



RADYOLOJİDE DERİN ÖĞRENME

Kamil DOĞAN¹

GİRİŞ

Bilgisayarlar içinde bulunduğumuz zamanda hayatımızın neredeyse vazgeçilmezi olmuşlardır. Bilgisayar programları ile bilgisayarların donanımlarının artırılması üzerinde en çok durulan alanlardandır. Bu donanımlar bilgisayarları daha fonksiyonlu hale getirmekte olup öğretilen özellikler artık zeka tabiriyle anlatılmaya başlanmıştır. Öyle ki pek çok alanda insanların yaptığı işler bilgisayarlardan beklenmektedir. İnsan zekası ile başlangıç alan ve cansız aletler olan bilgisayarların yeniden yeniye zeka fonksiyonu ile işlenmesi çok ta eski olmayan yapay zeka terimini hayatımıza getirmiştir.

Yapay zeka kapsamında bilgisayarların fonksiyonel verilerle eğitilmesi çok bölümlü, kısmen karmaşık, avantaj ve yer yer dezavantajlar içeren bir süreçtir. Bu bölümlerden bir kısmı makine öğrenme, derin öğrenme ve radyomiks olarak söylenebilir.

TANIM

Çoklu işleme katmanlarından meydana gelen hesaplama modelleri bulunmaktadır. Derin öğrenme burdan yola çıkarak gerçekleşen bir sonuçtur. Örnekleri arasında konuşma tanıma, nesne algılama, görsel nesne tanıma vb. sayılabilir.

Derin öğrenme bilgisayarın her aşamadaki veriyi bir öncekinden hangi algoritmalarla çıkaracağını anlatmaktadır. İlk veri yüklemeye video, konuşma ve sesin işlenmesinde nasıl atılımlar olmuşsa derin öğrenmedeki tekrarlayan iletişim ağları ile de sıralı veriler ortaya çıkmıştır.

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

TEKRARLAYAN SİNİR AĞLARI

Derin öğrenmede geri yayılım konusunun ilk sunulmasıyla birlikte, tekrarlayan sinir ağlarını eğitmek, en merak çeken kısım olmuştur. Bu özellikle sıralı girdileri olan konuşma ve dil gibi durumlarda daha da iyidir. Tekrarlayan sinir ağları her defasında bir öğeyi işlemektedir. Ancak gizli birimlerinde ise dizinin tüm geçmiş öğeleri hakkında saklı bilgi içeren bir durum vektörü bulundurmaktadır. Tekrarlayan sinir ağları dinamizmi yüksek çok güçlü sistemlerdir. Geri yayılım gradyanları her zaman adımında büyür yada küçülür.

Tekrarlayan sinir ağları zamanla ortaya çıkar. Çok derin ileri beslemeli ağlardır. Tüm katmanlar aynı ağırlıkları paylaşmaktadır. Ana amaçları uzun dönemdeki bağımlı durumların öğrenilmesidir. Bununla birlikte bazı kanıtlar çok uzun süre bilgi depolamanın zor olduğu yönündedir. Bunun bir çözümü bu ağı bir bellekle güçlendirmek olabilir. Bu şekilde ortaya çıkan ağ sistemleri geleneksel sinir ağlarından daha etkindir.

DERİN ÖĞRENMENİN GELECEĞİ

İnsanların ve hayvanları öğrenmeleri denetimsiz öğrenme modelleridir. Kendi öğrenmemizde dünyanın yapısını nesnelere isimlerini öğrenerek değil gözlemleyerek öğreniyoruz. Böyle bakarsak denetimsiz öğrenmenin uzun vadede çok daha önemli bir pozisyon kazanacağını çok rahat söyleyebiliriz.

Denetimsiz öğrenme derin öğrenmeye olan ilgiyi canlandırmada katalitik etki yapmıştır.

Derin öğrenmenin yakın gelecekte en çok etki göstereceği bir alan doğal dil anlayışı olacaktır.

Konuşma ve el yazısı için kullanılmış olsa bile sembolik ifadelerde yeni paradigmalara ihtiyaç vardır.

KAYNAKLAR

1. Farabet, C., Couprie, C., Najman, L. & LeCun, Y. Learning hierarchical features for scene labeling. *IEEE Trans. Pattern Anal. Mach. Intell.* **35**, 1915–1929 (2013).
2. Krizhevsky, A., Sutskever, I. & Hinton, G. ImageNet classification with deep convolutional neural networks. In *Proc. Advances in Neural Information Processing Systems* 25 1090–1098 (2012).
3. Ciodaro, T., Deva, D., de Seixas, J. & Damazio, D. Online particle detection with neural networks based on topological calorimetry information. *J. Phys. Conf. Series* **368**, 012030 (2012).
4. Szegedy, C. et al. Going deeper with convolutions. Preprint at <http://arxiv.org/abs/1409.4842> (2014).

5. Mikolov, T., Deoras, A., Povey, D., Burget, L. & Cernocky, J. Strategies for training large scale neural network language models. In Proc. Automatic Speech Recognition and Understanding 196–201 (2011).
6. Hinton, G. et al. Deep neural networks for acoustic modeling in speech recognition. *IEEE Signal Processing Magazine* 29, 82–97 (2012).
7. Sainath, T., Mohamed, A.-R., Kingsbury, B. & Ramabhadran, B. Deep convolutional neural networks for LVCSR. In Proc. Acoustics, Speech and Signal Processing 8614–8618 (2013).
8. Glorot, X., Bordes, A. & Bengio, Y. Deep sparse rectifier neural networks. In Proc. 14th International Conference on Artificial Intelligence and Statistics 315–323 (2011).
9. Tompson, J., Jain, A., LeCun, Y. & Bregler, C. Joint training of a convolutional network and a graphical model for human pose estimation. In Proc. Advances in Neural Information Processing Systems 27 1799–1807 (2014).
10. Schölkopf, B. & Smola, A. *Learning with Kernels* (MIT Press, 2002).
11. Bengio, Y., Delalleau, O. & Le Roux, N. The curse of highly variable functions for local kernel machines. In Proc. Advances in Neural Information Processing Systems 18 107–114 (2005).
12. Leung, M. K., Xiong, H. Y., Lee, L. J. & Frey, B. J. Deep learning of the tissue-regulated splicing code. *Bioinformatics* 30, i121–i129 (2014).
13. Xiong, H. Y. et al. The human splicing code reveals new insights into the genetic determinants of disease. *Science* 347, 6218 (2015).
14. Collobert, R., et al. Natural language processing (almost) from scratch. *J. Mach. Learn. Res.* 12, 2493–2537 (2011).
15. Parker, D. B. *Learning Logic Report TR-47* (MIT Press, 1985).
16. Ma, J., Sheridan, R. P., Liaw, A., Dahl, G. E. & Svetnik, V. Deep neural nets as a method for quantitative structure-activity relationships. *J. Chem. Inf. Model.* 55, 263–274 (2015).
17. Rumelhart, D. E., Hinton, G. E. & Williams, R. J. Learning representations by back-propagating errors. *Nature* 323, 533–536 (1986).
18. Bottou, L. & Bousquet, O. The tradeoffs of large scale learning. In Proc. Advances in Neural Information Processing Systems 20 161–168 (2007).
19. Duda, R. O. & Hart, P. E. *Pattern Classification and Scene Analysis* (Wiley, 1973).
20. Kaggle. Higgs boson machine learning challenge. Kaggle https://www.kaggle.com/c_higgs-boson(2014).
21. Helmstaedter, M. et al. Connectomic reconstruction of the inner plexiform layer in the mouse retina. *Nature* 500, 168–174 (2013).
22. Selfridge, O. G. Pandemonium: a paradigm for learning in mechanisation of thought processes. In Proc. Symposium on Mechanisation of Thought Processes 513–526 (1958).
23. Rosenblatt, F. *The Perceptron — A Perceiving and Recognizing Automaton*. Tech.Rep. 85-460-1 (Cornell Aeronautical Laboratory, 1957).
24. Werbos, P. *Beyond Regression: New Tools for Prediction and Analysis in the Behavioral Sciences*. PhD thesis, Harvard Univ. (1974).
25. Bordes, A., Chopra, S. & Weston, J. Question answering with subgraph embeddings. In Proc. Empirical Methods in Natural Language Processing <http://arxiv.org/abs/1406.3676v3> (2014).
26. LeCun, Y. Une procédure d'apprentissage pour Réseau à seuil assymétrique in *Cognitiva* 85: a la Frontière de l'Intelligence Artificielle, des Sciences de la Connaissance et des Neurosciences (in French) 599–604 (1985).
27. Sutskever, I., Vinyals, O. & Le. Q. V. Sequence to sequence learning with neural networks. In Proc. Advances in Neural Information Processing Systems 27 3104–3112 (2014).
28. Jean, S., Cho, K., Memisevic, R. & Bengio, Y. On using very large target vocabulary for neural machine translation. In Proc. ACL-IJCNLP <http://arxiv.org/abs/1412.2007> (2015).

29. Hinton, G. E. What kind of graphical model is the brain? In Proc. 19th International Joint Conference on Artificial intelligence 1765–1775 (2005).
30. Hinton, G. E., Osindero, S. & Teh, Y.-W. A fast learning algorithm for deep belief nets. *Neural Comp.* 18, 1527–1554 (2006).
31. Nowlan, S. & Platt, J. in *Neural Information Processing Systems* 901–908 (1995).
32. Sermanet, P., Kavukcuoglu, K., Chintala, S. & LeCun, Y. Pedestrian detection with unsupervised multi-stage feature learning. In Proc. International Conference on Computer Vision and Pattern Recognition <http://arxiv.org/abs/1212.0142> (2013).
33. Osadchy, M., LeCun, Y. & Miller, M. Synergistic face detection and pose estimation with energy-based models. *J. Mach. Learn. Res.* 8, 1197–1215 (2007).
34. Hochreiter, S. Untersuchungen zu dynamischen neuronalen Netzen (in German) Diploma thesis, T.U. München (1991).
35. Taigman, Y., Yang, M., Ranzato, M. & Wolf, L. Deepface: closing the gap to human-level performance in face verification. In Proc. Conference on Computer Vision and Pattern Recognition 1701–1708 (2014).
36. Vaillant, R., Monroq, C. & LeCun, Y. Original approach for the localisation of objects in images. In Proc. Vision, Image, and Signal Processing 141, 245–250 (1994).
37. Ranzato, M., Poultney, C., Chopra, S. & LeCun, Y. Efficient learning of sparse representations with an energy-based model. In Proc. Advances in Neural Information Processing Systems 19 1137–1144 (2006).
38. Garcia, C. & Delakis, M. Convolutional face finder: a neural architecture for fast and robust face detection. *IEEE Trans. Pattern Anal. Machine Intell.* 26, 1408–1423 (2004).
39. Raina, R., Madhavan, A. & Ng, A. Y. Large-scale deep unsupervised learning using graphics processors. In Proc. 26th Annual International Conference on Machine Learning 873–880 (2009).
40. Mohamed, A.-R., Dahl, G. E. & Hinton, G. Acoustic modeling using deep belief networks. *IEEE Trans. Audio Speech Lang. Process.* 20, 14–22 (2012).
41. Dahl, G. E., Yu, D., Deng, L. & Acero, A. Context-dependent pre-trained deep neural networks for large vocabulary speech recognition. *IEEE Trans. Audio Speech Lang. Process.* 20, 33–42 (2012).
42. Bengio, Y., Courville, A. & Vincent, P. Representation learning: a review and new perspectives. *IEEE Trans. Pattern Anal. Machine Intell.* 35, 1798–1828 (2013).
43. LeCun, Y. et al. Handwritten digit recognition with a back-propagation network. In Proc. Advances in Neural Information Processing Systems 396–404 (1990).
44. LeCun, Y., Bottou, L., Bengio, Y. & Haffner, P. Gradient-based learning applied to document recognition. *Proc. IEEE* 86, 2278–2324 (1998).
45. Cadieu, C. F. et al. Deep neural networks rival the representation of primate it cortex for core visual object recognition. *PLoS Comp. Biol.* 10, e1003963 (2014).
46. Sermanet, P. et al. Overfeat: integrated recognition, localization and detection using convolutional networks. In Proc. International Conference on Learning Representations <http://arxiv.org/abs/1312.6229> (2014).
47. Girshick, R., Donahue, J., Darrell, T. & Malik, J. Rich feature hierarchies for accurate object detection and semantic segmentation. In Proc. Conference on Computer Vision and Pattern Recognition 580–587 (2014).
48. Simonyan, K. & Zisserman, A. Very deep convolutional networks for large-scale image recognition. In Proc. International Conference on Learning Representations <http://arxiv.org/abs/1409.1556> (2014).
49. Bengio, Y. Learning Deep Architectures for AI (Now, 2009).

50. Graves, A., Mohamed, A.-R. & Hinton, G. Speech recognition with deep recurrent neural networks. In Proc. International Conference on Acoustics, Speech and Signal Processing 6645–6649 (2013).
51. Hinton, G. E., Dayan, P., Frey, B. J. & Neal, R. M. The wake-sleep algorithm for unsupervised neural networks. *Science* 268, 1558–1161 (1995).
52. Salakhutdinov, R. & Hinton, G. Deep Boltzmann machines. In Proc. International Conference on Artificial Intelligence and Statistics 448–455 (2009).
53. Vincent, P., Larochelle, H., Bengio, Y. & Manzagol, P.-A. Extracting and composing robust features with denoising autoencoders. In Proc. 25th International Conference on Machine Learning 1096–1103 (2008).
54. Kavukcuoglu, K. et al. Learning convolutional feature hierarchies for visual recognition. In Proc. Advances in Neural Information Processing Systems 23 1090–1098 (2010).
55. Gregor, K. & LeCun, Y. Learning fast approximations of sparse coding. In Proc. International Conference on Machine Learning 399–406 (2010).
56. Yann L.C., Yoshua B. & Geoffrey H. Deep learning *Nature*, Vol;521 doi:10.1038/nature 14539
57. Bengio, Y., Thibodeau-Laufer, E., Alain, G. & Yosinski, J. Deep generative stochastic networks trainable by backprop. In Proc. 31st International Conference on Machine Learning 226–234 (2014).
58. Kingma, D., Rezende, D., Mohamed, S. & Welling, M. Semi-supervised learning with deep generative models. In Proc. Advances in Neural Information Processing Systems 27 3581–3589 (2014).
59. Bottou, L. From machine learning to machine reasoning. *Mach. Learn.* 94, 133–149 (2014).
60. Montufar, G. & Morton, J. When does a mixture of products contain a product of mixtures? *J. Discrete Math.* 29, 321–347 (2014).
61. Montufar, G. F., Pascanu, R., Cho, K. & Bengio, Y. On the number of linear regions of deep neural networks. In Proc. Advances in Neural Information Processing Systems 27 2924–2932 (2014).
62. Schwenk, H. Continuous space language models. *Computer Speech Lang.* 21,492–518 (2007).
63. Socher, R., Lin, C. C.-Y., Manning, C. & Ng, A. Y. Parsing natural scenes and natural language with recursive neural networks. In Proc. International Conference on Machine Learning 129–136 (2011).
64. Tompson, J., Goroshin, R. R., Jain, A., LeCun, Y. Y. & Bregler, C. C. Efficient object localization using convolutional networks. In Proc. Conference on Computer Vision and Pattern Recognition <http://arxiv.org/abs/1411.4280> (2014).
65. Bengio, Y., Simard, P. & Frasconi, P. Learning long-term dependencies with gradient descent is difficult. *IEEE Trans. Neural Networks* 5, 157–166 (1994).
66. Ranzato, M., Mnih, V., Susskind, J. M. & Hinton, G. E. Modeling natural images using gated MRFs. *IEEE Trans. Pattern Anal. Machine Intell.* 35, 2206–2222 (2013).