

RADYOLOJİDE MAKİNE ÖĞRENMENİN ROLÜ

Adil DOĞAN¹

GİRİŞ

Tıp alanında radyoloji diğer bölümlere göre yeni bir bilim dalıdır. Radyoloji biliminin doğuşuna X ışınlarının ve radyoaktivitenin keşfedilmesi neden olmuştur. Bu keşifler sonucunda radyoloji tıp alanında hastalıkların tanı ve tedavisinde kullanılmaya başlamıştır. Radyoloji 1900'lü yılların başında bir tıp dalı olarak kliniğe girmiştir. Radyolojinin temel inceleme yöntemi x ışınlarını kullanan röntgendir. Sonraları değişik enerji türlerinin kullanılması ile birlikte farklı yöntemler geliştirilmiştir. Bu yöntemler bilgisayar ve x ışının birlikte kullanılmasıyla bilgisayarlı tomografi(BT), hidrojen atomundan sinyalleri toplayan magnetik rezonans görüntüleme(MRG) ve sesin dokulardan yansması sonucu görüntü oluşturan ultrasonografi (USG) günümüz radyolojik modalitelerinin temellerini oluşturmaktadırlar. Bu radyolojik modalitelerin her biri organizmanın görüntüsünü farklı enerji veya farklı fizik kuralları kullanarak elde ederler. Son yıllarda teknolojinin baş döndürücü bir şekilde ilerlemesi ile birlikte radyolojik modalitelerde de hızlı bir ilerleme gerçekleşmiştir. Radyoloji günümüzde tanı ve tedavi amacıyla çok sık kullanılan bir bilim dalı haline gelmiştir.

Radyolojik görüntüleme tanı ve tedavi endikasyonları hızlı bir şekilde artış göstermektedir. Bu yüzden radyolojik görüntüleme hasta bakımında önemli bir yer tutmaktadır . Bu hızlı artış daha az invaziv tedavi, hızlı, doğru ve uygun maliyet sonucunda gelişmektedir. Teknolojik gelişmelerin artması ile birlikte radyolojik ekipmanların kullanımında doğru orantılı olarak artmıştır. İleri düzey teknolojik gelişmeler yüksek çözünürlüklü görüntüler elde edilmesini, daha küçük anatomik yapıları ve dokuların mikroskopik düzeyde anormallikleri hakkında bilgi vermektedir. Yüksek çözünürlüklü görüntülerde görüntü sayısının artması

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

KAYNAKLAR

1. Ali , A.M.,Farag, A.A., 2008. Automatic lung segmentation of volumetric low-dose CT scans using graphcuts. *Advances in Visual Computing* pp 258-267
2. Bhargavan, M.,Kaye, A.H., Forman, H.P., Sunshine, J.H., 2009. Workload of radiologists in United States in 2006–2007 and trends since 1991–1992. *Radiology* 252, 458–467.
3. Buhmann MD. Radial basis functions with compact support. In: *Radial basis functions: theory and implementations*. Cambridge, England: Cambridge University Press, 147–162.
4. Chan, H.-P., Hadjiiski, L., Zhou, C., Sahiner, B., 2008. Computer-aided diagnosis of Lung cancer and pulmonary embolism in computed tomography—a review. *Academic Radiology* 15, 535–555.
5. Chartrand G, Cheng PM, Vorontsov E, et al. Deep learning: a primer for radiologists. *Radiographics* 2017; 37:2113–2131
6. Choy G, Khalilzadeh O, Michalski M. Current Applications and Future Impact of Machine Learning in Radiology. *Radiology*. 2018 Aug;288(2):318-328
7. Caruana, R., 1997. Multitask learning. *Machine Learning* 28, 41–75
8. Doi, K., 2005. Current status and future potential of computer-aided diagnosis in medical imaging. *British Journal of Radiology* 78, S3–S19.
9. Dreyer, K.J., Kalra, M.K., Maher, M.M., Hurier, A.M., Asfaw, B.A., Schultz, T., Halpern, E.F., Thrall, J.H., 2005. Application of recently developed computer algorithm for automatic classification of unstructured radiology reports: validation study. *Radiology* 234, 323–329
10. El-Naqa, I., Yang, Y.Y., Galatsanos, N.P., Nishikawa, R.M., Wernick, M.N., 2004. A similarity learning approach to content-based image retrieval: application to digital mammography. *IEEE Transactions on Medical Imaging* 23, 1233–1244.
11. Erickson BJ, Korfiatis P, Akkus Z et al. Machine Learning for Medical Imaging. *Radiographics*. 2017 Mar-Apr;37(2):505-515
12. Erickson BJ. Deep Learning and Machine Learning in Imaging: Basic Principles. in: E. R. Ranschaert et al. (eds.), *Artificial Intelligence in Medical Imaging*, Springer Nature Switzerland AG 2019, pp 39-46
13. Friedman, C., Hripcsak, G., 1999. Natural language processing and its future in medicine. *Academic Medicine* 74, 890–895.
14. Greig, D.M., Porteous, B.T., Seheult, A.H., 1989. Exact maximum a-posteriori estimation for binary images. *Journal of the Royal Statistical Society Series B Methodological* 51, 271–279
15. James H. Thrall, , Xiang Li, Quanzheng Li et al. Artificial Intelligence and Machine Learning in Radiology: Opportunities, Challenges, Pitfalls, and Criteria for Success. *J Am Coll Radiol* 2018;15:504-508.
16. Keysers, D., Dahmen, J., Ney, H., Wein, B.B., Lehmann, T.M., 2003. Statistical frame work for model-based image retrieval in medical applications. *Journal of Electronic Imaging* 12, 59–68.
17. Koçak B, Durmaz EŞ, Ateş E et al. Radiomics with artificial intelligence: a practical guide for beginners. *Diagn Interv Radiol* 2019; 25:485–495
18. Kononenko, I. 2001. Machine learning for medical diagnosis: history, state of the art And perspective. *Artificial Intelligence in Medicine* 23, 89–109
19. Ochs, R.A., Goldin, J.G., Abtin, F., Kim, H.J., Brown, K., Batra, P., Roback, D., McNitt-Gray, M.F., Brown, M.S., 2007. Automated classification of lung bronchovascular anatomy in CT using AdaBoost. *Medical Image Analysis* 11, 315–324.
20. Pluim, J.P.W., Maintz, J.B.A., Viergever, M.A., 2003. Mutual-information-based registration of medical images: a survey. *IEEE Transactions on Medical Imaging* 22, 986–1004
21. Prajapati GL, Patle A. On performing classification using SVM With radial basis and polynomial kernel functions: 2010 3rd International Conference on Emerging Trends in Engineering and Technology. New York, NY: Institute of Electrical and Electronics Engineers, 2010.

22. Rokach L, Maimon O. Data mining with decision trees: theory and applications. 2nd ed. Singapore: World Scientific Publishing Company, 2014.
23. Sajda, P., 2006. Machine learning for detection and diagnosis of disease. *Annual Review of Biomedical Engineering* 8, 537–565.
24. Schoepf, U.J., Costello, P., 2004. CT angiography for diagnosis of pulmonary embolism: state of the art. *Radiology* 230, 329–337.
25. Schoepf, U.J., Schneider, A.C., Das, M., Wood, S.A., Cheema, J.L., Costello, P., 2007. Pulmonary embolism: computer-aided detection at multi detectorrow spiral computed tomography. *Journal of Thoracic Imaging* 22, 319–323
26. ShijunWang, Ronald M.Summers. Machine learning and radiology. *Medical Image Analysis*. 2012(16)933-951
27. Summers, R.M., 2010. Improving the accuracy of CT colonography interpretation: computer-aided diagnosis. *Gastrointestinal Endoscopy Clinics of North America* 20, 245–257.
28. Szegedy C, Toshev A, Erhan D. Deep neural Networks for object detection. In: Burges CJC, Bottou L, Welling M, GhahramaniZ, Weinberger KQ, eds. *Advances in neuralin formation processing systems*. RedHook, NY: CurranAssociates, 2013; 2553–2561
29. Tagare, H.D., Jaffe, C.C., Duncan, J., 1997. Medical image databases: a content-based Retrieval approach. *Journal of the American Medical Informatics Association* 4, 184–198.
30. Tuncel E . *Klinik Radyoloji Genişletilmiş 2. Baskı*. İstanbul: Nobel kitapevleri, 2011 ,p1-11
31. Way TW, Sahiner B, Hadjiiski LM, Chan HP. Effect of finite sample size on feature selection and classification: a simulationstudy. *MedPhys* 2010;37(2):907–920.
32. Yoshida, H., Dachman, A.H., 2006. CAD techniques, challenges, and controversies in computed tomographic colonography. *AbdominalImaging* 30, 26–41.