

Öz kodlayıcı kullanarak Elektrokardiyogram Sinyallerin Sınıflanması

Yücel KOÇYİĞİT^{1*}

¹Elektrik-Elektronik Müh. Bölümü /Manisa Celal Bayar Üniversitesi, Türkiye

*(yucel.kocyigit@cbu.edu.tr)

Özet – Elektrokardiyogram (EKG) sinyali temel olarak kalbin elektriksel aktivitesine karşılık gelir. Literatürde EKG sinyali, kalp anormalliklerini teşhis etmek, duyu tanıma ve biyometrik tanımlama gibi çeşitli amaçlar için analiz edilmiş ve kullanılmıştır. EKG analizi (analizin türüne bağlı olarak), ön işleme, öznelik çıkarma, öznelik seçimi, öznelik dönüşümü ve sınıflandırma gibi birkaç adım içerebilir. Her bir adımı gerçekleştirmek, ilgili analiz için çok önemlidir. Bu çalışmada öznelik çıkarımı için öz kodlayıcı derin öğrenme ağı; sınıflandırma için ise K En yakın komşuluk (KNN), Destek Vektör Makineleri (SVM) ve Yapay Sinir Ağları (ANN) yöntemleri kullanılmış ve en yüksek Doğruluk %72,16 olarak elde edilmiştir.

Anahtar Kelimeler – Elektrokardiyogram, Öznelik Çıkartma, Öz Kodlayıcı, Sınıflama

I. GİRİŞ

Kalbe bağlı hastalıkları dünyada milyonlarca erken ölüme neden olmaktadır [1]. Bu nedenle kalp sağlığın korunması gereken hayati bir organdır. Elektrokardiyogram (EKG) kalpteki elektriksel aktiviteyi gösteren işarettir. EKG'den alınan ham sinyal, kalp atış hızına göre kalp sinyalini tanımlamak ve sınıflandırmak için kullanılır. Kaydedilen her EKG sinyalinde kalp sinyallerinin normal mi yoksa anormal mi olduğu analiz edilir. Düzenli bir sinyalin genliğindeki anormal şekil veya düzensiz zaman aralığı aritmileri gösterir. EKG sinyallerindeki aritmilerin otomatik olarak tespit edilebilmesi için adımlar öznelik çıkarımı ve sinyal sınıflandırması olmak üzere ikiye ayrılır. Ancak EKG sinyallerinin de gürültüden arınmış olduğu tespit edilemez. Bu nedenle özneliklerin çıkarılmasından önce ham sinyal ilk olarak ön işleme aşamasına girer. Gürültüyü ortadan kaldırmak için ön işleme aşamasında çeşitli filtreleme prosedürleriyle ham EKG sinyali filtrelenir. Filtrelenen sinyal gürültüden arındırıldıktan sonra sinyalden öznelik çıkarılır. Hastaların doğru teşhis edilmesine yardımcı olması

amacıyla çıkarılan özneliklere göre EKG sinyali sınıflandırma yöntemiyle sınıflandırılır.

Yapılan çalışmalarda, EKG sinyallerini kesin olarak tanımlamak için çeşitli analiz teknikleri ve algoritmalar kullanılmıştır. Bu teknikler, dalga şekli fonksiyonlarını [2], dalgacık tabanlı öznelik çıkarımlarını [3], frekans tabanlı öznelik çıkarımını [4] ve istatistiksel özellikleri [5] içerir. Çıkarılan bu öznelikleri sınıflandırmak için kullanılan yöntemler arasında destek vektör makineleri [6], karar ağaçları [7], yapay sinir ağları [8], K en yakın komşuluk [9] yer alır.


Bu çalışma, üç farklı sınıfa ait EKG sinyallerini sınıflamayı amaçlamaktadır. Bunun için yeni bir yaklaşım sergileyerek önce Öz kodlayıcı yöntemi ile öznelikler elde edilmiş; sonra Destek Vektör Makineleri (SVM), Yapay Sinir Ağları (ANN) ve K En yakın komşuluk (KNN) gibi farklı makine öğrenmesi yöntemleri ile sınıflama yapılmıştır.

II. MATERYAL VE YÖNTEM

A. Veri Seti

Bu çalışmada, üç insan grubundan veya sınıftan elde edilen EKG verileri kullanılıyor:

kardiyak aritmisi olan kişiler, konjestif kalp yetmezliği olan kişiler ve normal sinüs ritmi olan kişiler. Üç PhysioNet veri tabanından alınan 162 adet EKG kaydı kullanıldı [10]: MIT-BIH Arrhythmia Database [11][12], MIT-BIH Normal Sinus Rhythm Database [11] ve The BIDMC Congestive Heart Failure Database [11] (Şekil 1). Toplamda ritim bozukluğu olan kişilerden 96, konjestif kalp yetmezliği olan kişilerden 30 ve normal sinüs ritmi olan kişilerden 36 kayıt bulunmaktadır. Amaç, aritmi (ARR), konjestif kalp yetmezliği (CHF) ve normal sinüs ritmini (NSR) ayırt edecek bir sınıflandırıcı bulmaktır.

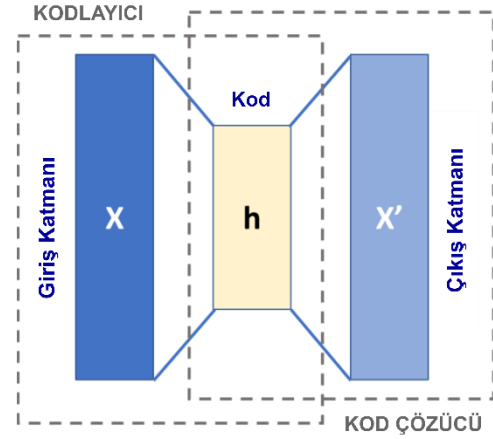


Şekil 1. ARR, CHF ve NSR'ye ait EKG kayıtları

A. Öz kodlayıcı (Auto Encoder) yöntemi

Öz kodlayıcı aldığı girişi kendi çıkışına kopyalamak amacıyla eğitilen bir sinir ağıdır. Temel olarak verilerin boyutunun azaltılmasında sıklıkla kullanılır. Öz kodlayıcı ileri beslemeli Yapay Sinir Ağlarının özel bir türüdür. Auto-Encoder girişi temsil eden bir gizli katmana

sahiptir. Basit bir Öz kodlayıcı, kodlayıcı (encoder) ve kod çözücü (decoder) olmak üzere iki ana yapıdan oluşur (Şekil 2).



Şekil 2. Öz kodlayıcıya ait yapı [13]

Datayı yeniden kurarken Denklem 1'deki kayıp (loss) fonksiyonunu kullanır ve hata oranını düşürmek için yapay sinir ağlarındaki gibi ağırlıkları (W) gradyanlarla günceller. Böylece x' çıkışı, x girişine yaklaşmış olur ve kayıp fonksiyonunu minimize eder.

$$\mathcal{L}(x, x') = \|x - x'\|^2 \quad (1)$$

x' ve h 'yi bulmak için kullanılan formüller Denklem 2 ve Denklem 3'teki gibidir. İleri Beslemeli Sinir Ağlarının çalışma yapısı ile benzerlik gösterir. Denklemdeki σ aktivasyon fonksiyonunu temsil etmektedir. Denklem 2 ile gizli katmandaki değerler (h) bulunurken, Denklem 3 ile h 'yi kullanarak çıkış katmanındaki değerler (x') hesaplanır.

$$h = \sigma(Wx + b) \quad (2)$$

$$x' = \sigma'(W'h + b') \quad (3)$$

B. Sınıflandırıcıların Performans Değerlendirmesi

Şekil 3'te verildiği gibi sınıflama işlemlerinde performans ölçütü olarak kullanılan karışıklık matrisi ikili bir sınıflandırmada dört olası sonuç vardır; gerçek pozitif (TP), pozitif örneklerin doğru şekilde sınıflandırılma sayısını, yanlış negatif (FN) ise pozitif örneklerin yanlış şekilde sınıflandırılma sayısını gösterir. Gerçek negatif (TN), negatif

örneklerin doğru şekilde sınıflandırılma sayısını, yanlış pozitif (FP) ise negatif örneklerin yanlış şekilde sınıflandırılma sayısını verir.

		Tahmin Edilen Sınıf	
		Tahmin Edilen Pozitifler	Tahmin Edilen Negatifler
Gerçek Sınıf	Gerçek Pozitifler	TP	FN
	Gerçek Negatifler	FP	TN

Şekil 3. Karışıklık matrisi

Sınıflandırıcı performansını değerlendirmek için genellikle doğruluk ölçütü kullanılır. Fakat bu ölçüt, performans değerlendirmede tek başına yanıltıcı olabilir. Bu sebeple bu ölçüt yanında, kesinlik (precision), anma (recall) ve F1 skoru, sınıflandırıcının performansını daha nesnel bir şekilde değerlendirmek için kullanılmaktadır.

$$\text{Doğruluk} = \frac{TP+TN}{TP+TN+FP+FN}$$

$$\text{Kesinlik} = \frac{TP}{TP+FP}$$

$$\text{Anma} = \frac{TP}{TP+FN}$$

$$\text{F1-Skor} = 2 * \text{Kesinlik} * \text{Anma} / (\text{Kesinlik} + \text{Anma})$$

burada TP, TN, FP ve FN sırasıyla gerçek pozitifleri, gerçek negatifleri, yanlış pozitifleri ve yanlış negatifleri gösterir.

III. BULGULAR

Bu çalışmada biri normal ve ikisi hasta olmak üzere üç tip kalp sinyalinin Derin Öğrenme algoritmalarından olan Öz kodlayıcı ağı yardımı ile öznelikleri çıkarılarak sınıflanması amaçlanmıştır. Bu amaçla üç PhysioNet veri tabanından alınan 162 adet EKG kaydı kullanıldı [10]. Bu kayıtlar eğitim ve test aşamalarında kullanılmak üzere sırasıyla %70-%30 oranında ayrıldı.

Çalışmanın temel yaklaşımı, segmentasyon işleminde alınacak katsayı miktarına göre Öz kodlayıcının giriş düğümlerini belirlemek ve gizli katmandaki düğüm sayılarının miktarına göre de hem boyut azaltmak hem de katman çıkışlarını öznelik olarak kullanmaktır. Ağın yapısı kodlayıcı ve şifre çözücü olduğundan gizli katmandaki düğüm çıkışları aynı zamanda sinyallere ait öznelikleri de barındıracaktır. Farklı giriş ve gizli düğümü sayıları denenmiş; bu çalışmada en başarılı bulunan yapının sonuçları verilmiştir.

Öncelikle her bir ham EKG sinyali 200 katsayıdan oluşan segmentasyon işlemine tabi tutuldu. Böylece eğitim aşamasında aritmi (ARR) tipi için 21909 adet, konjestif kalp yetmezliği (CHF) için 6867 adet ve normal sinüs ritmi (NSR) için 8175 adet EKG örneği; test için ise ARR için 9483 adet, CHF için 2943 adet ve NSR için 3597 adet EKG örneği elde edildi. Öznelik çıkartmak amacıyla 200 giriş düğümüne sahip Öz kodlayıcı ağ girişine eğitime ait örnekler uygulanırken Öz kodlayıcı ağın gizli katmanındaki düğüm sayısı 30 seçilerek katman çıkışındaki katsayılar EKG örneklerinin öznelikleri olarak alındı. Test için kullanılacak örneklere ait öznelikler, eğitilmiş Öz kodlayıcı ağı uygulanarak elde edildi.

Sonrasında eğitime ait örnekler, KNN, SVM ve ANN sınıflandırıcılara uygulanarak sınıflandırıcı eğitimi gerçekleştirildi. Eğitimin daha robust olması için 5 kat çapraz geçirme (cross validation) yapıldı. Sınıflayıcılara ait eğitim doğruluk oranları Tablo 1’de verilmiştir. Buna göre KNN sınıflandırıcı en başarılı eğitim işlemini gerçekleştirmiştir. Şekil 4’te KNN sınıflandırıcısının eğitimi sonucunda bulunan karışıklık matrisi görülmektedir.

Eğitimlerin ardından sınıflandırıcılara uygulanan test örneklerinin performansları Tablo 2, 3 ve 4’te görülmektedir. Sınıflayıcılara ait test doğruluk oranları Tablo 5’te verilmiştir. Şekil 5’te ise KNN sınıflandırıcısının test sonucunda bulunan karışıklık matrisi görülmektedir.

True Class	ARR	20220	654	1035
	CHF	646	6029	192
	NSR	736	150	7289
		ARR	CHF	NSR
		Predicted Class		

Şekil 4. KNN sınıflandırıcısının eğitimine ait karışıklık matrisi

True Class	ARR	7599	891	993
	CHF	1750	964	229
	NSR	608	162	2827
		ARR	CHF	NSR
		Predicted Class		

Şekil 5. KNN sınıflandırıcısının test örneklerine ait karışıklık matrisi

Tablo 1. Sınıflandırıcıların eğitim doğruluk oranları

	KNN	SVM	ANN
Doğruluk (%)	90,8	83,2	84,6

Tablo 2. KNN sınıflandırıcı performans değerleri

	Kesinlik	Anma	F1 skor
ARR	76,32	80,13	78,18
CHF	47,79	32,76	38,87
NSR	69,82	78,59	73,95

Tablo 3. SVM sınıflandırıcı performans değerleri

	Kesinlik	Anma	F1 skor
ARR	68,21	91,80	78,26
CHF	78,57	20,93	33,06
NSR	73,55	50,63	59,97

Tablo 4. ANN sınıflandırıcı performans değerleri

	Kesinlik	Anma	F1 skor
ARR	74,88	82,41	78,46
CHF	56,74	43,19	49,05
NSR	73,99	68,84	71,32

Tablo 5. Sınıflandırıcıların test doğruluk oranları

	KNN	SVM	ANN
Doğruluk (%)	71,1	69,6	72,16

Tablolarda ARR ve NSR ler için yüksek oranda doğru sınıflandığı görülürken CHF için oldukça kötü bir performans ortaya çıkmıştır. Sınıflandırıcılar arasında en iyi performans genel olarak ANN sınıflandırıcısına aittir.

Tüm bu işlemler İ7-7700 HQ işlemci, Nvidia GTX 1060 ekran kartı ve 16GB RAM donanımına sahip dizüstü bilgisayarda MATLAB ortamında gerçekleştirilmiştir.

IV. TARTIŞMA

Öz kodlayıcı ağı girişi çıkışa kopyaladığından dolayı gizli katman çıkışlarının uygun öznelikler olacağı düşünülmüştür. Nitekim bulunan öznelikleri kullanarak eğitilen KNN yönteminde başarı %90,8 bulunmuştur. Ancak bu başarı test verilerine yansımamış ve %70 civarında kalmıştır. Bunun sebebi olarak birkaç madde sayılabilir; birincisi, verilerin aynı veri tabanından olmayıp birbirinden farklı derivasyonlara sahip olması; ikincisi, segmentasyon işleminin tek bir atım için yapılmayıp sabit sayıda katsayı alınması; üçüncüsü, EKG kayıtlarındaki atımların herbirinin yukarıda anılan hastalıklara ait olduğunun varsayılması -ki aritmi olanlar içinde normal atımlar da yer alıyor- nedenleri sayılabilir. Özellikle üçüncü nedenden dolayı hatalı bir sınıflandırma yapılmış sonucuna ulaşılmaktadır.

Literatürdeki farklı öznelik çıkartma ve makine öğrenmesi yöntemlerini kullanarak yapılan çalışmalara göre bu çalışmanın başarısı oldukça düşük çıkmıştır.

V. SONUÇLAR

Bu çalışmada biri normal ve ikisi hasta olmak üzere üç tip kalp sinyalinin Derin Öğrenme algoritmalarından olan Öz kodlayıcı ağı yardımı ile öznelikleri çıkarılarak sınıflanması amaçlanmıştır. Bulunan özneliklerin performansları, farklı sınıflandırıcılar kullanılarak görülmüştür. Bulunan sonuçlar literatürdeki diğer çalışmaların epey gerisinde kalmakla birlikte EKG kayıtlarının atımlara göre segmente edilmesi ve atımların doğru etiketlenmesi durumunda başarının daha yüksek olacağı düşünülmektedir.

KAYNAKLAR

- [1] <https://www.who.int/health-topics/cardiovascular-diseases>
- [2] Ye, C., Kumar, B. V., & Coimbra, M. T., "Heartbeat classification using morphological and dynamic features of ECG signals," IEEE Transactions on Biomedical Engineering, 59(10), 2930-2941, 2012.
- [3] Li, T., & Zhou, M., "ECG classification using wavelet packet entropy and random forests", Entropy, 18(8), 285, 2016.
- [4] Kayıkcıoğlu, I., Akdeniz, F., Köse, C., & Kayıkcıoğlu, T., "Time-frequency approach to ECG classification of myocardial infarction", Computers & Electrical Engineering, 84, 106621, 2020.
- [5] Afkhami, R. G., Azarnia, G., & Tinati, M. A., "Cardiac arrhythmia classification using statistical and mixture modeling features of ECG signals", Pattern Recognition Letters, 70, 45-51, 2016.

- [6] Rajesh, K. N., & Dhuli, R., “Classification of ECG heartbeats using nonlinear decomposition methods and support vector machine”, *Computers in biology and medicine*, 87, 271-284, 2017.
- [7] Zhang, L., Peng, H., & Yu, C., “An approach for ECG classification based on wavelet feature extraction and decision tree”, In 2010 international conference on wireless communications & signal processing (WCSP) (pp. 1-4). IEEE, 2010.
- [8] Silipo, R., & Marchesi, C., “Artificial neural networks for automatic ECG analysis”, *IEEE transactions on signal processing*, 46(5), 1417-1425, 1998.
- [9] Saini, R., Bindal, N., & Bansal, P., “Classification of heart diseases from ECG signals using wavelet transform and kNN classifier”, In *International Conference on Computing, Communication & Automation* (pp. 1208-1215). IEEE, May 2015.
- [10] Wayne King (2023) *mathworks/physionet_ECG_data* (https://github.com/mathworks/physionet_ECG_data), GitHub. Retrieved September 21, 2023.
- [11] Goldberger AL, Amaral LAN, Glass L, Hausdorff JM, Ivanov PCh, Mark RG, Mietus JE, Moody GB, Peng C-K, Stanley HE. *PhysioBank, PhysioToolkit, and PhysioNet: Components of a New Research Resource for Complex Physiologic Signals. Circulation*. Vol. 101, No. 23, 13 June 2000, pp. e215-e220.
- [12] Moody GB, Mark RG. *The impact of the MIT-BIH Arrhythmia Database. IEEE Eng in Med and Biol* 20(3):45-50 (May-June 2001)
- [13] The wikipedia website. [Online]. Available <https://en.wikipedia.org/wiki/Autoencoder>