

Farklı Otokodlayıcı Modelleri ile Sentetik Beyin MR Görüntülerinin Çoğaltılması

Şeyda KARCI

İnönü Üniversitesi Mühendislik Fakültesi, Bilgisayar Mühendisliği Bölümü
seydakarc@gmail.com, 0000-0001-8489-7828

Geliş tarihi:16.01.2021;

Kabul tarihi:16.02.2021

Özet:

Oto-kodlayıcılar girdi katmanında ki değerleri çıkış katmanında da elde etmeye çalışan tam bağlı yapay sinir ağlarıdır. Yapılan bu çalışmada, farklı modelleri MR görüntülerine uygulanacak şekilde düzenlenmiş ve uygulanmıştır. Bu amaçla üç farklı yöntem uygulanmış ve sonuçları elde edilmiştir. Sonuçlar yapısal benzerlikleri ve görünümüleri açısından karşılaştırmalı olarak detaylı bir şekilde verilmiştir.

Anahtar Kelimeler: Beyin MR görüntüleri, oto-kodlayıcılar.

Reproduction of Synthetic Brain MR Images with Different Autocode Models

Abstract:

Autoencoders are fully connected artificial neural networks that try to obtain the values at the input layer also at the output layer. In this study, different models were arranged and applied to be applied to MR images. For this purpose, three different methods were applied and results have been obtained. The results are given in detail in terms of structural similarities and appearances, in comparison.

Keywords: Brain MR images, autoencoders.

1. GİRİŞ

Otokodlayıcıların geniş alanda kullanımı bulunmaktadır. Yüksek çözünürlük sınır profili, geniş bant radar verilerinin alt-yankılarının vektör toplamı şeklinde ifade edilir ve bu amaçla yapılan çalışmalardan birinin detayı için (Guo ve d., 2020) bakılabilir. Oto-kodlayıcıların diğer bir kullanım alanı ultra-düşük-doza hesapsal tomografi görüntülerin gürültüden arındırılması alanıdır ve bu amaçla yapılan çalışmalardan bir tanesi (Nishio ve d., 2017) yer almaktadır. Üretim sektöründe de yapay zekâ tekniklerinin kullanımı son yıllarda artmaya başlamıştır ve üretim sistemlerinde ara elemanların hatalarından kaçınmak ve sistem bakımı maliyetini düşürmek amacıyla bu tekniklerden istifade edilmektedir (Wang ve d., 2020). Çok modelli derin öğrenme iki modelliği üzerinde çalışmalar yapılmıştır (Chen ve d., 2021). Tensör faktörleri kullanarak bağlam-farkında öneri sistemlerinin problemine odaklanma üzerine çalışmalar bulunmaktadır (Wu ve d., 2017).

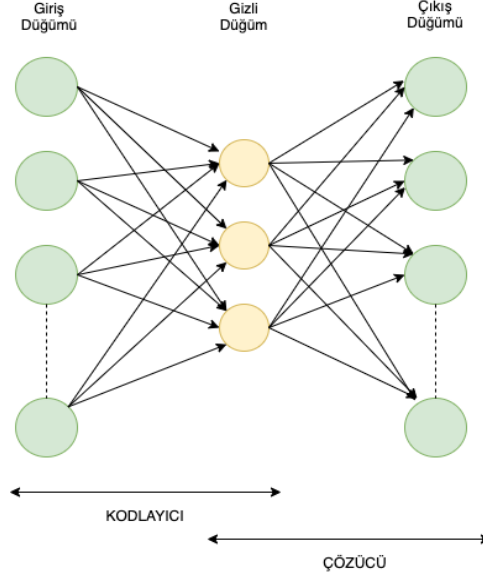
Bu çalışmada beyin MR görüntüleri kullanılarak oto-kodlayıcıların farklı modellerinin karşılaştırılması yapılmış amacıyla uygulamalar yapılmıştır.

2. DERİN OTO-KODLAYICILAR (DEEP AUTO-ENCODERS)

İnsan beyin hücrelerinin modellenmesi sonucunda yapay sinir ağları modelleri küçük dünya ağı modelinin bir alt kümesi olarak ortaya çıkmıştır. Bu modelin ortaya çıkması ile beraber makine öğrenmesi alanında çok daha hızlı adımlar atılmaya başlanmıştır. Yapay sinir ağlarının gelişimi ile beraber veri boyutunun ve miktarının artması yapay sinir ağlarının sınırlı olma problemini ortaya çıkarmıştır. Sınırlama kullanılacak veri ile ilgili özellik çıkarma şeklindedir; bütün veri giriş olarak verilememektedir. Bu problemi gidermek amacıyla her katmanın anlamı belli olan ve katman sayısı fazla olan derin öğrenme modelleri geliştirilmiştir. Derin öğrenmede verinin kendisi doğrudan girdi olarak kullanılabilir.

Yapay sinir ağlarının bir türevidir olan oto kodlayıcı, ilk olarak 1990'lı yıllarda Hinton ve PDB grup tarafından ortaya atılmış, 2006 yılında derin öğrenme mimarisinin güncellik kazanması ile makine öğrenmesindeki ana konulardan biri haline gelmiştir (Baldi, 2012).

Basit oto-kodlayıcı (autoencoder) modelleri kodlayıcı, çözücü ve gizli katman olmak üzere üç kısımdan meydana gelen tam bağlı bir yapay sinir ağıdır. Şekil 1’ de bu yapının mimarisi verilmiştir. Bu kısımlar tek bir modelmiş gibi beraber eğitilirler. Kodlayıcı katmanları veriyi sıkıştırırken çözücü katman ise sıkıştırılmış veriyi açmak için kullanılırlar.



Şekil 1. Oto-kodlayıcı mimarisi.

Modeli yapay sinir ağlarında ayıran özelliği ağıın kodlayıcı ve çözücü katmanındaki veri aynı olduğundan katmanlardaki nöron sayılarının birbirlerine eşit olmasıdır. Aynı zamanda etiket bilgisi bu modelde kullanılmaz ve gizli katmandaki nöron sayısı ise veriye göre istenildiği gibi verilebilir.

Ağ, giriş veri setini çıkışta verilen aynı veri setine uydurmak amacıyla eğitim sırasında geri yayılım algoritmasını kullanarak en uygun ağırlık değerlerini belirler. Bu nedenle yöntem öğreticisi olmayan geri yayılım algoritması olarak da anılmaktadır (Rumelhart ve d., 1986).

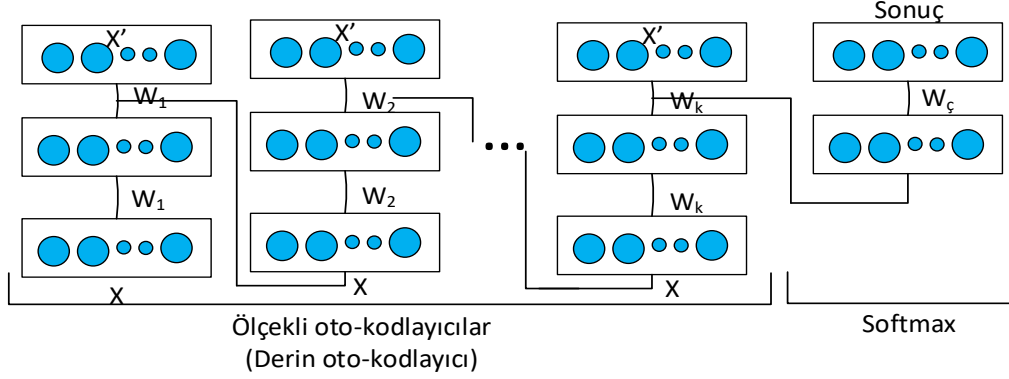
Diğer bir deyişle oto-kodlayıcılar kendi giriş verisini tekrar kendisine eşleştiren bir sinir ağı olarak düşünülebilir. Oto-kodlayıcıların giriş ve çıkış katmanlarındaki nöron sayıları orta katmandan fazla olmaktadır. Bu durumda giriş verisinin boyut indirgenmesi yaşanır ve orta katmanın çıkışında sonuç elde edilebilir. Oto-kodlayıcıların haritalama bağıntısı Denklem 1’de verilmektedir.

$$h = f_{\theta} = \sigma(Wx + b) \text{ ve } \theta = \{W, b\} \quad (1)$$

Denklem 1’de verilen bağıntı ve parametre kümesi ile giriş katmanı gizli katmana haritalanmış olur. Tekrar çıkışı elde etmek amacıyla Denklem 2 kullanılmaktadır.

$$f: y = f_{\theta'} = \sigma(bfW'h + b') \text{ ve } \theta = \{W', b'\} \quad (2)$$

Derin öğrenme mimarisi, sinir ağlarının tekrar eden belli katmanların ardışıl kullanımı şeklinde özetlenebilir. Benzer durum oto-kodlayıcılar için de geçerli olan bir durumdur ve oto-kodlayıcıların ardışıl bir şekilde kullanımı ile derin oto-kodlayıcılar elde edilmektedir veya elde edilen mimariye derin oto-kodlayıcılar denilmektedir.



Şekil 2. Derin oto-kodlayıcı mimarisi.

Oto-kodlayıcıların orta katmanından çıkış elde edilebildiğinden Şekil 2’de görüleceği gibi bir önceki katmanın orta seviyesinde elde edilen çıkış bir sonraki katmana giriş olarak verilmektedir. Şekil 2’de görüleceği gibi oto-kodlayıcıların ezberleme probleminin oluşacağı durumu görülmektedir. Bu problemi çözmek amacıyla girişe gürültü eklenerek problemin çözüm yoluna gidilmektedir.

3. Evrişimsel Oto-kodlayıcılar (Convolutional Autoencoders)


Girdilerimiz görüntü olduğundan katmanlarımızda evrişimli sinir ağları kullanmak mantıklıdır. Evrişimsel otokodlayıcılarda, ağırlıklar girişin tüm konumları için paylaşılmaktadır. Evrişimsel otokodlayıcılar için kayıp fonksiyonu Denklem 3’de verilmiştir. Denklemdeki λ düzenleme parametresidir.

$$e(x, y, w) = \frac{1}{2n} \sum_{i=1}^n \|x_i - y_i\|_2^2 + \lambda \|w\|_2^2 \quad (3)$$

Aşağıda bir x girişi için gizli katman haritalaması ve yeniden üretim Denklem 4 ve 5’te verilmiştir. Kullanılan evrişimsel oto-kodlayıcı mimarisi ise Şekil 3’te giriş ve çıkışları ile verilmiştir.

$$h_k = \sigma(x * w_k + b_k) \quad (4)$$


$$y = \sigma\left(\sum_{k \in H} h_k * \tilde{w}_k + c\right) \quad (5)$$



Şekil 3. Evrişimsel oto-kodlayıcı mimarisi.


4. VERİ SETİ VE UYGULAMA SONUÇLARI

Araştırmada kullanılan veri seti 154 beyin MR görüntüsünden oluşmaktadır ve bu veriler <https://www.kaggle.com/navoneel/brain-mri-images-for-brain-tumor-detection> adresindeki “Brain MRI Images for Brain Tumor Detection” veri setindeki görüntülerin bir kısmı bu çalışmada kullanılmıştır (Kaggle.com, 2021). Şekil 4’te bu 154 görüntüden birkaçı verilmiştir. Veriler kullanılan mimarilere giriş olarak kullanmak için görüntülerin hepsi 224x224 boyutlarına getirmek amacıyla ön işlem yapıldı. Bu çalışmada kullanılan görüntülerden özellikleri mimari tarafından boyut indirgeme işleminden sonra öğrenilmektedir ve daha sonra bu özellikler kullanılarak görüntüler elde edilmeye çalışılmaktadır.



Şekil 4. Verilerdeki örnek beyin MR görüntüleri.


Şekil 4’te, görüntüler farklı genişlik ve yüksekliklere sahiptir. Ön işlemenin ilk adımı beyinleri görüntüden ayırmak ve ikinci adımı bütün görüntüleri 224x224 olarak yeniden boyutlandırmaktır. Şekil 5’te işlemler sonucu elde edilen bir görüntü verilmiştir.




Şekil 5. Ön işleme sonucu beyin MR görüntüsü.

Modeller eğitime, hazırlanan veri setleri ile farklı iterasyonlarda verildikten sonra sonuçlar elde edilmiştir. Şekil 6’da ilk model olan derin oto-kodlayıcıların 100 iterasyon sonucu elde edilen görüntüleri verilmiştir. Şekil 7’de gürültü gideren (Denoising) oto-kodlayıcıların 100 iterasyon sonucu verilmiştir. Gürültü için standart normal dağılım kullanılmıştır. Şekil 8’de ise evrişimli oto-kodlayıcıların 50 iterasyon sonucu verilmiştir.


Üç farklı modellerin sonuçları ve modele verilen giriş görüntüleri arasında ki yapısal benzerlik oranlarına bakılmıştır. Bu SSIM metriği ile yapılmıştır. Bunun gibi PSNR ve MSE metrikleri de vardır fakat insan görsel algısı açısından SSIM daha iyi sonuçlar vermektedir (Sara ve d., 2019). Bu yüzden çalışmada SSIM metriği tercih edilmiştir. SSIM (structural similitary-yapısal benzerlik), veri sıkıştırma gibi işlemlerden veya veri iletimindeki kayıplardan kaynaklanan görüntü kalitesi düşüşünü ölçen yani görüntü benzerliğini ölçen bir metriktir. Eğitilen modeller sonucu elde edilen görüntüler ve giriş görüntülerdeki benzerlik oranı aşağıda verilmiştir. Sonuç olarak üç farklı yöntemle oto-kodlayıcıları MR görüntülerine uygulayarak amaçlanan sonuçlar Tablo 1’de verilmiştir.



Şekil 6. Derin oto-kodlayıcılara verilen giriş görüntüleri ve sonuçları.



Şekil 7. Gürültü gideren oto-kodlayıcılara verilen giriş görüntüleri ve sonuçları.



Şekil 8. Evrişimli oto-kodlayıcılara verilen giriş görüntüler ve sonuçlar.

Tablo 1. SSIM sonuçları

Model	SSIM Sonuçları
Derin Oto-kodlayıcı	0.628627834580116
Denoising Oto-kodlayıcı	0.726668361091387
Evrişimli Oto-kodlayıcı	0.7698221465790571

5. SONUÇ

Bu çalışmada 154 farklı beyin MR görüntüleri çeşitli ön işlemlerden geçirilip, farklı oto-kodlayıcı modellerine verilmiştir. Bu amaçla derin oto-kodlayıcı modeli, evrişimli oto-kodlayıcı modeli ve derin oto-kodlayıcı modeline giriş olarak iki farklı şekilde ayarlanan gürültü gideren oto-kodlayıcılar kullanılmıştır. Sonuçları yapısal benzerlik yöntemi ile değerlendirilmiştir. Yapılan uygulamalar sonucunda yapısal benzerlik oranlarına bakılarak evrişimli oto-kodlayıcıların anlamlı sonuçlar verdiği görülmüştür.

KAYNAKÇA

- Baldi, P., "Autoencoders, Unsupervised Learning, and Deep Architectures," Workshop on Unsupervised and Transfer Learning, 2012.
- Chen, w., Wang, W., Liu, L., Lew, M.S., "New ideas and trends in deep multimodal content understanding: A review", Neurocomputing, Vol:426, pp:195-215, 2021.
- Guo, C., Wang, H., Jian, T., Xu, C., Sun, S., "Method for denoising and reconstructing radar HRRP using modified sparse auto-encoder", Chinese Journal of Aeronautics, vol. 33, pp:1026-1036, 2020.
- Kaggle: <https://www.kaggle.com/navoneel/brain-mri-images-for-brain-tumor-detection> (Ocak,2021).
- Nishio, M., Nagashima, C., Hirabayashi, S., Ohnishi, A., Sasaki, K., Sagawa, T., Hamada, M., Yamashita, T., "Convolutional auto-encoder for image denoising of ultra-low-dose CT", Heliyon, Vol:2017, doi: 10.1016/j.heliyon.2017. e00393.
- Rumelhart, D.E., Hinton, G.E., Williams, R.J., "Parallel Distributed Processing: Explorations in the Microstructure of Cognition, Vol. 1," D. E. Rumelhart, J. L. McClelland, and C. PDP Research Group, Eds. Cambridge, MA, USA: MIT Press, pp. 318–362, 1986.
- Wang, Y., Zhao, Y., Addepalli, S., "Remaining useful life prediction using deep learning approaches: A Review", Procedia Manufacturing, Vol: 49, pp:81-88, 2020.
- Wu, W., Zhao, J., Zhang, C., Meng, F., Zhang, Z., Zhang, Y., Sun, Q., "Improving performance of tensor-based context-aware recommenders using bias tensor factorization with context feature auto-encoding", Knowledge-Based Systems, Vol:128, pp:71-77, 2017.
- Sara, U., Akter, M., Uddin, M.S., "Image Quality Assessment Through FSIM, SSIM, MSE and PSNR-A Comparative Study", Journal of Computer and Communications, Vol.7 No.3, 2019.