



SAĞLIKTA YAPAY ZEKA: DERİN ÖĞRENME TEKNİKLERİ VE UYGULAMALARI

Pelin CANBAY¹

ÖZET

Son yıllarda yapay zeka uygulamaları kullanılarak birçok hastalığın tahmini veya erken teşhisi yapılabilmektedir. Hem hayatta kalma oranını arttırmak hem de yüksek maliyetlerdeki tedavilerden kaçınabilmek için bu çalışmalara olan ihtiyaç gün geçtikçe artmaktadır. Sağlık verilerinin analiz edilmesi ile hastalıkların tahmin, tanı ve tedavi süreçlerinde görülen olumlu gelişmeler sağlık alanında yapay zeka çalışmalarına olan ilgiyi daha da arttırmıştır. Dünya genelinde her yıl trilyonlarca gigabayt sağlık verisi üretilmektedir. Verilerin hızla çoğalması ve daha karmaşık hale dönüşmesi bu verilerin analizinde daha karmaşık ve daha derin çözümler sunulmasını da gerektirmektedir. Bu gereklilik sonucu ortaya çıkan Derin Öğrenme teknikleri son yıllarda birçok alanda başarıyla kullanılmaktadır. Bu çalışmada, bazı yaygın kullanılan Derin Öğrenme teknikleri tanıtılmış ve sağlık alanında kullanım örnekleri sunularak güncel bir tarama yapılmıştır.

GİRİŞ

Derin öğrenme, makine öğrenmesinin alt dallarından biri olarak, özellikle çok sayıda ve karmaşık verilerin analizi için geliştirilen öğrenme türüdür. Kendileri de bir çeşit makine öğrenmesi yöntemi olan derin öğrenme teknikleri, makine öğrenmesi yöntemlerinde olduğu gibi farklı türde (denetimli, denetimsiz vb.) öğrenmeler için kullanılabilir. Denetimli öğrenmede etiketli veriler ile derin katmanlara sahip modeller eğitilip sınıflandırmada ya da regresyon analizinde kullanılmaktadır. Denetimsiz öğrenmede ise, etiketsiz veriler kullanılarak eğitilen veya ağırlıkları öğrenilen yapılar genellikle, kümeleme, öznitelik çıkarımı ve ya boyut indirgeme işlemleri için kullanılmaktadır.

¹ Kahramanmaraş Sütçü İmam Üniversitesi, Bilgisayar Mühendisliği Bölümü

Kanser verilerinin analizi ile sınıflandırılmasında [41], göğüs kanseri tahmininde [42], Alzheimer hastalığı ve ona bağlı hafif bilişsel bozuklukların sınıflandırılmasında [43], sağlık hizmetlerinde elektronik sağlık kayıtları ile karar vermede [44], sosyal-sağlık çevresinde insan davranış tahmininde [45] ve küresel-yerel sağlık durumlarının değerlendirilmesinde [46] Boltzmann makinelelerinden faydalanılmıştır.

DEĞERLENDİRMELER

Yapay zeka çalışmaları son zamanlarda derin öğrenme yöntemleri üzerine yoğunlaşmıştır. Bu yöntemlerin büyük ve karmaşık verilerin analizinde başarılı çıktılar ürettiği birçok alanda yapılan çalışmaların tekrar değerlendirilmesine yol açmıştır. Özellikle sağlık alanında sürekli ve hızla artan verilerin analiz edilmesi için derin öğrenme yöntemlerinin kullanılması büyük avantaj sağlamaktadır. Bu çalışmada, bazı yaygın kullanılan derin öğrenme teknikleri tanıtılmış ve bu tekniklerin sağlık alanında kullanımlarını içeren akademik örneklerle yer verilmiştir. Derin öğrenme teknikleri tek başına kullanımında güçlü yöntemler olmasına rağmen birlikte/sıralı kullanımları ile de başarılı çıktılar üretebilmektedir. Birçok farklı kombinasyonu da kullanılabilen bu derin öğrenme tekniklerinin, hızla büyüyen ve daha da karmaşılaşan sağlık verilerinde kullanımının birçok hastalığın erken teşhis, tanı ve tedavi süreçlerine katkı sağlaması beklenmektedir.

KAYNAKLAR

1. Gupta S, Sedamkar RR. Machine Learning for Healthcare: Introduction. 2020. Epub ahead of print 2020. DOI: 10.1007/978-3-030-40850-3_1.
2. Nahata H, Singh SP. Deep Learning Solutions for Skin Cancer Detection and Diagnosis. 2020. Epub ahead of print 2020. DOI: 10.1007/978-3-030-40850-3_8.
3. Hornik K. Approximation capabilities of multilayer feedforward networks. *Neural Networks*. Epub ahead of print 1991. DOI: 10.1016/0893-6080(91)90009-T.
4. Hecht-Nielsen R. Theory of the backpropagation neural network. 1989. Epub ahead of print 1989. DOI: 10.1109/ijcnn.1989.118638.
5. Ravi D, Wong C, Deligianni F, et al. Deep Learning for Health Informatics. *IEEE J Biomed Heal Informatics*. Epub ahead of print 2017. DOI: 10.1109/JBHI.2016.2636665.
6. Khan J, Wei JS, Ringné M, et al. Classification and diagnostic prediction of cancers using gene expression profiling and artificial neural networks. *Nat Med*. Epub ahead of print 2001. DOI: 10.1038/89044.
7. Altman EI, Marco G, Varetto F. Corporate distress diagnosis: Comparisons using linear discriminant analysis and neural networks (the Italian experience). *J Bank Financ*. Epub ahead of print 1994. DOI: 10.1016/0378-4266(94)90007-8.
8. Caliskan A, Badem H, Baştürk A, et al. Diagnosis of the Parkinson disease by using deep neural network classifier. *Istanbul Univ - J Electr Electron Eng*.
9. Amato F, López A, Peña-Méndez EM, et al. Artificial neural networks in medical diagnosis. *Journal of Applied Biomedicine*. Epub ahead of print 2013. DOI: 10.2478/v10136-012-0031-x.

10. LeCun Y, Bottou L, Bengio Y, et al. Gradient-based learning applied to document recognition. *Proc IEEE*. Epub ahead of print 1998. DOI: 10.1109/5.726791.
11. Esteva A, Kuprel B, Novoa RA, et al. Dermatologist-level classification of skin cancer with deep neural networks. *Nature*. Epub ahead of print 2017. DOI: 10.1038/nature21056.
12. Liang Z, Powell A, Ersoy I, et al. CNN-based image analysis for malaria diagnosis. In: *Proceedings - 2016 IEEE International Conference on Bioinformatics and Biomedicine, BIBM 2016*. 2017. Epub ahead of print 2017. DOI: 10.1109/BIBM.2016.7822567.
13. Zou L, Zheng J, Miao C, et al. 3D CNN Based Automatic Diagnosis of Attention Deficit Hyperactivity Disorder Using Functional and Structural MRI. *IEEE Access*. Epub ahead of print 2017. DOI: 10.1109/ACCESS.2017.2762703.
14. Gao F, Wu T, Li J, et al. SD-CNN: A shallow-deep CNN for improved breast cancer diagnosis. *Comput Med Imaging Graph*. Epub ahead of print 2018. DOI: 10.1016/j.compmedimag.2018.09.004.
15. Mikolov T, Karafiát M, Burget L, et al. Recurrent neural network based language model. In: *Proceedings of the 11th Annual Conference of the International Speech Communication Association, INTERSPEECH 2010*. 2010.
16. Bengio Y, Simard P, Frasconi P. Learning Long-Term Dependencies with Gradient Descent is Difficult. *IEEE Trans Neural Networks*. Epub ahead of print 1994. DOI: 10.1109/72.279181.
17. Hochreiter S, Schmidhuber J. Long Short-Term Memory. *Neural Comput*. Epub ahead of print 1997. DOI: 10.1162/neco.1997.9.8.1735.
18. Cho K, Van Merriënboer B, Gulcehre C, et al. Learning phrase representations using RNN encoder-decoder for statistical machine translation. In: *EMNLP 2014 - 2014 Conference on Empirical Methods in Natural Language Processing, Proceedings of the Conference*. 2014. Epub ahead of print 2014. DOI: 10.3115/v1/d14-1179.
19. Chung J, Gulcehre C, Cho K, et al. Gated feedback recurrent neural networks. In: *32nd International Conference on Machine Learning, ICML 2015*. 2015.
21. Jagannatha AN, Yu H. Bidirectional RNN for medical event detection in electronic health records. In: *2016 Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies, NAACL HLT 2016 - Proceedings of the Conference*. 2016. Epub ahead of print 2016. DOI: 10.18653/v1/n16-1056.
22. Zhao R, Yan R, Chen Z, et al. Deep learning and its applications to machine health monitoring. *Mechanical Systems and Signal Processing*. Epub ahead of print 2019. DOI: 10.1016/j.ymssp.2018.05.050.
23. Zhao A, Qi L, Dong J, et al. Dual channel LSTM based multi-feature extraction in gait for diagnosis of Neurodegenerative diseases. *Knowledge-Based Syst*. Epub ahead of print 2018. DOI: 10.1016/j.knosys.2018.01.004.
24. Oh SL, Ng EYK, Tan RS, et al. Automated diagnosis of arrhythmia using combination of CNN and LSTM techniques with variable length heart beats. *Comput Biol Med*. Epub ahead of print 2018. DOI: 10.1016/j.compbiomed.2018.06.002.
25. Lipton ZC, Kale DC, Elkan C, et al. Learning to diagnose with LSTM recurrent neural networks. In: *4th International Conference on Learning Representations, ICLR 2016 - Conference Track Proceedings*. 2016.
26. Kramer MA. Nonlinear principal component analysis using autoassociative neural networks. *AIChe J*. Epub ahead of print 1991. DOI: 10.1002/aic.690370209.
26. Hinton GE, Salakhutdinov RR. Reducing the dimensionality of data with neural networks. *Science* (80-). Epub ahead of print 2006. DOI: 10.1126/science.1127647.
27. Makhzani A, Frey B. k-Sparse autoencoders. In: *2nd International Conference on Learning Representations, ICLR 2014 - Conference Track Proceedings*. 2014.
28. Lu X, Tsao Y, Matsuda S, et al. Speech enhancement based on deep denoising autoencoder. In: *Proceedings of the Annual Conference of the International Speech Communication Association, INTERSPEECH*. 2013.

29. Vincent P, Larochelle H, Bengio Y, et al. Extracting and composing robust features with denoising autoencoders. In: *Proceedings of the 25th International Conference on Machine Learning*. 2008. Epub ahead of print 2008. DOI: 10.1145/1390156.1390294.
30. Fakoor R, Ladhak F, Nazi A, et al. Using deep learning to enhance cancer diagnosis and classification. *Proc ICML Work Role Mach Learn Transform Healthc*.
31. Bhatkoti P, Paul M. Early diagnosis of Alzheimer's disease: A multi-class deep learning framework with modified k-sparse autoencoder classification. In: *International Conference Image and Vision Computing New Zealand*. 2016. Epub ahead of print 2016. DOI: 10.1109/IVC-NZ.2016.7804459.
32. Badem H, Caliskan A, Basturk A, et al. Classification and diagnosis of the Parkinson disease by stacked autoencoder. In: *2016 National Conference on Electrical, Electronics and Biomedical Engineering, ELECO 2016*. 2017.
33. Miotto R, Li L, Kidd BA, et al. Deep Patient: An Unsupervised Representation to Predict the Future of Patients from the Electronic Health Records. *Sci Rep*. Epub ahead of print 2016. DOI: 10.1038/srep26094.
34. Suk H II, Lee SW, Shen D. Latent feature representation with stacked auto-encoder for AD/MCI diagnosis. *Brain Struct Funct*. Epub ahead of print 2015. DOI: 10.1007/s00429-013-0687-3.
35. Ackley DH, Hinton GE, Sejnowski TJ. A learning algorithm for boltzmann machines. *Cogn Sci*. Epub ahead of print 1985. DOI: 10.1016/S0364-0213(85)80012-4.
36. Hinton G. Boltzmann Machines. In: *Encyclopedia of Machine Learning and Data Mining*. 2017. Epub ahead of print 2017. DOI: 10.1007/978-1-4899-7687-1_31.
37. G. E. Hinton, T. J. Sejnowski. *Parallel distributed processing : explorations in the microstructure of cognition, vol 1, Learning and relearning in Boltzmann machines*. 1986.
38. Bengio Y, Lamblin P, Popovici D, et al. Greedy layer-wise training of deep networks. In: *Advances in Neural Information Processing Systems*. 2007.
39. Hinton GE, Osindero S, Teh YW. A fast learning algorithm for deep belief nets. *Neural Comput*. Epub ahead of print 2006. DOI: 10.1162/neco.2006.18.7.1527.
40. Salakhutdinov R, Hinton G. Deep Boltzmann machines. In: *Journal of Machine Learning Research*. 2009.
41. Karabulut EM, Ibrikci T. Discriminative deep belief networks for microarray based cancer classification. *Biomed Res*.
42. Khademi M, Nedialkov NS. Probabilistic graphical models and deep belief networks for prognosis of breast cancer. In: *Proceedings - 2015 IEEE 14th International Conference on Machine Learning and Applications, ICMLA 2015*. 2016. Epub ahead of print 2016. DOI: 10.1109/ICMLA.2015.196.
43. Li F, Tran L, Thung KH, et al. A Robust Deep Model for Improved Classification of AD/ MCI Patients. *IEEE J Biomed Heal Informatics*. Epub ahead of print 2015. DOI: 10.1109/JBHI.2015.2429556.
44. Liang Z, Zhang G, Huang JX, et al. Deep learning for healthcare decision making with EMRs. In: *Proceedings - 2014 IEEE International Conference on Bioinformatics and Biomedicine, IEEE BIBM 2014*. 2014. Epub ahead of print 2014. DOI: 10.1109/BIBM.2014.6999219.
45. Phan NH, Dou D, Piniewski B, et al. Social Restricted Boltzmann Machine: Human behavior prediction in health social networks. In: *Proceedings of the 2015 IEEE/ACM International Conference on Advances in Social Networks Analysis and Mining, ASONAM 2015*. 2015. Epub ahead of print 2015. DOI: 10.1145/2808797.2809307.
46. Rafiei MH, Adeli H. A novel unsupervised deep learning model for global and local health condition assessment of structures. *Eng Struct*. Epub ahead of print 2018. DOI: 10.1016/j.eng-struct.2017.10.070.