

Anormal Kalp Seslerinin Sınıflandırıcı Toplulukları ile Tespit Edilmesi

Abnormal Heart Sound Detection Using Ensemble Classifiers

Hasan Zan

Meslek Yüksekokulu
Mardin Artuklu Üniversitesi
Mardin, Türkiye
hasanzan@artuklu.edu.tr

Abdulnasır Yıldız

Elektrik – Elektronik Mühendisliği Bölümü
Dicle Üniversitesi
Diyarbakır, Türkiye
abnaysil@dicle.edu.tr

Özet—Fonokardiyogram (PCG) sinyali kalbin genel sağlık durumunu değerlendirmek, kardiyovasküler hastalıkları tespit etmek için kullanılan ve ayakta uygulanan bir teşhis yöntemidir. Bu çalışmanın amacı farklı veri bankalarından alınan ve farklı şekilde kaydedilen kayıtları normal ve anormal şeklinde otomatik olarak sınıflandıran bir yöntemin geliştirilmesidir. Bunun için, iki farklı veri bankasından alınan kayıtların çeşitli zaman ve frekans özellikleri çıkarıldıktan sonra ön bir sınıflandırmaya tabi tutularak kayıtların hangi veri bankasına ait olduğu tespit edildi. Sınıflandırılan kayıtların zaman, frekans ve zaman-frekans özellikleri elde edildikten sonra bu özellikler eğitim veri setiyle ayrı ayrı olarak eğitilen dört farklı sınıflandırıcı topluluğunun girişine verildi. Son sınıflandırma kuralıyla beraber önerilen algoritma %98,9'luk doğruluk, %93,75'lik duyarlılık ve %99,5'lik bir hassasiyet elde etmiştir.

Anahtar Kelimeler—PCG, kalp sesi, sınıflandırma, sınıflandırıcı toplulukları.

Abstract—Phonocardiogram is used for ambulatory diagnostic to assess health status of heart and detect cardiovascular disease. The goal of this study is to develop automatic classification method of PCG recordings collected from different databases and recorded in a different way. For this purpose, after various time and frequency domain features are extracted from PCG recordings obtained from two databases, recordings are subjected to pre-classification in order determine which database they are obtained from. Before final classification, various time, frequency and time-frequency domain features of classified recordings are extracted. These features are fed into four different classification ensembles trained with training dataset. With final decision rule, proposed algorithm achieved an accuracy of 98.9%, a sensitivity of 93.75% and a specificity of 99.5%.

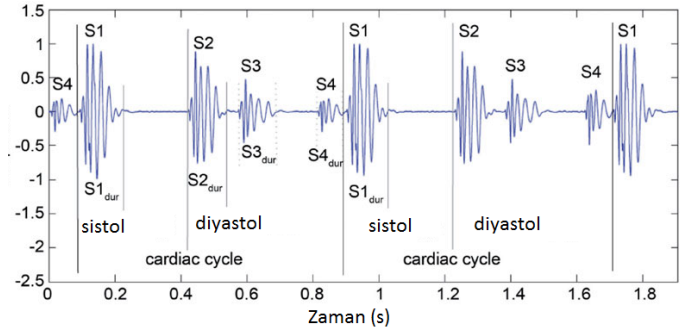
Index Terms—PCG, heart sound, classification, classification ensembles.

I. GİRİŞ

Kalbin stetoskop ile dinlenmesi hızlı bir şekilde yapılan ve uygun maliyetli teşhis yöntemlerinden bir tanesidir. Bu yöntem

kalbin genel sağlık durumuyla ilgili ilk bir değerlendirme sağlar ve çeşitli kardiyovasküler hastalığın tespitinde kullanılır [1]. Kalp sesi (veya fonokardiyogram) ayrıca sonraki medikal değerlendirmeler için ilave teşhis yöntemleri de sunabilir.

Kalp sesinin pratik uygulamaları muayeneyi yapan hekimin kavrama becerilerine ve uzmanlığına bağlıdır. Duyulabilen frekans aralığı, çevresel gürültü ve kayıt bölgelerindeki farklılıklar gibi sınırlamalar bu testin diğer başlıca dezavantajlarıdır. Bu teşhis yönteminin dezavantajlarının üstesinden gelmek için kalp sesinin otomatik analizi için pek çok teknik önerilmiştir [2-5].



Şekil 1. Tipik bir PCG sinyali.

Fonokardiyogram (PCG) sinyal analizi iki temel gruba ayrılabilir. İlk yaklaşım tipi geçici segmentasyona dayanır, yani kalp döngüsünün tanımlanması ve temel kalp sesleri olan birinci (S1, sistolün başlangıcı) ile ikinci (S2, sistolün sonu) kalp seslerinin pozisyonunun belirlenmesi. S1'in ve S2'nin uzunluk ve yoğunluğundaki farklılıklar kalpteki anormalliklerin kesin bir işareti olarak görülür.

Shannon enerji [2], Shannon entropi [3], Hilbert-Huang dönüşümü [4] ve otokorelasyon [5] gibi farklı zarf çıkarma yöntemleri kullanılan pek çok çalışma PCG segmentasyonu için yapılmıştır. Bir sinyalin zarfı, gürültüleri azaltarak sinyalin düşük yoğunluklu bileşenlerini kuvvetlendirir. Bazı segmentasyon yaklaşımlarında S1 ve S2 seslerinin frekans karakteristiğini elde etmek için dalgacık dönüşümü tabanlı zarf

çıkarma yöntemleri kullanılmıştır. İkinci tip yaklaşımlarda ise anormal PCG kayıtları segmentasyon yapılmadan tespit edilmiştir [7,8]. Pek çok çalışmada yapay sinir ağları, vektör destek makinası, karar ağaçları ve k en yakın komşular (kNN) gibi sınıflandırıcılar, girişlerine sinyallerin zaman, frekans, dalgaçık dönüşümü ve karmaşıklık temelli özellikleri verilerek kullanılmıştır.

Bu çalışmada her iki yaklaşım tipi aynı anda kullanılmıştır. Bu yaklaşımın altında yatan temel motivasyon ise segmentasyon yapmadan kalp sesinin tamamında yayılan anormallikler ile sadece kalp sesinin bir bölgesinde olan anormalliklerin karakteristiklerinin bir arada kullanılmasıdır. Bu çalışmanın temel katkısı ise farklı şekilde elde edilen kayıtların farklı özellikler göstermesinden dolayı nihai sınıflandırma yapılmadan önce kayıtların kaynağına göre sınıflandırılmasıdır.

II. MATERYAL VE METOT

A. Materyal

2016 PhisioNet yarışmasının veri bankası üç kütadan, yedi ülkeden, yedi araştırmacı takım tarafından toplanan toplam sekiz veri bankasını bir araya getirmektedir. Bu veri bankası, 1072 denekten alınan toplam 41517 kayıttan oluşmakla beraber altı veri bankasına (a, b, c, d, e ve f) ait 3240 tanesi yarışmanın web sitesinden indirilebilir. Yüksek lisan tezinin bir parçası olan bu çalışmada toplamda 2255 tane kayda sahip veri bankası “e” ve veri bankası “f” kullanılmıştır. Bu kayıtlar beşli çapraz doğrulama ile hem eğitimde aşamasında hem de test aşamasında kullanılmıştır. Veriler hakkında ayrıntılı bilgi [8]’de yer almaktadır.

B. Algoritmanın Yapısı

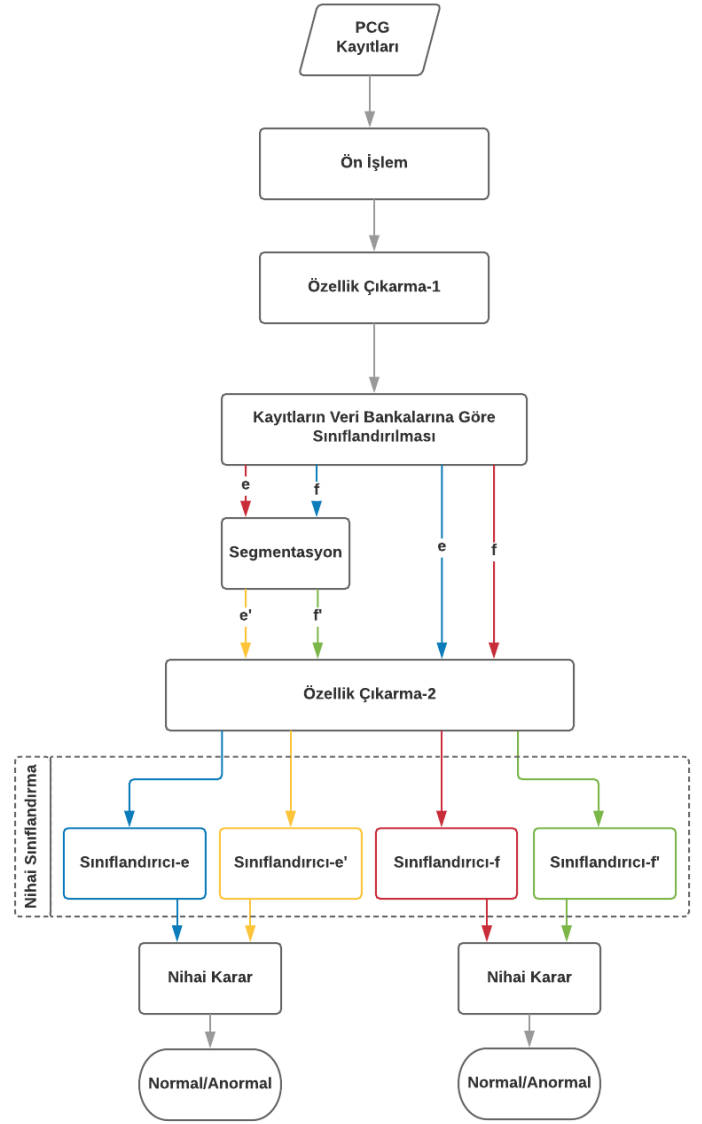
PCG kayıtlarını sınıflandırmak için önerilen algoritmanın yapısı Şekil 1 de yer almaktadır.

1) Ön İşlem

Önişlem aşamasında sırasıyla, PCG kayıtlarındaki gürültüden kaynaklı sivri uçları yok etmek amacıyla aşağıdaki işlemler uygulanmış ve daha sonra minmaks normalizasyonu yapılmıştır.

- 1) Sinyal 500 ms’lik bölütlere ayrılır.
- 2) Her bölütteki maksimum mutlak genlik (MMG) bulunur.
- 3) Eğer en az bir tane MMG, tüm MMG’lerin medyan değerinin üç katını geçerse a’den f’ye kadar olan işlemler uygulanır, yoksa dördüncü adıma geçilir.
 - a) En yüksek MMG değerine sahip bölüt seçilir.
 - b) Seçilen bölütte sivri ucun tepe noktası MMG’nin konumu olarak tanımlanır.
 - c) Sivri ucun başlangıç noktası, MMG’den önce sinyalin en en sıfırdan geçtiği nokta olarak tanımlanır.
 - d) Sivri ucun son bulunduğu nokta, MMG’den sonra sinyalin ilk defa sıfırdan geçtiği nokta olarak tanımlanır.
 - e) Tanımlanan sivri uç sıfırlar ile değiştirilir.

İşlem tamamlanır.



Şekil 2. Önerilen algoritmanın blok şeması.

2) Özellik Çıkarma -1

Algoritmanın bu adımında veri bankası sınıflandırıcısının girişine verilmek üzere sinyalin zaman ve frekans uzayına ait özellikler çıkarılmıştır. Sinyal ve sinyalin 0-200 ile 800-1000 Hz aralığındaki minimum, maksimum, ortalama, median, basıklık, çarpıklık, etkin değeri ve etkin değerin maksimum değere oranı olmak üzere toplam 24 özellik çıkarılmıştır.


3) Segmentasyon

Literatürde en başarılı sonuçları veren Schmidt yönteminin gelişmiş bir versiyonu olan Springer’in saklı Markov modeli temelli segmentasyon yöntemi kullanılmıştır [9].

4) Veri Bankası Sınıflandırması

Kayıtların alındığı veri bankasına göre sınıflandırılması amacıyla Matlab r2017b programındaki sınıflandırıcı toplulukları ve bu sınıflandırıcının parametrelerini ayarlamak için de Bayesian Optimizasyonu kullanıldı. Karar ağaçları topluluğundaki zayıf sınıflandırıcı olarak seçilirken topluluğu oluşturmak için boosting algoritma ailesinden AdaBoost

algoritması kullanıldı. Bu aşamadaki doğruluk %98,6 olarak elde edildi.



Şekil 3. Boosting algoritma ailesinin blok şeması.

5) Özellik Çıkarma-2

Bu aşamada iki alt kısımdan oluşmaktadır. Birincisi alt kalp seslerine ayrılmamış, yani segmentasyon yapılmamış sinyalin özelliklerinin çıkarılmasıdır. Bunlar;

- Sinyalin zaman uzayına ait etkin değer, sıfırdan geçme oranı, basıklık, çarpıklık, ortalama değer, standart sapma, varyans, entropi, maksimum ve medyan değer (10 adet özellik),
- Sinyalin hızlı Fourier dönüşümü ile elde edilen frekans uzayına ait etkin değer, sıfırdan geçme oranı, basıklık, çarpıklık, ortalama değer, standart sapma, varyans, entropi, maksimum ve medyan değer (10 adet özellik),
- "Db4" dalgacığı ile elde edilen üçüncü düzey dalgacık dönüşümünün yaklaşım katsayılarının etkin değeri, sıfırdan geçme oranı, basıklığı, çarpıklığı, ortalama değeri, standart sapması, varyansı, entropisi, maksimum ve medyan değeri (10 adet özellik),
- "Db4" dalgacığı ile elde edilen dördüncü düzey dalgacık dönüşümünün yaklaşım katsayılarının etkin değeri, sıfırdan geçme oranı, basıklığı, çarpıklığı, ortalama değeri, standart sapması, varyansı, entropisi, maksimum ve medyan değeri (10 adet özellik),
- "Db4" dalgacığı ile elde edilen üçüncü düzey dalgacık dönüşümünün detay katsayılarının etkin değeri, sıfırdan geçme oranı, basıklığı, çarpıklığı, ortalama değeri, standart sapması, varyansı, entropisi, maksimum ve medyan değeri (10 adet özellik),
- "Db4" dalgacığı ile elde edilen dördüncü düzey dalgacık dönüşümünün detay katsayılarının etkin değeri, sıfırdan geçme oranı, basıklığı, çarpıklığı, ortalama değeri, standart sapması, varyansı, entropisi, maksimum ve medyan değeri (10 adet özellik),
- Mel frekansı kepstrem katsayılarına ait etkin değer, sıfırdan geçme oranı, basıklık, çarpıklık, ortalama değer, standart sapma, varyans, entropi, maksimum ve medyan değer (14 × 10 = 140 adet),

olmak üzere toplamda 200 adet özellik elde edildi. Çıkarılan özellik sayısını azaltmak ve gereksiz özelliklerden kurtulmak amacıyla Matlab'ta yer alan ve deneme yanılma yolu ile özellik seçmeye yarayan algoritma kullanılarak veri bankası "e" için özellik sayısı 178, veri bankası "f" için 170'e indirilmiştir.

İkinci kısım ise segmentasyon yapılmış sinyalin özelliklerinin çıkarılmasıdır. Bunlar;

- Her bir bölgenin uzunluğunun ve uzunluklarının birbirine oranının ortalama ve standart sapması (20 adet özellik).
- Her bölgedeki sinyalin genliğinin etkin değeri, basıklığı, ortalaması, standart sapması, varyansı, entropisi ve maksimum değeri (4 bölge × 7 özellik = 28 adet özellik).
- Her bir bölgenin mel frekansı kepstrem katsayılarının etkin değeri, basıklığı, çarpıklığı, ortalaması, standart sapması ve varyansı (4 bölge × 14 katsayı × 6 özellik = 336 adet özellik).

olmak üzere toplamda 384 adet özellik elde edildi. Çıkarılan özellik sayısını azaltmak ve gereksiz özelliklerden kurtulmak amacıyla Matlab'ta yer alan ve deneme yanılma yolu ile özellik seçmeye yarayan algoritma kullanılarak veri bankası "e" için özellik sayısı 310'na, veri bankası "f" için 305'e indirilmiştir.

6) Nihai Sınıflandırma

PCG kayıtlarının normal veya anormal şeklinde sınıflandırılması amacıyla toplamda dört farklı özellik matrisi için dört adet sınıflandırıcı topluluğu ve bu sınıflandırıcıların parametrelerini ayarlamak için de Bayesian Optimizasyonu kullanıldı. Karar ağaçları topluluklardaki zayıf sınıflandırıcı olarak seçilirken topluluğu oluşturmak için farklı algoritmalar kullanıldı.

TABLO I. NİHAİ SINIFLANDIRICI ALGORİTMALARI

Veri Bankası	Özellik Matrisi	Seçilen Algoritma
e	Segmentasyon yok (e)	GentleBoost
	Segmentasyon var (e')	AdaBoost
f	Segmentasyon yok (f)	Bag
	Segmentasyon var (f')	GentleBoost

7) Nihai Karar

Bu aşamada algoritma sınıflandırıcılardan elde edilen sonuca göre karar vermektedir. Her bir veri bankasına ait iki sınıflandırıcıdan herhangi bir tanesi PCG kaydının anormal olduğu sonucuna varırsa o kayıt anormal olarak etiketlenir. Eğer sınıflandırıcıların ikisi de kaydın normal olduğu sonucuna varır ise o kayıt normal olarak etiketlenir.

III. SONUÇLAR

Oluşturulan algoritmanın test edilmesi amacıyla PCG kayıtlarından beş kopya oluşturulmuş ve bu kopyaların her biri de beş parçaya ayrılmıştır. Bu parçalardan dört tanesi algoritmayı eğitmek bir tanesi ise algoritmayı test etmek için kullanılmıştır. Eğitim ve test işlemleri beş defa tekrarlanarak tüm verinin hem eğitim için hem de test için kullanılması sağlanmıştır. Elde edilen sonuçlar ortalamalar alınarak elde edilmiştir. Sonuçların başarısını ölçmek doğruluk, duyarlılık ve hassasiyet parametreleri seçilmiştir.

$$\text{duyarlılık} = \frac{GP}{P} = \frac{GP}{GP+YN} \quad (1)$$

$$\text{hassasiyet} = \frac{GN}{N} = \frac{GP}{GN+YP} \quad (2)$$

Burada,

P: Pozitif, tüm hasta vakaların sayısı,

N: Negatif, tüm sağlıklı vakaların sayısı,

GP: Gerçek pozitif, doğru şekilde hasta olarak tespit edilenlerin sayısı,

YP: Yanlış pozitif, yanlış şekilde hasta olarak tespit edilenlerin sayısı,

GN: Doğru negatif, doğru şekilde sağlıklı olarak tespit edilenlerin sayısı,

YN: Yanlış negatif, yanlış şekilde sağlıklı olarak tespit edilenlerin sayısı.

TABLO II. ALGORİTMANIN BEŞLİ ÇAPRAZ DOĞRULAMAYA GÖRE SINIFLANDIRMA PERFORMANSI

Veri Bankası	Doğruluk (%)	Duyarlılık (%)	Hassasiyet (%)
e	99,53	95,12	100
f	86,96	85,71	87,5
Toplam	98,90	93,75	99,51

Bu çalışmada anormal farklı veri bankalarından ve farklı şekilde elde edilen PCG kayıtlarının hem segmentasyon yaparak hem de segmentasyon yapmadan anormal ve normal şeklinde sınıflandırmaya yarayan bir algoritma önerilmiştir. Elde edilen sonuçlar algoritmanın başarılı bir şekilde sınıflandırma yapabildiğini göstermektedir.

Gelecekte daha geniş veri bankaları kullanılarak eğitilecek olan ve telefon veya benzeri taşınabilir bir aygıtta çalışan algoritmalar sayesinde her kalp hastalığının çok yüksek bir doğrulukla kısa sürede ve basit bir şekilde tespit edilmesi mümkün olabilir.

TEŞEKKÜR

Bu tez çalışması, Dicle Üniversitesi Bilimsel Araştırma Projeleri (DÜBAP) Koordinatörlüğü tarafından 17.019 proje numarası ile desteklenmiştir.

REFERANSLAR

- [1] M. E. McConnell, *Pediatric Heart Sounds*, Springer Science & Business Media, 2008.
- [2] C. C. Balili, M. Sobrepena, P. C. Naval, "Classification of heart sounds using discrete and continuous wavelet transform and random forests," *3rd IAPR Asian Conference on Pattern Recognition*, 2015.
- [3] A. Moukadem, A. Dieterlen, C. Brandt, "Shannon Entropy based on the S-Transform Spectrogram applied on the classification of heart sounds," *IEEE International Conference on Acoustics Speech and Signal Processing*, 2013.
- [4] D. Zhang, J. He, Y. Jiang, M. Du, "Analysis and classification of heart sounds with mechanical prosthetic heart valves based on Hilbert-Huang transform," *International Journal of Cardiology*, vol. 151, no. 1, pp. 126-127, 2011.
- [5] W. C. Kao, C. C. Wei, "Automatic phonocardiograph signal analysis for detecting heart valve disorders," *Expert Systems with Applications*, vol. 38, no. 6, pp. 6458-68, 2011.
- [6] L. Huiying, L. Sakari, H. Iiro, "A heart sound segmentation algorithm using wavelet," *19th international Conference IEEE/EMBS*, 1997.
- [7] S. Yuenyong, A. Nishihara, W. Kongprawechnon, K. Tungpimolrut, "A framework for automatic heart sound analysis without segmentation," *BioMedical Engineering Online*, pp. 10-13, 2011.
- [8] C. Liu, D. Springer, Q. Li, B. Moody, R. Juan, F. Chorro, F. Castells, J. Roig, I. Silva, A. Johnson, Z. Syed, S. Schmidt, C. Papadaniil, L. Hadjileontiadis, H. Naseri, A. Moukadem, A. Dieterlen, C. Brandt, H. Tang, M. Samieinasab, M. Samieinasab, R. Sameni, R. Mark, G. D. Clifford, "An open access database for the evaluation of heart sound algorithms", *Physiological Measurement*, vol. 37, no. 9, 2016.
- [9] D. B. Springer, L. Tarassenko and G. D. Clifford, "Logistic Regression-HSMM-Based Heart Sound Segmentation," in *IEEE Transactions on Biomedical Engineering*, vol. 63, no. 4, pp. 822-832, April 2016.