri hekime bilgi sağlamaktadır. Hastaya uygulanacak tedavi prosedürünün başarısı, doğru tanı ile koreledir. Doğru tanıya karar verilebilmesinde

¹ Dr. Öğretim Üyesi, Kahramanmaraş Sütçü İmam Üniversitesi, Tıp Fakültesi Biyoistatistik ve Tıbbi Bilişim AD

Konvolüsyonel sinir ağları medikal alanda, özellikle görüntü işleme ve hastalık tahminlerinde başarılı bir şekilde uygulanmaktadır. Yöntem, medikal görüntülerin analizinde yüksek performans sağlamaktadır³⁷. Benzer şekilde hastalıkların erken teşhisi, bilişsel fonksiyonlar ve fonksiyonel bozuklukların belirlenmesinde konvolüsyonel sinir ağları sıklıkla tercih edilen bir yöntem olmuştur³⁸⁻³⁹. Konvolüsyonel sinir ağları hızla gelişimini sürdürerek radyolojik görüntüleme, dermatolojik görüntüleme ve histopatolojik görüntülemede yüksek performans ile klinisyenlere karar almada kolaylık sağlayacak uygulamaların içinde yer almaktadır⁴⁰.

KAYNAKLAR

1. Goel N, Yadav A, Singh BM. (2016). Medical image processing: A review. *2nd IEEE Int. Conf. Innov. Appl. Comput. Intell. Power, Energy Control. with their Impact Humanit. CIPECH 2016*, (pp. 57-62). <https://doi.org/10.1109/CIPECH.2016.7918737>.
2. Zhang J, Xia Y, Xie Y, Fulham M, et al. Classification of Medical Images in the Biomedical Literature by Jointly Using Deep and Handcrafted Visual Features. *IEEE J Biomed Health Informatics*. 2017, 22(5):1521-1530. <https://doi.org/10.1109/JBHI.2017.2775662>.
3. Toğaçar M, Ergen B. Biyomedikal Görüntülerde Derin Öğrenme ile Mevcut Yöntemlerin Kıyaslanması. *Fırat Üniversitesi Mühendislik Bilim Dergisi*. 2019, 31(1), 109-121.
4. Lecun Y, Bengio Y, Hinton G. Deep learning. *Nature*. 2015, 521(7553), 436-444. <https://doi.org/10.1038/nature14539>.
5. Miotto R, Wang F, Wang S, et al. Deep learning for healthcare: Review, opportunities and challenges. *Brief Bioinform*. 2017, 19(6):1236-1246. <https://doi.org/10.1093/bib/bbx044>.
6. Abadi M, McMahan HB, Chu A, et al. Deep learning with differential privacy. *Proc. ACM Conf. Comput. Commun. Secur*. 2016: 308-318. <https://doi.org/10.1145/2976749.2978318>.
7. Bakator M, Radosav D. Deep Learning and Medical Diagnosis: A Review of Literature. *Multi-modal Technol Interact* 2018, 2(3): 47. <https://doi.org/10.3390/mti2030047>.
8. Deng L, Yu D. (2013). Deep learning: Methods and applications. *Found Trends Signal Process*, 2013, 7(3-4), (pp.197-387). USA, Now Publishers. <https://doi.org/10.1561/20000000039>.
9. Bengio Y. (2009). Learning deep architectures for AI. *Found Trends Mach Learn*, 2(1), (pp.1-127). USA, Now Publishers. <https://doi.org/10.1561/22000000006>.
10. Şeker A, Diri B, Balık H. Derin Öğrenme Yöntemleri ve Uygulamaları Hakkında Bir İnceleme. *Gazi J Eng Sci*. 2017, 3(3), 47-64.
11. Litjens G, Kooi T, Bejnordi BE, et al. A survey on deep learning in medical image analysis. *Med Image Anal*. 2017, 42, 60-88. <https://doi.org/10.1016/j.media.2017.07.005>.
12. Nweke HF, Teh YW, Al-garadi MA, et al. Deep learning algorithms for human activity recognition using mobile and wearable sensor networks: State of the art and research challenges. *Expert Syst Appl*. 2018, 105:233-261. <https://doi.org/10.1016/j.eswa.2018.03.056>.
13. Baldi P. Autoencoders, Unsupervised Learning, and Deep Architectures. *ICML Unsupervised Transf Learn*. 2012, (pp. 37-49). <https://doi.org/10.1561/22000000006>.
14. Wang Y, Yao H, Zhao S. Auto-encoder based dimensionality reduction. *Neurocomputing*. 2016, (184), 232-242. <https://doi.org/10.1016/j.neucom.2015.08.104>.
15. Kaynar O, Yüksek AG, Gormez Y, et al. (2017). Intrusion detection with autoencoder based deep learning machine. *25th Signal Process. Commun. Appl. Conf. SIU 2017*, (pp. 1-4). <https://doi.org/10.1109/SIU.2017.7960180>.

16. Salakhutdinov R, Hinton G. Deep Boltzmann machines. *J Mach Learn Res.* 2009, (pp. 448-455).
17. Ravi D, Wong C, Deligianni F, et al. Deep Learning for Health Informatics. *IEEE J Biomed Heal Informatics.* 2016, 21(1):4-21. <https://doi.org/10.1109/JBHI.2016.2636665>.
18. Karasulu B. (2015). Aşırı öğrenme makinesi ve derin Boltzmann makinesi üzerine bir inceleme. *EEMKON 2015*, 19-21 Kasım 2015, İstanbul, 199-206.
19. Yu D, Deng L, Jang I, et al. Deep learning and its applications to signal and information processing. *IEEE Signal Process Mag.* 2010, 28(1):145-154. <https://doi.org/10.1109/MSP.2010.939038>.
20. He S, Wang S, Lan W, et al.(2013). Facial expression recognition using deep boltzmann machine from thermal infrared images. *Hum. Assoc. Conf. Affect. Comput. Intell. Interact. ACII 2013.* (pp. 239-244). <https://doi.org/10.1109/ACII.2013.46>.
21. Ser G, Bati CT. Derin sinir ağları ile en iyi modelin belirlenmesi: mantar verileri üzerine ke-ras uygulaması. *Yüzüncü Yıl Üniversitesi Tarım Bilim Dergisi*, 2019, 29(3), 406-417. <https://doi.org/10.29133/yyutbd.505086>.
22. Hinton G, Deng L, Yu D, et al. Deep Neural Networks for Acoustic Modeling in Speech Recognition. *IEEE Signal Process Mag.* 2012, 29(6):82-97. <https://doi.org/10.1109/MSP.2012.2205597>.
23. Choi E, Schuetz A, Stewart WF, et al. Using recurrent neural network models for early detection of heart failure onset. *J Am Med Informatics Assoc.* 2017, 24(2):361-370. <https://doi.org/10.1093/jamia/ocw112>.
24. Güntürkün R. Determining the amount of anesthetic medicine to be applied by using elman's recurrent neural networks via resilient back propagation. *J Med Syst.* 2010, 34(4):493-497. <https://doi.org/10.1007/s10916-009-9262-0>.
25. Zhou W, Zurada JM. (2010). Discrete-time recurrent neural networks for medical image segmentation based on competitive layer model with LT neurons. *Int. Conf. Biomed. Eng. Comput. Sci. ICBECs 2010*, (pp. 1-4). <https://doi.org/10.1109/ICBECs.2010.5462290>.
26. Viani N, Miller T, Dligach D, et al. (2017). Recurrent neural network architectures for event extraction from Italian medical reports. Ten Teije A, Popow C, Holmes J, Sacchi L. (Ed.) In: Artificial Intelligence in Medicine. AIME 2017. Lecture Notes in Computer Science, vol 10259. Springer, Cham. https://doi.org/10.1007/978-3-319-59758-4_21.
27. Hinton GE, Salakhutdinov RR. Reducing the dimensionality of data with neural networks. *Science.* 2006, 313(5786), 504-507. <https://doi.org/10.1126/science.1127647>.
28. Khatami A, Khosravi A, Nguyen T, et al. Medical image analysis using wavelet transform and deep belief networks. *Expert Syst Appl.* 2017,86:190-198. <https://doi.org/10.1016/j.eswa.2017.05.073>.
29. Abdel-Zaher AM, Eldeib AM. Breast cancer classification using deep belief networks. *Expert Syst Appl.* 2016, 46:139-144. <https://doi.org/10.1016/j.eswa.2015.10.015>.
30. Al-Fatlawi AH, Jabardi MH, Ling SH, (2016). Efficient diagnosis system for Parkinson's disease using deep belief network. *IEEE Congr. Evol. Comput. CEC 2016*. <https://doi.org/10.1109/CEC.2016.7743941>.
31. Lawrence S, Giles CL, Tsoi AC, et al. Face recognition: A convolutional neural-network approach. *IEEE Trans Neural Networks.* 1997, 8(1):98-113. <https://doi.org/10.1109/72.554195>.
32. Lin M, Chen Q, Yan S. (2014). Network in network. Arxiv:1312.4400.
33. Giusti A, Cireşan DC, Masci J, et al. (2013). Fast image scanning with deep max-pooling convolutional neural networks. *IEEE Int. Conf. Image Process. ICIP 2013*, (pp. 4034-4038). <https://doi.org/10.1109/ICIP.2013.6738831>.
34. Liu K, Kang G, Zhang N et al. Breast cancer classification based on fully-connected layer first convolutional neural networks. *IEEE Access* 2018, (6), 23722-23732. <https://doi.org/10.1109/ACCESS.2018.2817593>.
35. Krizhevsky A, Sutskever I, Hinton GE. (2012). ImageNet classification with deep convolutional neural networks. *Adv. Neural Inf. Process. Syst.* 2012, (pp. 1097-1105).

36. LeCun Y, Bottou L, Bengio Y, et al. Gradient-based learning applied to document recognition. *Proc IEEE*. 1998, 86(11):2278-2324. <https://doi.org/10.1109/5.726791>.
37. Anwar SM, Majid M, Qayyum A, et al. Medical Image Analysis using Convolutional Neural Networks: A Review. *J Med Syst*. 2018, 42(11): 226. <https://doi.org/10.1007/s10916-018-1088-1>.
38. Liu N, Han J, Zhang D. et al. (2015). Predicting eye fixations using convolutional neural networks. *Proc. IEEE Comput. Soc. Conf. Comput. Vis. Pattern Recognit.*, 2015, (pp. 362-370). <https://doi.org/10.1109/CVPR.2015.7298633>.
39. Kawahara J, Brown CJ, Miller SP, et al. BrainNetCNN: Convolutional neural networks for brain networks; towards predicting neurodevelopment. *Neuroimage*, 2017, (146), 1038-1049. <https://doi.org/10.1016/j.neuroimage.2016.09.046>.
40. Zheng Y, Jiang Z, Xie F, et al. Feature extraction from histopathological images based on nucleus-guided convolutional neural network for breast lesion classification. *Pattern Recognit*. 2017, 71:14-25. <https://doi.org/10.1016/j.patcog.2017.05.010>.