

Yığılanmış Özdevinimli Kodlayıcı ile Parkinson Hastalığının Sınıflandırılması ve Teşhis Edilmesi

Classification and Diagnosis of the Parkinson Disease by Stacked Autoencoder

Hasan Badem¹, Abdullah Caliskan², Alper Basturk¹, Mehmet Emin Yuksel²

¹Bilgisayar Mühendisliği Bölümü, Erciyes Üniversitesi, Kayseri, Türkiye
hbadem@erciyes.edu.tr, ab@erciyes.edu.tr

²Biyomedikal Mühendisliği Bölümü, Erciyes Üniversitesi, Kayseri, Türkiye
acaliskan@erciyes.edu.tr, yuksel@erciyes.edu.tr

Özet

Parkinson hastalığı ses ve konuşma bozukluklarına yol açan nörodejeneratif bir hareket bozukluğudur. Bundan dolayı hastalık sekte meydana gelen disfoniden teşhis edilebilmektedir. Bu çalışmada parkinson hastalığının sınıflandırılmasında yeni bir yöntem olan yığılanmış özdevinimli kodlayıcı kullanılmıştır. Bu yöntem iki adet veri seti ile test edilerek klasik yöntemlerle kıyaslanmıştır. Elde edilen sonuçlara göre bu yöntem klasik yöntemlere göre daha iyi sonuç vermiştir.

Abstract

Parkinson disease is neuro-degenerative motion disorder this disease causes voice and speech dysfunctions. Therefore, disease can be diagnosed by determining dysphonia produced by a subject with parkinson diseases. In this paper we have introduced a new classification method of the parkinson disease which is based on the stacked autoencoder. The method is tested with two data sets and results show that the performance of the stacked autoencoder is significantly better than the state-of-the-art methods.

1. Giriş

Ülkemizde ve dünyada her yıl binlerce kişi Parkinson hastalığına yakalanmaktadır. Parkinson farklı evreleri olan genellikle yaşlılarda görülen ve vücudun tamamını etkileyen bir hastalıktır [1]. Hastalığın teşhisi uzman hekim tarafından son derece teknolojik cihazlarla kolaylıkla yapılabilmektedir. Ancak bu tarz masraflı ve hastayı yoran teşhis yöntemlerini her bireye uygulamak son derece zor ve zahmetli olabilmektedir. Bu hastalığa yakalanan bireylerde en sık görülen olumsuzluk konuşma bozuklukları olarak karşımıza çıkmaktadır. Bundan dolayı hastalığa kişinin ses sinyallerinin analizinin yapılarak teşhis konulması alternatif bir teşhis yöntemi olarak karşımıza çıkmaktadır. Bu yöntemin en büyük avantajı kişinin evinden bile ayrılmadan kişiye teşhis konulması hatta hastalığın evrelerinin belirlenmesi mümkün olmaktadır. Bunun yanında hastalığın seyri uzaktan bile takip edilebilmektedir.

Hastalık teşhisi ve hastalığın derecesi parkinson hastalığına yakalanmış kişinin ses kayıt örnekleri yardımıyla yapılabilmektedir [2]. Deneğin ses kayıtlarından çeşitli öznitelikler çıkarılarak sınıflandırma işlemi yapılmaktadır. Bu sınıflandırma işlemi birçok sınıflandırma yöntemi ile yapılabilmektedir. Bu çalışmada daha önce kullanılmayan bir yöntem ile sınıflandırma

işlemi yapılmıştır. Sınıflandırma işlemi için derin öğrenme yapılarından yığılanmış özdevinimli kodlayıcı (YÖK) kullanılmıştır. Derin öğrenme teknikleri bilimin birçok alanında kullanılmasıyla ve bilinen klasik yöntemlere göre gayet başarılı sonuçlar üretmesiyle ön plana çıkmaktadır [3]. Bu çalışmada derin sinir ağı yapılarından özdevinimli kodlayıcılardan yararlanılarak oluşturan yığılanmış özdevinimli kodlayıcılar ve bu yapıya entegre edilen softmax katmanı yardımıyla parkinson hastalığı için sınıflandırma işlemi yapılmıştır. Bu işlem için parkinson hastalığına bağlı oluşan disfoniyi ölçerek deneklere teşhis koymayı amaçlayan UCI veri tabanından [4] alınan iki adet veri seti YÖK yapısı yardımıyla sınıflandırılmıştır. Bu çalışmanın, ikinci bölümünde YÖK yapısı ve tasarlanan ağ yapısı hakkında bilgi verilecektir. Üçüncü bölümde ise deneysel sonuçlar verilmektedir. Son bölümde ise çalışmadan elde edilen sonuçlar değerlendirilmektedir.

2. Derin Öğrenme: Yığılanmış Özdevinimli Kodlayıcı

2.1. Özdevinimli Kodlayıcı

Özdevinimli kodlayıcı (ÖK), girişi ve çıkışı aynı olan bir yapay sinir ağı modelidir. Bu model iç parametrelerini ($\mathbf{W}$ ve $\mathbf{b}$) sistemin çıkışı $h_{\mathbf{W},\mathbf{b}}(\mathbf{x})$ ile girişi $\mathbf{x}$ aynı olacak şekilde $h_{\mathbf{W},\mathbf{b}}(\mathbf{x}) \approx \mathbf{x}$ olarak ayarlamaktadır [5, 6]. Bir ÖK özdeşlik fonksiyonunu elde ederken çıkış etiketi olarak giriş veri kümesi kullanılmasından dolayı ÖK'ler danışmansız öğrenme modeli olarak tanımlanmaktadır. ÖK'lerin derin öğrenme yapısında temel kullanım amacı gizli katman çıkışlarından yeni öznitelikler elde etmektir [5, 6, 7].

ÖK temelde iki kısımdan oluşur bunlardan ilki kodlayıcı olarak adlandırılan gizli katmana giren ağırlıklar, ikincisi çözücü olarak adlandırılan gizli katmandan çıkan ağırlıklardır. ÖK'nin eğitimi tamamlandıktan sonra gizli katman yapısının çıkışı bir sonraki ÖK'ye ya da sınıflandırma birimi softmax katmanına giriş olarak verilmektedir. ÖK'nin gizli katmanındaki nöron sayısı giriş verisinin boyutundan yüksek ya da daha az olabilmektedir. Gizli katmandaki nöron sayısının daha az olduğu durumlarda sıkıştırılmış öznitelikler elde edilmektedir. [5, 6, 7].

ÖK'nin eğitimi aşağıda görülen amaç fonksiyonunun parametrelerinin optimize edilmesiyle gerçekleştirilir.

$$\frac{1}{T} \sum_{k=1}^T e_k^2 + \frac{\lambda}{2} \|\mathbf{W}\| + \beta \sum_{j=1}^s KL(\rho \parallel \hat{\rho}_j) \quad (1)$$

Burada modelin çıkışı ile arzu edilen çıkış arasındaki fark e_k aşağıdaki şekilde ifade edilir.

$$e_k = \|h_{\mathbf{w},\mathbf{b}}(\mathbf{x}^{(k)}) - x^{(k)}\| \quad (2)$$

ÖK yapısında, giriş verisi $\{x^{(1)}, x^{(2)}, \dots, x^{(T)}\}$ olmak üzere gizli katmandaki nöron sayısını s gizli katmandaki nöron sayısı ve T örneklem sayısını ifade etmektedir.

Denklem 1’de yer alan $\sum_{j=1}^s KL(\rho \parallel \hat{\rho}_j)$ ceza terimi Kullback–Leibler (KL) diverjansı olarak bilinmektedir. Burada yer alan seyreklik terimi ρ dışarıdan girilen ve genellikle sıfıra yakın bir değerdir. Seyreklik terimi gibi dışarıdan girilen ve genellikle 0,5 ile 5 arasında seçilen β ise KL’nin amaç fonksiyonundaki etkinlik değerini ayarlayan bir katsayıdır. Seyreklik terimi ρ ile j . nöronun gizli katman çıkışlarının ortalaması olan $\hat{\rho}_j$ arasındaki ilişkiyi tanımlayan Kullback–Leibler (KL) diverjansı Denklem 3’den hesaplanmaktadır [6].

$$KL(\rho \parallel \hat{\rho}_j) = \rho \log \frac{\rho}{\hat{\rho}_j} + (1 - \rho) \log \frac{1 - \rho}{1 - \hat{\rho}_j} \quad (3)$$

$$\hat{\rho}_j = \frac{1}{T} \sum_{i=1}^T f_j(\mathbf{x}(i); \mathbf{W}^{(1)}, \mathbf{b}^{(1)}) \quad (4)$$

Burada yer alan $(\hat{\rho}_j)$, tüm veri seti için j . nöronun ortalama aktivasyon değeri olarak tanımlanmaktadır. $\mathbf{W}^{(1)}, \mathbf{b}^{(1)}$ değerleri ise giriş ile gizli katman arasındaki yani kodlayıcı olarak adlandırılan kısımdaki ağırlık parametreleridir.

2.2. Softmax

Softmax, ikili sınıflandırma problemlerinde kullanılan lojistik regresyonun genişletilmiş hali olan çoklu sınıflandırıcıdır. Bu nedenle karşılaşılan problemdeki sınıf sayısına bakılmaksızın sağlıklı bir sınıflandırma yapabilmek için YÖK yapısından sonra sınıflandırma birimi olarak softmax kullanılmaktadır. Softmax katmanı YÖK yapısına kolay entegre ediliyor olmasından ve basit olmasından dolayı derin öğrenme yapılarında kullanılmaktadır [8].

2.3. YÖK Tabanlı Derin Sinir Ağının Eğitimi

Derin sinir ağı oluşturmak için ÖK’ler temel elemanlar olarak kullanılırlar. YÖK tabanlı bir derin sinir ağının eğitimi aşağıdaki gibi yapılır [5, 6].

1. Şekil 1a da görüldüğü üzere ÖK’nin ilk katmanı denklem 1’de görülen amaç fonksiyonun optimize edilmesiyle eğitilir. Burada daha öncede belirtildiği gibi giriş ve çıkışta aynı veri seti kullanılır.
2. İlk ÖK’nin gizli katman çıkışı ikinci ÖK’ye giriş olarak Şekil 1b’deki gibi verilir. Bu ikinci ÖK de tıpkı birinci ÖK gibi eğitilir.
3. Ulaşılan problemin doğasına göre istenilen sayıda ÖK eklenerek 2. adımda olduğu gibi eklenen ÖK eğitilir.
4. Son ÖK’nin gizli katman çıkışı softmax katmanına gönderilerek Şekil 1c’de olduğu gibi sınıflandırma yapılır.
5. Bu adımda tüm ÖK’lerin kodlayıcı kısımlarının birbirleriyle bağlanması sonucu oluşan Şekil 1d YÖK ve softmax katmanı birbirine bağlanır. Oluşan bu yapıya derin sinir ağı denir ve hassas eğitim denilen bu aşamada bu yapı tekrar optimize edilerek sonuca ulaşılır.

Çizelge 1. Tasarlanan YÖK’te kullanılan parametreler

Öğrenme	ÖK		OPD	PSD
		Aktivasyon Fonk.	Sigmoid	Sigmoid
Ön Öğrenme	ÖK	Nöron Sayısı	4	5
		Seyreklik Parametresi (ρ)	0.15	0.1
		Seyreklik Ceza Parametresi (β)	4	1
		Lamda (λ)	0.003	0.003
		İterasyon	400	400
		Sınıf Sayısı	2	2
	Softmax	Lamda (λ)	0.003	0.003
		İterasyon	400	400
Hassas Öğrenme	YÖK	Aktivasyon Fonk.	Sigmoid	Sigmoid
		Sınıf Sayısı	2	2
		Lamda (λ)	0.003	0.003
		İterasyon	400	400

1 ve 4 arasında olan eğitime ön eğitim adı verilmektedir. Ön eğitim ve hassas eğitim aşamalarında kullanılan tüm eğitim işlemlerinde L-BFGS [9] algoritması kullanılmıştır.

3. Deneysel Sonuçlar

Derin sinir ağı yapılarından YÖK’ün parkinson hastalığı teşhisindeki başarımı benzer nitelikteki iki adet veri seti ile ölçülmüştür. Veri setlerinden ilki “Oxford Parkinson’s Disease Detection” (OPD) veri setidir [2]. Bu veri setindeki veriler 31 denekten toplanmıştır. Bu deneklerden 23 tanesi parkinson hastalığına sahip deneklerden diğer 8 tanesi sağlıklı deneklerden oluşmaktadır. Bu veri seti 23 adet özneliğe sahiptir. Bu öznelikler deneklerin çeşitli kelimeleri söylerken kayıt edilen seslerinden çıkarılmıştır. Bu konuda literatürde ilk veri setine göre daha az kullanılan bir diğer set ise “Parkinson Speech Dataset with Multiple Types of Sound Recordings” (PSD) veri setidir [10]. PSD veri seti 20 sağlıklı 20 hastalıklı denekten oluşmaktadır. Deneklerin kayıt edilen ses sinyallerinden 26 adet öznelik çıkarılarak sınıflandırma yapılmıştır.

Parkinson hastalarının ses disfonilerinden yararlanılarak YÖK yapısı ile yapılan sınıflandırma sonuçları izleyen bölümde verilmiştir. Bunun yanında YÖK yapısı ile yapılan sınıflandırma literatürde sınıflandırma alanında başarıları yüksek olan ve yaygın olarak kullanılan sınıflandırma algoritmalarıyla karşılaştırılmıştır.


3.1. Simülasyon Sonuçları

Tüm simülasyonlar Intel i7 2600 3.4 Ghz işlemcili, 12 GB DDR3 RAM bellekli sistemde gerçekleştirilmiştir. Yöntemin başarımı ve yapılan simülasyonların objektif kriterlere dayandırılması amacıyla 10 kat çapraz doğrulama tekniği kullanılmıştır. Birinci veri setinde yani OPD’de yer alan 31 denekten 197 adet örneklem alınmıştır. İkinci veri seti PSD’deki 40 kişiden 1040 adet örneklem alınmıştır.

Simülasyonlarda kullanılan YÖK yapısı ile ilgili gerekli bilgiler Çizelge 1’de görülmektedir. İki veri setinde de tek katmanlı yapı kullanılmıştır. YÖK yapısının diğer yöntemlerle karşılaştırması standart sapmaları ile birlikte Çizelge 2’de verilmiştir.

Sonuçlar YÖK yapısının diğer yöntemlerden daha başarılı olduğunu açık şekilde göstermektedir. Her ne kadar iki veri seti aynı amaç için tasarlanmış ve neredeyse aynı öznelikler yardımıyla sınıflandırma yapılmışsa da elde edilen sonuçlar arasında ciddi bir fark olduğu göze çarpmaktadır. Bu farkın sebebi hastalık dereceleri, örneklem sayıları, deney ortamı, özelliğin nasıl çıkarıldığı gibi bir takım farklılıklardan kaynaklanmaktadır.

Çizelge 2 incelendiğinde OPD veri seti için tasarlanan YÖK



Şekil 1. Örnek YÖK yapısı (a) Özdevinimli kodlayıcı 1 (b) Özdevinimli kodlayıcı 2 (c) Softmax sınıflandırıcı (d) Eğitilmiş YÖK’ün son hali

Çizelge 2. Karşılaştırma Tablosu

Yöntem	Doğruluk Değeri (%)	
	OPD veri seti	PSD veri seti
Karar Ağacı	%86.63 ± 3.74	%64.14 ± 7.1
SVM	%86.10 ± 5.98	%66.06 ± 4.85
Navie Bayes	%70.21 ± 10.91	%59.28 ± 3.72
Önerilen YÖK	%87.66 ± 5.48	%66.39 ± 3.62

yapısı %87.66 doğruluk oranıyla ilk sırada yer almaktadır. PSD veri seti için bu oran %66.39’luk doğruluk değeriyle yine ilk sırada yer almaktadır. Bu doğruluk oranlarının yanında YÖK yapısının bir durum hariç diğer tüm durumlarda daha düşük bir standart sapma oranına sahip olduğu görülmektedir. Bu da bize YÖK yapısının daha istikrarlı sonuçlar üretebilen bir yapı olduğunu gösterir.

4. Sonuç

Bu çalışmada derin sinir ağı yapılarından yığılmış özdevinimli kodlayıcı kullanılarak parkinson hastalığı sınıflandırılmıştır. Parkinson hastalığı hastalardan alınan ses sinyallerinden çıkarılan bir takım öz niteliklerin sınıflandırma biriminde kullanılmasıyla disfonilerden teşhis edilebilmektedir. Parkinson hastalığı için bu tarz bir teşhis yönteminin YÖK yapısı yardımıyla yapılması yeni bir yaklaşımdır. YÖK yapısının performansı iki adet veri seti yardımıyla ölçülmüştür ve literatürde sıklıkla kullanılan diğer sınıflandırma yöntemlerinden daha başarılı sonuçlar üretmiştir. Bu başarılı sonuçlar

derin öğrenme yapılarının sınıflandırma için önemli bir araç olacağının göstergesidir.

5. Kaynaklar

- [1] Ögüt F., Yavuzer A., Uygur M., Akyürekli Ö ve Kalaycı T., “Parkinson Hastalığındaki Ses Değişiminin Değerlendirme Kriterleri”, *Ege Tıp Dergisi*, cilt. 39, no.1, 2000.
- [2] Little M. A., McSharry P. E., Roberts S. J., Costello D. A. ve Moroz I. M., “Exploiting nonlinear recurrence and fractal scaling properties for voice disorder detection”, *Biomed. Eng. Online.*, cilt. 6, sf. 23, 2007.
- [3] LeCun Y., Bengio Y. ve Hinton G., “Deep Learning”, *Nature*, cilt.521, sf.436-444, 2015.
- [4] Lichman, M. UCI Machine Learning Repository [http://archive.ics.uci.edu/ml]. Irvine, CA: University of California, School of Information and Computer Science, 2013.
- [5] Ranzato M., Poultney C., Chopra S. ve LeCun Y., “Efficient Learning of Sparse Representations with an Energy-Based Model”, *Proceedings of Neural Information and Processing Systems*, 2006.
- [6] Ngiam J., Coates A., Lahiri A., Prochnow B., Le Q. V. ve Ng A. Y., “On optimization methods for deep learning”, in: *Proceedings of the 28th International Conference on Machine Learning (ICML-11)*, 2011, sf. 265–272.

- [7] Bengio Y., “Practical recommendations for gradient-based training of deep architectures”, *Neural Networks: Tricks of the Trade*, Springer, sf. 437–478, 2012.
- [8] Zhang Y., Zhang E. ve Chen W. “Deep neural network for halftone image classification based on sparse auto-encoder”, *Engineering Applications of Artificial Intelligence*, cilt. 50, 2016.
- [9] Liu D.C. ve Nocedal J. “On the Limited Memory Method for Large Scale Optimization”, *Mathematical Programming B*, cilt. 45, no. 3, sf. 503-528, 1989.
- [10] Sakar B. E., Isenkul M. E., Sakar C.O., Sertbas A., Gorgen F., Delil S., Apaydin H., Kursun, O., “Collection and Analysis of a Parkinson Speech Dataset with Multiple Types of Sound Recordings”, *IEEE Journal of Biomedical and Health Informatics*, cilt. 17, no.4, sf. 828-834, 2013.