



DERİN ÖĞRENME MİMARİSİ

Fahriye GEMCİ¹

Turgay İBRİKÇİ²

ÖZET

Son yıllarda, derin öğrenme mimarisi moda konulardan biri haline gelmiştir. Biyomedikal, biyoenformatik ve genetik, ses ve görüntü tanıma, hastalık tanıma gibi pek çok alanda başarılı bir şekilde kullanılmaktadır. Derin öğrenme mimarisi, beynin çalışma mantığını matematiksel işlemlerle GPU gibi günümüz teknolojilerini ve programlama dillerini kullanarak sanal dünyaya modellenmesiyle gerçekleştirilmektedir. Bu çalışmada, derin öğrenmenin günümüzde neden bu kadar çok çalışma alanında tercih edilir olduğu açıklandı. Derin öğrenmenin tanımı yapıldı. Derin öğrenme gerçekleştirebilmek amacıyla kullanılan yazılım paketleri ve bu paketlerin hangi programlama dillerinde çalıştırılabildiği tanıtıldı. Derin öğrenme temel çalışma prensibi ve en temel derin öğrenme mimarileri tanıtıldı. Derin öğrenmenin çeşitli kullanım alanları ve özellikle sağlıkta kullanım alanları incelenip, tanıtıldı.

GİRİŞ

Derin öğrenme, son yıllarda verinin miktarının önemli ölçüde artışı, yazılım teknolojilerinin her alana girmesi ve problemlerin oldukça karmaşıklaşmasıyla beraber; makine öğrenme algoritmaları arasında yükselen bir moda haline gelmiştir. Derin öğrenme modellerinin matematiksel temeli 1943 yılında atılırken; 1965 yılında genel algoritması tasarlanmış, 1943-1990 yılları arası olan dönemde, o günün bilgisayar donanım teknolojisi yeterli olmadığından istenilen testlerin yapılması çok uzun zaman almaktadır. Bu yüzden, yeterli işlemci gücü gibi donanım teknolojileri 1990 ve öncesi dönemde mevcut olmadığından; 1990-2010

¹ Bilgisayar Mühendisliği, Kahramanmaraş Sütçü İmam Üniversitesi, Kahramanmaraş, Türkiye, fahriyegemci@ksu.edu.tr

² Elektrik-Elektronik Mühendisliği, Çukurova Üniversitesi, Adana, Türkiye, ibrikci@cu.edu.tr

BİLGİLENDİRME

Bu çalışma, Çukurova Üniversitesi Bilimsel Araştırma Projeleri (BAP) tarafından desteklenmektedir. Proje No: FDK-2019-11621

KAYNAKLAR

1. Ravi, D., Wong, C., Deligianni, F., Berthelot, M., Andreu-Perez, J., Lo, B., & Yang, G. Z. (2016). *Deep learning for health informatics*. IEEE journal of biomedical and health informatics, 21(1), 4-21.
2. KIZRAK, M. A., & BOLAT, B. (2018). *Derin öğrenme ile kalabalık analizi üzerine detaylı bir araştırma*. Bilişim Teknolojileri Dergisi, 11(3), 263-286.
3. McCulloch, W. S., & Pitts, W. (1943). *A Logical Calculus of the Idea Immanent in Nervous Activity*. Bulletin of Mathematical Biophysics, 5, 115-133.
4. Kayaalp, K., & Süzen, A. A. (2018) DERİN ÖĞRENME.
5. Chollet, F. (2018). *Deep Learning mit Python und Keras: Das Praxis-Handbuch vom Entwickler der Keras-Bibliothek*. MITP-Verlags GmbH & Co. KG.
6. Şeker, A., Diri, B., & Balık, H. H. (2017). *Derin öğrenme yöntemleri ve uygulamaları hakkında bir inceleme*. Gazi Mühendislik Bilimleri Dergisi (GMBD), 3(3), 47-64.
7. Guo, Y., Liu, Y., Oerlemans, A., Lao, S., Wu, S., & Lew, M. S. (2016). *Deep learning for visual understanding: A review*. Neurocomputing, 187, 27-48.
8. Center Berkeley, , (2016). *Caffe*. (Online). Available: <http://caffe.berkeleyvision.org/>
9. Google, (2016). *Tensorflow*. (Online). Available: <https://www.tensorflow.org/>
10. Universite de Montreal, (2016). *Theano*. (Online). Available: <http://deeplearning.net/software/theano/>
11. Collobert, R., Kavukcuoglu, K., & Farabet, C. (2016). *Torch*. (Online). Available: <http://torch.ch/>
12. Nielsen, M. A. 2015. *Neural Networks and Deep Learning*. Vol. 25. <http://neuralnetworksanddeeplearning.com/>, USA, 224s.
13. Tim D. (2015). *Deep Learning in a Nutshell: History and Training Parallel Forall*. (Online). Available: <https://devblogs.nvidia.com/parallelforall/deep-learning-nutshell-history-training/>. (Accessed: 20-Mar-2017).
14. Hubel, D. H. & Wiesel, T. N. (1962). *Receptive fields, binocular interaction and functional architecture in the cat's visual cortex*. J. Physiol., vol. 160, no. 1, pp. 106-154.
15. Karakuş, B. (2018). *Derin öğrenme ve büyük veri yaklaşımları ile metin analizi*. Elazığ: Fırat Üniversitesi Doktora Tezi.
16. Hochreiter, S., and Schmidhuber, J. (1997). *Long short-term Memory*. Neural Computation, 9(8): 1735-1780.
17. Sak, H., Senior, A. W., and Beaufays, F. (2014). *Long short-term memory recurrent neural network architectures for large scale acoustic modeling*.
18. Hinton, G. E. & Salakhutdinov, R. R. (2006). *Reducing the Dimensionality of Data with Neural Networks*. Science (80-.), 313(5786), 504-507.
19. Bengio, Y. (2009). *Learning Deep Architectures for AI*. Found. trends* Mach. Learn., 2(1), pp. 1-127.
20. Baldi, P. (2012). *Autoencoders, unsupervised learning, and deep architectures*. In Proceedings of ICML workshop on unsupervised and transfer learning, pp. 37-49.

21. Gemci, F., & Ibrikci, T. (2019). *Using deep learning algorithm to diagnose parkinson disease with high accuracy*. Kahramanmaraş Sütçü İmam Üniversitesi Mühendislik Bilimleri Dergisi, 22, 19-25.
22. Caliskan, A., Badem, H., Basturk, A., & Yuksel, M. E. (2017). *Diagnosis of the parkinson disease by using deep neural network classifier*. Istanbul University-Journal of Electrical & Electronics Engineering, 17(2), 3311-3318.
23. de Dieu Uwisengeyimana, J., & Ibrikci, T. (2017). *Diagnosing knee osteoarthritis using artificial neural networks and deep learning*. Biomedical Statistics and Informatics, 2(3), 95.
24. Ocaña, M. I. G., Román, K. L. L., Urzelai, N. L., Ballester, M. Á. G., & Oliver, I. M. (2020). *Medical Image Detection Using Deep Learning*. In Deep Learning in Healthcare (pp. 3-16). Springer, Cham.
25. Benhammou, Y., Achchab, B., Herrera, F. & Tabik, S. (2020). Break His based breast cancer automatic diagnosis using deep learning: Taxonomy, survey and insights. Neurocomputing, 375, 9-24.
26. Karabulut, E. M., & Ibrikci, T. (2017). *Discriminative deep belief networks for microarray based cancer classification*.
27. Karabulut, E. M., & Ibrikci, T. (2016, April). *Texture analysis of melanoma images for computer-aided diagnosis*. In Int. Conference on Intelligent Computing, Computer Science & Information Systems (ICCSIS 16) 2, 26-29.
28. Karabulut, E. M., & Ibrikci, T. (2015). *Emphysema discrimination from raw HRCT images by convolutional neural networks*. In 2015 9th International Conference on Electrical and Electronics Engineering (ELECO) (pp. 705-708). IEEE.
29. Sarıkaya, M. A. & İnce, G. (2017). *Emotion recognition from EEG signals through one electrode device*. In Signal Processing and Communications Applications Conference (SIU), 2017 25th (pp. 1-4). IEEE.
30. Salakhutdinov, R. & Hinton, G. (2009). *Semantic hashing*. Int. J. Approx. Reason., 50, 969-978.
31. Metin, İ. A., & Karasulu, B. (2015). *İnsan Aktivitelerinin Sınıflandırılmasında Tekrarlayan Sinir Ağı Kullanan Derin Öğrenme Tabanlı Yaklaşım*. Veri Bilimi, 2(2), 1-10.
32. Baştürk, A., Yüksel, M. E., Çalışkan, A., & Badem, H. (2017, May). *Deep neural network classifier for hand movement prediction*. In 2017 25th Signal Processing and Communications Applications Conference (SIU) (pp. 1-4). IEEE.