



## Segmentasyon yapmadan patolojik kalp sesi kayıtlarının tespiti için bir örüntü sınıflandırma algoritması

**Abdulnasır YILDIZ**

Dicle Üniversitesi, Elektrik Elektronik Mühendisliği Bölümü, Diyarbakır  
[abnavil@dicle.edu.tr](mailto:abnavil@dicle.edu.tr) ORCID: 0000-0002-1432-8360, Tel: (412) 241 10 00

**Hasan ZAN\***

Mardin Artuklu Üniversitesi, Meslek Yüksekokulu, Mardin  
[hasanzan@artuklu.edu.tr](mailto:hasanzan@artuklu.edu.tr) ORCID: 0000-0002-8156-016X

Geliş: 30.10.2018, Kabul Tarihi: 28.11.2018

### Öz

*Bu çalışmada, altı adet veri bankasından alınan kalp sesi kayıtlarına segmentasyon uygulamadan k-En Küçük Komşuluk (kNN), Destek Vektör Makinesi (DVM) ve sınıflandırıcı metotları topluluğu kullanarak sınıflandırmaya yarayan bir algoritma geliştirilmesi amaçlanmıştır. Altı aşamadan oluşan algoritmanın ilk aşaması olan Önilem aşamasında sinyaller sivri uçlarından arındırılmış ve ardından normalize edilmiştir. İkinci aşama olan Özellik çıkarma-1 aşamasında, sinyalin çeşitli zaman ve frekans özellikleri çıkarılarak üçüncü aşamadaki veri bankası sınıflandırıcının eğitilmesinde ve test edilmesinde kullanılmıştır. Üçüncü aşama olan veri bankası sınıflandırması aşamasında, her veri bankası oluşturulurken kullanılan cihazların, kayıt yeri ve ortamının farklılığının negatif etkilerini azaltmak ve her veri bankası için farklı özellikler ile sınıflandırıcılar kullanmak amacıyla kalp sesi kayıtları veri bankalarına göre sınıflandırılmıştır. Dördüncü aşama olan Özellik Çıkarma-2 aşamasında veri bankalarına göre sınıflandırılan sinyallerin yine çeşitli zaman ve zaman-frekans özellikleri çıkarılmıştır. Beşinci aşamada her veri bankası için 3 farklı sınıflandırıcı (kNN, DVM ve sınıflandırıcı topluluğu) kullanılarak kayıtlar sınıflandırılmıştır. Algoritmanın son aşaması olan Oylama aşamasında, nihai sınıflandırma başarımını arttırmak amacıyla her kayıt için 3 farklı sınıflandırıcının çıkışları belli kurallara göre oylanarak kaydın sınıfı (patolojik veya normal) belirlenmiştir. Beşli çapraz doğrulama kullanılarak eğitilen ve test (tanı testi) edilen algoritmanın performansı ölçülürken doğruluk, duyarlılık, özgüllük, pozitif ve negatif yorum gücü ile ROC grafiğinin altında kalan alan gibi parametreler kullanılmıştır. En iyi performans sonuçları doğruluk: %94.28, duyarlılık: %87.97, özgüllük: %87.97, pozitif yorum gücü: %84.78, negatif yorum gücü: %96.86 ve ROC eğrisi altında kalan alan: 0.919 şeklinde elde edildi. Elde edilen bu değerler daha önceki çalışmalar ile kıyaslandığında algoritmanın oldukça başarılı olduğu ve kalbin patolojik durumuna ilişkin uzman hekime ön tanı imkânı sunabileceği söylenebilir.*

**Anahtar Kelimeler:** Kalp sesi; Fourier dönüşümü; DVM; kNN; Sınıflandırıcı metotları topluluğu; Sınıflandırma;

\* Yazışmaların yapılacağı yazar

DOI: 10.24012/dumf.476437

## Giriş


Kardiyovasküler bozukluklar veya kalp hastalıkları bir insanın kalp durumu hakkında bilgi veren genel bir terimdir. Kalp hastalıkları, dünyada artan ölümlerin ana kaynaklarından bir tanesidir. Her yıl Türkiye’de kalp hastalıkları yüzünden ölen insan sayısı diğer sebeplerden dolayı ölen insan sayısından daha fazladır. 2014 yılında ölen insan sayısının % 25.61’lik kısmı kalp hastalıklarından dolayı öldüğü tahmin edilmektedir (WHO, 2018)

Kalp hastalıklarını tespit etmek amacıyla EKG, bilgisayarlı tomografi, efor testi ve MR gibi gelişmiş yöntemlerin yanı sıra kalp sesinin stetoskop yardımıyla hekimler tarafından dinlenerek kalp sesindeki bozuklukların tespiti gibi basit yöntemler de kullanılmaktadır. Ayrıca son yıllarda kalp sesi kayıtlarını kullanarak sinyal işleme teknikleri ve makine öğrenmesi yardımıyla kişilerin kalp hastalıklarına sahip olup olmadığını tespit eden otomatik örüntü tanıma sistemleri geliştirilmeye çalışılmaktadır (Maglogiannis, 2009).

Elektronik stetoskop ile kaydedilip dijital sinyale dönüştürülen kalp sesine fonokardiyogram (PCG) denir (Zhongwei ve Samjin, 2006). Bu sinyaller kompleks, durağan olmayan sinyallerdir ve vücudun mekanik aktiviteleri sonucu meydana gelmekle beraber kalp hastalıklarını tespit etmede önemli bilgiler içerir (Lekram ve Abhishek, 2014).

PCG kayıtları dört tane kalp sesi bileşeninden (S1, S2, S3 ve S4) meydana gelebilir. Temel kalp sesleri olarak da adlandırılan birinci ve ikinci kalp sesleri (S1 ve S2) herhangi bir hastalığa sahip olmayan her kalpten duyulabilir. Bu sesler kalpteki kapakçıkların kapanıp açılması sonucu oluşur. S1’in başlangıcı ile S2’nin başlangıcı arasında kalan bölge sistol (kalbin kasılması) olarak adlandırılır. S2’nin başlangıcı ve diğer döngüdeki S1’in başlangıcı arasında kalan bölge ise diyastol (kalbin genişlemesi) olarak adlandırılır. Hastalıklı bir kalbe ait PCG kayıtlarında üçüncü ve dördüncü (S3 ve S4) kalp sesleri de duyulabilir (Johnston,

2007). Şekil 1’de tüm kalp seslerine sahip örnek bir PCG kaydı verilmiştir.



Şekil 1. Tipik bir kalp sesi sinyali

Kalp atımı sırasında duyulan olağan dışı seslere üfürüm denir. Üfürümler en yaygın görülen kalp anormalliklerinden biridir. Üfürümler ile kalp sesleri arasındaki temel fark üfürümlerin gürültülü ve daha uzun olmasıdır. Sistol (kalbin kasılması) aralığında meydana gelen üfürümler, sistolik üfürüm; diyastol (kalbin genişlemesi) aralığında meydana gelen üfürümler diyastolik üfürüm olarak sınıflandırılır (Nigam ve Priemer, 2007).

Literatürde yer alan kalp hastalıklarını tespit etmede kullanılan otomatik örüntü tanıma sistemleri genellikle önışlem, segmentasyon, özellik çıkarma ve sınıflandırma olmak üzere dört temel aşamadan oluşmaktadır (Nabih vd., 2017). Yapılan pek çok çalışmanın önışlem aşamasında, sinyallere filtreleme, gürültüden arındırma ve normalizasyon gibi işlemler uygulanmıştır (Nabih vd., 2017). Kalp seslerinin alt kalp seslerine ayrılması işlemi olan segmentasyon aşamasında ise zarf, özellik, makine öğrenmesi ve saklı Markov modeli temelli metodlar kullanılmıştır (Liu vd., 2016). Özellik çıkarma aşamasında ise Fourier dönüşümü, dalgacık dönüşümü, mel frekansı keprum katsayıları, S dönüşümü, ayrık kosinüs dönüşümü, Choi-Williams dağılımı ve Shannon enerji gibi yöntemler kullanılmıştır (Nabih vd.,

2017). Algoritmanın son aşaması olan sınıflandırma aşamasında ise Yapay sinir ağları (YSA), DVM, kNN, sınıflandırıcı metotları topluluğu ve derin öğrenme gibi pek çok yöntem sınıflandırıcı olarak kullanılmıştır (Nabih vd., 2017).

Son 50 yıldır kalp sesi işaretlerinden kişinin kalp hastası olup olmadığının tespitine yönelik geliştirilen otomatik teşhis algoritmalarının başarımı genelde belirli bir lokasyondan alınan, gürültüsüz ve az sayıda kalp sesi kaydı içeren veri setleri üzerinden test edilmiştir. Bu da farklı lokasyonlardan alınan, gürültülü ve çok fazla sayıda kayıt içeren bir veri seti üzerinden başarımı test edilmiş yüksek performanslı algoritmaların geliştirilmesi gerektiğini gösterir.

Bu çalışmada, PCG kayıtlarından kişinin kalp hastası olup olmadığını tespit eden zaman, zaman-frekans tabanlı işaret işleme ve makine öğrenmesi algoritmalarına dayalı bir örüntü sınıflandırma sistemi geliştirilmeye çalışılmıştır. Çalışmada, farklı veri bankalarından alınan PCG kayıtlarındaki farklılıkların olumsuz etkisini azaltmak amacıyla kayıtlar veri bankasına göre ön sınıflandırmaya tabi tutulmuştur. Veriler veri bankalarına göre

sınıflandırıldıktan sonra segmentasyon işlemine tabi tutulmadan DVM, kNN ve sınıflandırıcı metotları topluluğu kullanılarak sınıflandırılmıştır. Geliştirilen sistemin başarımlı performansı altı adet veri bankasından elde edilen, farklı lokasyonlu ve gürültülü kayıtların da içerisinde yer aldığı ve toplamda 3240 kalp sesi kaydından oluşan bir veri seti üzerinden test edilmiştir. Elde edilen test sonuçları daha önce yapılmış olan benzer çalışmalar ile kıyaslanmıştır.

## Materyal ve Yöntem

### Kullanılan Kalp Sesi Kayıtları

Yapılan önceki çalışmaların çoğundaki en büyük eksiklik kullanılan verilerin kısıtlı sayıda ve gürültüsüz olmasıydı. Bu amaçla pek çok kurum tarafından desteklenen physionet.org, geniş bir veri bankası oluşturmak ve dünyadaki araştırmacıları normal ve anormal PCG kayıtlarının sınıflandırılması konusunda çalışma yapmaları için teşvik etmek amacıyla 2016 yılında bir yarışma düzenledi. Yarışma kapsamında oluşturulan veri bankasının eğitim seti “[physionet.org/challenge/2016](http://physionet.org/challenge/2016)” adresinden indirilebilir. Tablo 1’de veri bankaları ile ilgili detaylar yer almaktadır.

Tablo 1. Kullanılan verilere ilişkin detaylar

Veri Bankası	Denek Tipi	Denek Sayısı	Yaş	Kayıt Sayısı	Kayıt Uzunluğu (Saniye)	Örnekleme Frekansı
<b>MITHSDB</b>	Normal	38	Bilinmiyor	117	33±5	44100 Hz
<b>(a)</b>	Anormal	83	Bilinmiyor	292	33±5	44100 Hz
<b>AADHSDB</b>	Normal	121	Bilinmiyor	544	8	4000 Hz
<b>(b)</b>	Anormal	30	Bilinmiyor	151	8	4000 Hz
<b>AUTHHSDB</b>	Normal	11	29±8	11	47±25	4000 Hz
<b>(c)</b>	Anormal	34	77±9	34	56±34	4000 Hz
<b>TUTHSDB</b>	Normal	28	Bilinmiyor	174	15	4000 Hz
<b>(g)</b>	Anormal	16	Bilinmiyor		15	4000 Hz
<b>UHAHSDB</b>	Normal	19	18-40	19	14±5	8000 Hz
<b>(d)</b>	Anormal	36	44-90	60	16±9	8000 Hz
<b>DLUTHSDB</b>	Normal	174	25±3	338	209±78	800–22050 Hz
<b>(e)</b>	Anormal	335	60±12	335	17±12	8000 Hz
<b>SUAHSDB</b>	Normal	79	56±16	81	33±5	8000 Hz
<b>(f)</b>	Anormal	33	56±16	33	33±5	8000 Hz
<b>SSHHSDB</b>	Normal	12	Bilinmiyor	12	36±12	8000 Hz
<b>(i)</b>	Anormal	23	Bilinmiyor	23	36±12	8000 Hz
<b>Toplam</b>	—	1072	—	2224	—	—

Yarışma kapsamında Tablo 1’de verilen veri bankaları 2 kHz örnekleme frekansı ile yeniden örneklendirilerek bir araya getirilmiş ve veriler eğitim ve test veri seti olarak ayrılmıştır. Sadece eğitim veri seti indirilebildiğinden bu çalışmada a, b, c, d, e ve f olarak etiketlenen veri bankalarının eğitim veri seti olarak adlandırılan PCG kayıtları kullanılmıştır. Bu veri seti altı adet farklı veri bankasının birleşiminden oluşmaktadır. Veri seti 2575’ü normal ve 665’si anormal olmak üzere toplamda 3240 adet PCG kaydı içermektedir. Mevcut çalışmamızda bu veri seti çalışma veri seti olarak adlandırılmıştır. Çalışmamızda geliştirilen algoritmanın performans değerlendirilmesinde 5-katlı çaprazlama doğrulama (5-fold cross validation) yöntemi kullanılmıştır. Bunun için çalışma veri setinden beş adet kopya oluşturulmuş, her kopya beş parçaya bölünmüştür. Oluşturulan beş parçanın dördü eğitim, bir ise test (tanı testi) için kullanılmıştır. Son olarak beş tanı testi sonuçlarının ortalaması alınarak algoritmanın performansı hesaplanmıştır. Çapraz doğrulamanın her adımında kullanılan kayıtlara ilişkin detaylar Tablo 2’te verilmiştir.

Tablo 2. Çapraz doğrulama için eğitim veri seti ve test veri seti

Veri Seti	Alt Veri Seti	Normal	Anormal
Eğitim	a	94	234
	b	309	84
	c	6	19
	d	22	22
	e	1566	146
	f	64	27
	Toplam	2061	532
Test	a	23	58
	b	77	20
	c	1	5
	d	5	6
	e	392	37
	f	16	7
	Toplam	514	133

### Algoritmanın Yapısı

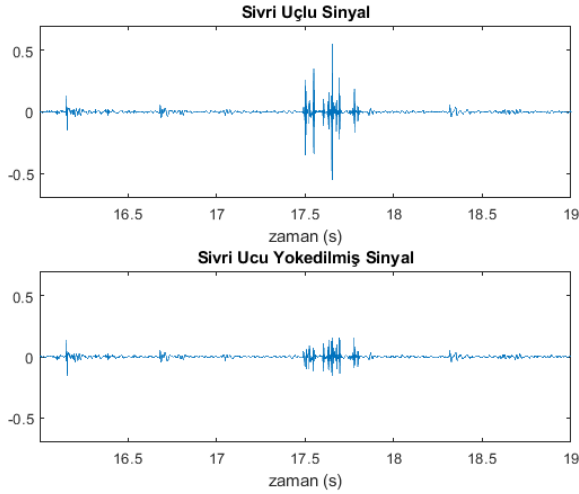
Matlab R2017b programında yazılmış olan algoritma Önişlem, Özellik Çıkarma-1, Veri Bankası Sınıflandırması, Özellik Çıkarma-2, Nihai Sınıflandırma ve Oylama olmak üzere altı aşamadan oluşmaktadır. Algoritmanın blok diyagramı Şekil 2’de verilmiştir.

### Önişlem

Bu aşamada gürültüden kaynaklı sivri uçları PCG kayıtlarından ayıklamak için Schmidt ve diğerleri (2010) tarafından geliştirilen bir yöntem kullanılmıştır. Dört adımdan oluşan bu yöntemin işlem adımları sırasıyla aşağıda verilmiştir;

- 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 ortanca değerinin üç katını geçerse a’dan e’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 son 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.
- 4) İşlem tamamlanır.

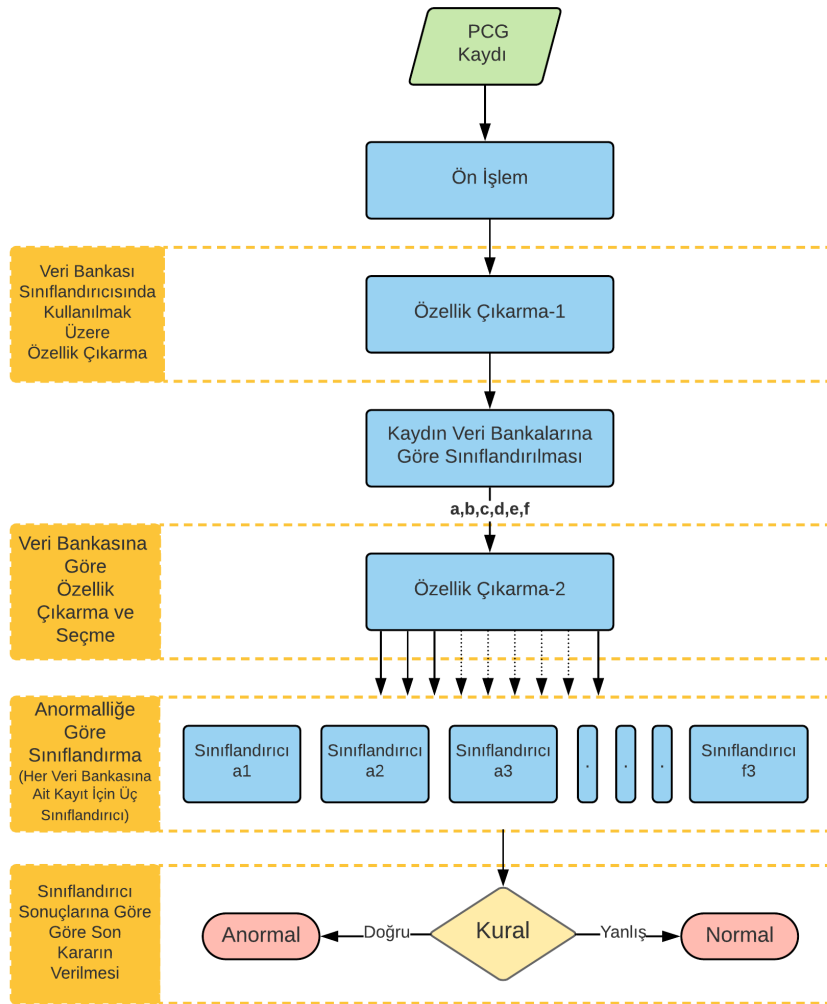
Belirtilen yöntemin örnek bir PCG kaydına uygulanması Şekil 3’de gösterilmiştir. Önişlem aşamasında gerçekleştirilen bir diğer işlem normalizasyon işlemidir. Normalizasyon deneğe ait özelliklerin kayıtlardan arındırılması için başvurulan bir işlemdir. Bu işlem için çalışmada minmaks normalizasyon yöntemi kullanılmıştır.



Şekil 3. Sivri uçlu ve sivri ucu yok edilmiş iki PCG kaydı

### Özellik Çıkarma-1

Bu aşamada, sinyalin zaman uzayına ve Hızlı Fourier Dönüşümü (HFD) kullanılarak elde edilen frekans uzayına (0–200 Hz ile 800–1000 Hz frekans aralıkları) ait istatistiksel özellikleri çıkarılmıştır (minimum, maksimum, ortalama, medyan, basıklık, çarpıklık, etkin değer ve etkin değer maksimum değere oranı olmak üzere  $8 \times 4 = 24$  adet özellik).



Şekil 2. Önerilen algoritmanın blok diyagramı

### Veri Bankası Sınıflandırması

Bu aşamanın amacı altı adet veri bankasından alınan kalp sesi kayıtlarının altı sınıfa ayrılmasıdır. Böylece sonraki adımlarda her veri bankasına ait kayıtlar için farklı özellik

seçilebilmesi ve nihai sınıflandırma aşamasında her veri bankası için ayrı sınıflandırıcı kullanılması mümkündür.

Detaylı açıklaması aşağıda verilmiş olan sınıflandırıcı metotları topluluğu veri bankası sınıflandırıcısı olarak kullanılmıştır. Bu sınıflandırıcı beşli çapraz doğrulamanın her adımında her biri 24 adet özelliğe sahip 2590 adet PCG kaydı ile eğitilmiştir. Sınıflandırıcıya ait parametreler deneme yanılma yolu ile bulunmuştur. Bu aşamada kullanılan sınıflandırıcı verileri altı sınıfa %98.14'lük bir doğruluk ile sınıflandırmıştır.

Tablo 3. Veri bankası sınıflandırıcısına ait detaylar


<b>Sınıflandırıcı Türü</b>	Sınıflandırıcı Metotları Topluluğu
<b>Algoritma</b>	AdaBoostM2
<b>Zayıf Sınıflandırıcı Türü</b>	Karar Ağacı
<b>Sınıflandırıcı Sayısı</b>	487
<b>Öğrenme Oranı</b>	0,4591

#### a) Sınıflandırıcı Metotları Topluluğu

Pek çok araştırmacı çok sayıda sınıflandırıcının tahminlerini birleştirerek tek bir sınıflandırıcı oluşturma tekniğini incelemiştir. Elde edilen sınıflandırıcı, yani topluluk, genellikle bu topluluğu oluşturan her bir sınıflandırıcıdan daha yüksek bir doğruluğa sahip olur. Bu yöntemin temel prensibi bir grup zayıf sınıflandırıcıyı çeşitli algoritmalar kullanarak bir araya getirip güçlü bir sınıflandırıcı oluşturmaktır. Sınıflandırıcı topluluğu oluşturulurken en çok kullanılan

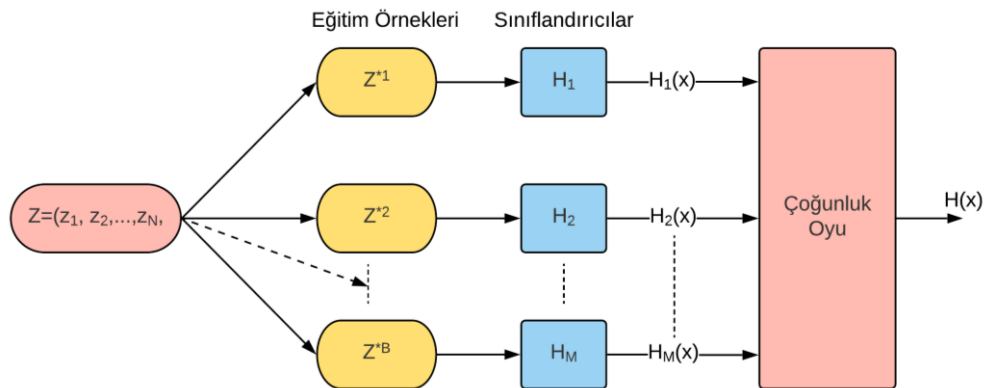
algoritmalar Adaboost ailesi algoritmaları (arttırma, boosting) ve bagging (özyükleme bütünleştirilmesi, bootstrap aggregation) algoritmasıdır. Bu algoritmalar ile beraber en çok kullanılan zayıf sınıflandırıcı ise karar ağacıdır (Zhukov vd., 2017).

Boosting ile yeniden ağırlıklandırılmış eğitim verilerine sınıflandırma algoritmalarından bir tanesi sıra ile uygulanır ve elde edilen sonuçlar ağırlıkları ile beraber oylanarak tek bir sınıflandırma sonucu elde edilir.



Şekil 4. Boosting algoritmalarının genel yapısı

Bootstrap, genel amaçlı ve örnek temelli bir istatistiksel yöntemdir. Bu yöntemde, temel bir veri setinden rastgele, her seferinde eşit sayıda ve tekrar yerine koymak suretiyle veri alınarak ayrık eğitim verileri oluşturulur. Bagging, bootstrap örnekleme kullanılarak sınıflandırıcıların doğruluğunu arttırmak için kullanılan bir tekniktir. Mevcut çalışmada PCG kayıtlarının hangi veri bankasına ait olduğunu belirlemek için kullanılan sınıflandırıcı metotlar topluluğun ilişkin detaylar Tablo 3'de verilmiştir.



Şekil 5. Bagging algoritmasının genel yapısı

## Özellik Çıkarma-2

Bu aşamada PCG kayıtlarının “Db4” dalgacı ile elde edilen 3. ve 4. seviye detay ile yaklaşım katsayılarının, mel frekansı kepsturm katsayılarının, sinyalin zaman ve frekans uzayının aşağıda belirtilen özellikleri çıkarılmıştır.

Bütün veri bankaları için aynı sayıda olmak üzere her veri bankası için toplamda 169 adet

özellik çıkarılmıştır. Çıkarılan özellik sayısını azaltmak için açıklaması aşağıda verilen ardışık ileri yönde özellik seçme algoritması kullanılarak sınıflandırma performansına olumsuz etkisi olan ve sınıflandırma performansına hiçbir etkisi olmayan gereksiz özellikler elemine edilmiştir. Özellik seçme sonrası veri bankaları için seçilen özellik sayısı Tablo 5’te verilmiştir.

Tablo 4. Çıkarılan özellikler

Özellik	Zaman Uzayı	Hızlı Fourier Dönüşümü	Ayrık dalgacık dönüşümü: 3. ve 4. Seviye Yaklaşım ve Detay Katsayıları (Db4 dalgacı)	Mel Frekansı Kepstrum Katsayıları (13 katsayı+1 filtre enerjisi)
Etkin değer	✓	✓	✓	✓
Sıfırdan geçme oranı	✓	✓	✓	X
Basıklık	✓	✓	✓	✓
Çarpıklık	✓	✓	✓	✓
Ortalama	✓	✓	✓	✓
Standart Sapma	✓	✓	✓	✓
Varyans	✓	✓	✓	✓
Entropi	✓	✓	✓	✓
Maksimum	✓	✓	✓	✓
Medyan	✓	✓	X	X
Toplam harmonik bozulma	X	✓	X	X

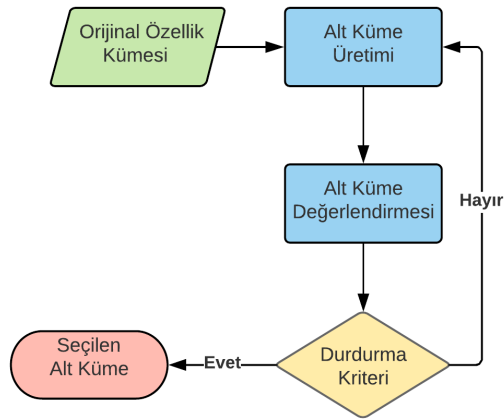
Tablo 5’ten de görülebileceği gibi veri bankası b ve c için seçilen özellik sayısı ilk başta çıkarılan özellik sayısı ile aynıdır. Çünkü özellik seçmeden sonra Veri bankası-b için performans düşmüştür. Veri bankası-c için ise özellik seçmeden önce bile tam performans elde edildiğinden özellik seçmeye gerek kalmamıştır.

Tablo 5. Özellik seçme sonrası özellik sayıları

Veri Bankası	Özellik Sayısı
a	9
b	169
c	169
d	4
e	6
f	7

### a) İleri Yönde Özellik Seçme Algoritması

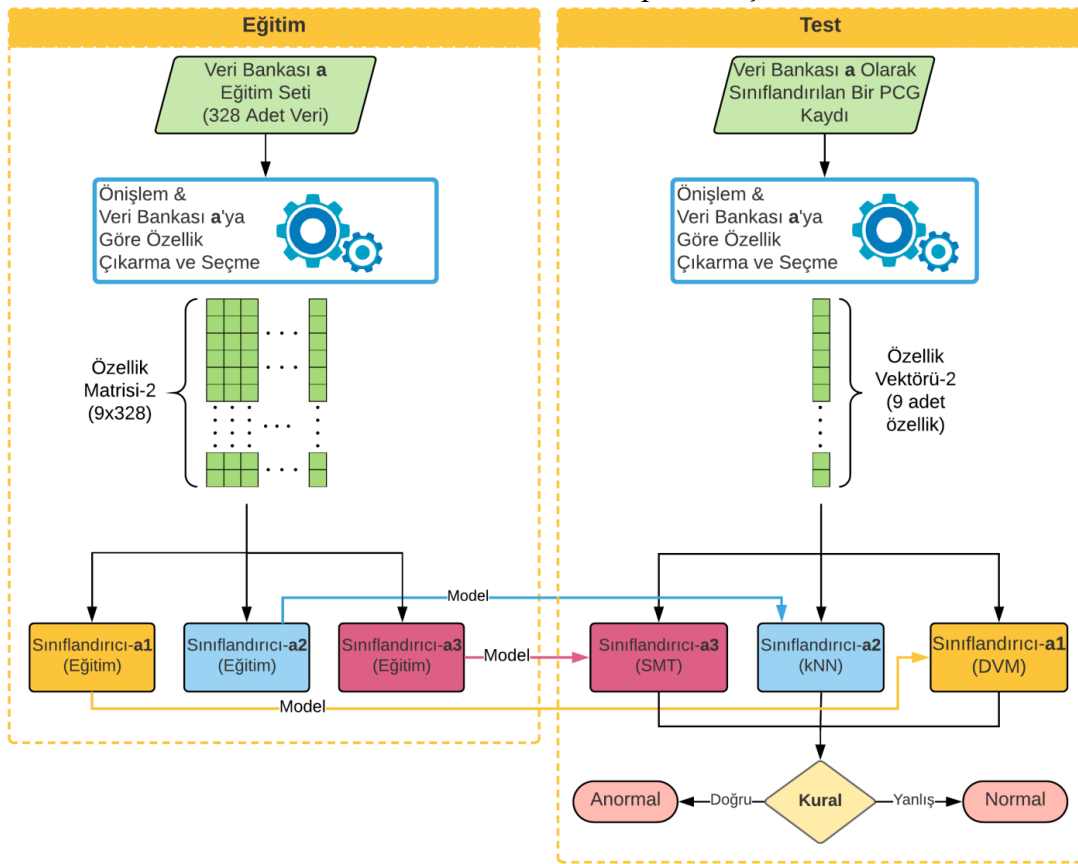
Özellik seçmenin amacı, çıkarılan özellik kümesinden daha az sınıflandırma hatası elde edilebilecek bir alt küme seçilmesidir. İleri yönde özellik seçme algoritması boş bir alt küme ile başlar. Sonra alt kümeye yeni bir özellik eklenir ve aday alt küme oluşturulur. Aday alt küme, değerlendirme kriterine göre değerlendirilir. Değerlendirme sonucu özellik eklenmeden önceki değerlendirme sonucundan daha iyi ise özellik tutulur, değil ise çıkarılır. Daha sonra alt kümeye özellik kümesinden yeni bir özellik eklenerek aynı işlemler tekrarlanır. Durma kriterine ulaşıncaya veya özellik kümesinde özellik kalmayana kadar aynı işlemler tekrarlanır (Jain ve Zongker, 1997). Algoritmanın blok diyagramı Şekil 6’da verilmiştir.



Şekil 6. İleri yönde özellik seçme algoritması

### Nihai Sınıflandırma

Algoritmanın bu adımında, patolojik kalp sesi kayıtlarını tespit etmek amacıyla her veri bankası için özel olarak eğitilen DVM, kNN ve sınıflandırıcı metotları topluluğu (SMT) olmak üzere veri bankası başına üç adet, toplamda ise 18 adet sınıflandırıcı kullanılmıştır. Sınıflandırıcılara ilişkin deneme yanılma yoluyla bulunan parametreler Tablo 6’da verilmiştir. Veri bankası-a için sınıflandırıcıların eğitilmesi ve test edilmesine ilişkin blok diyagramı Şekil 7’de verilmiştir. Bütün veri bankaları için aynı işlem adımları takip edilmiştir.



Şekil 7. Sınıflandırıcıların eğitilmesi ve test edilmesi

Tablo 6. Sınıflandırıcılara ilişkin detaylar

Parametre	Veri Bankası					
	a	b	c	d	e	f
Çekirdek Fonksiyonu	gaussian	gaussian	polynomial	polynomial	polynomial	gaussian
Çekirdek Ölçeği	999.520	85.645	–	–	–	244.311
Polinom Derecesi	–	–	3	2	2	–
Kutu Sınırı	7.548	976.000	4.735	541.412	0.065	946.500



Parametre	Veri Bankası					
	a	b	c	d	e	f
Komşu Sayısı	38	1	8	11	1	25
Uzaklık	minkowski	kapsamlı	minkowski	seuclidean	mahalonobis	chebychev
Uzaklık Ağırlığı	Karesel-ters	Öklit-ters	eşit	eşit	ters	eşit
Üs	0.645	–	2	–	–	–
Metot	bag	bag	bag	gentleboost	gentleboost	logitboost
Sınıflandırıcı	ağaç	ağaç	ağaç	ağaç	ağaç	ağaç
Sınıflandırıcı Sayısı	496	45	265	10	338	337
Öğrenme Oranı	1	1	1	0.991	0.002	0.001

### a) kNN


kNN metodu kümeleme ve sınıflandırma uygulamalarda geniş bir şekilde kullanılan basit bir makine öğrenmesi tekniğidir. Bu yöntemde, sınıfları bilinen eğitim veri seti kullanılarak test veri seti aynı sınıflara girecek şekilde sınıflandırılır. Bunun için eğitim veri setinin her bir noktasına en yakın k adet test eğitim seti noktası belirlenir. Daha sonra çoğunluk oyuna göre test veri setinin sınıfları belirlenir (Lubaib ve Ahammed, 2015). kNN algoritmasının işlem adımları şu şekildedir:

- 1) Verileri yükle.
- 2) k, yani komşu sayısını belirle.
- 3) Tahmin edilen sınıfları elde etmek için birden eğitim setindeki örnek sayısına kadar iterasyon yap.
  - a) Test verileri ile eğitim verisinin her bir sütunu arasındaki uzaklığı uzaklık fonksiyonu ile hesapla.
  - b) Hesaplanan uzaklıkları küçükten büyüğe doğru sırala.
  - c) Sıralanmış diziden k adet sütun al.
  - d) Bu sütunlarda en sık karşılaşılan sınıfları al.
  - e) Tahmin edilen sınıfları elde et.

### b) DVM

DMM ikili sınıflandırma için kullanılan makine öğrenmesi tekniğidir. DVM'nin temelleri Vapnik (1995) tarafından atılmıştır. DVM'nin temeli pozitif ve negatif örnekler

arasındaki ayrımı en iyi şekilde yapan bir hiper düzlemin bulunmasıdır. Hiper düzlem bulunurken düzlemin her iki sınıfa olan uzaklık maksimize edilmeye çalışılır. Eğer örnekler lineer olarak ayrılmıyorsa örneklere çeşitli çekirdek dönüşümleri uygulanarak boyut sayısı artırılarak hiper düzlem bulunur. Bu hiper düzleme en yakın olan noktalara yani sınıflandırılması en zor olan noktalara destek vektörleri denir. Eğitim verileri kullanılarak hiper düzlem bulunduktan sonra test verileri bu düzlem kullanılarak sınıflandırılır (Lubaib ve Ahammed, 2015). İki boyutlu eğitim veri seti için bulunan hiper düzlemin geometrik gösterimi Şekil 8'de verilmiştir.



Şekil 8. Hiper düzlemin geometrik gösterimi

### Oylama

Algoritmanın son aşamasında Tablo 7'de belirlenen kural çerçevesinde sınıflandırma sonuçları üzerinden oylama yapılmıştır.

Tablo 7. Oylama aşamasında Kullanılan kurallar (VB: Veri Bankası)

<b>Kural-1</b>	Eğer DVM sonucu anormal ise kayıt anormaldir
<b>Kural-2</b>	Eğer kNN sonucu anormal ise kayıt anormaldir
<b>Kural-3</b>	Eğer SMT sonucu anormal ise kayıt anormaldir
<b>Kural-4</b>	Eğer DVM ve kNN sonucu anormal ise kayıt anormaldir
<b>Kural-5</b>	Eğer DVM veya SMT sonucu anormal ise kayıt anormaldir
<b>Kural-6</b>	Eğer kNN veya SMT sonucu anormal ise kayıt anormaldir
<b>Kural-7</b>	Eğer DVM, kNN veya SMT sonucu anormal ise kayıt anormaldir
<b>Kural-8</b>	VB-a için Kural-7 VB-b için Kural-6 VB-c için Kural-1 VB-d için Kural-7 VB-e için Kural-2 VB-f için Kural-3

### Başarı Ölçütü

Biyomedikal çalışmalarda tanı testi deneklerde hastalık olup olmadığını tespit etmede kullanılır. Tanı testi, test sonuçlarının denegin gerçek durumu ile karşılaştırılarak yapılır. Tanı testi yapıldıktan sonra doğruluk, duyarlılık, özgüllük, pozitif ve negatif yorum gücü ile ROC eğrisinin altında kalan alan gibi parametreler hesaplanarak performans değerlendirilmesi yapılır (Wong ve Lim, 2011). Bir tanı testine ilişkin bütün olası sonuçlar Tablo 8’de verilmiştir. Testin tüm denekleri doğru tespit etme başarısını ifade eden doğruluk Denklem 1’de, sağlıklı bireyleri tespit etme başarısını ifade eden özgüllük Denklem 2’de ve sağlıklı bireyleri doğru tespit etme başarısını ifade eden duyarlılık ise Denklem 3’te verilmiştir.

Tablo 8. Bir tanı testinin tüm olası sonuçları

Tanı testi Sonuçları	Gerçek Durum	
	Anormal (Hastalıklı, Pozitif)	Normal (Sağlıklı, Negatif)
<b>Anormal (Hastalıklı, Pozitif)</b>	Doğru Pozitif (DP)	Yanlış Pozitif (YP)
<b>Normal (Sağlıklı, Negatif)</b>	Yanlış Negatif (YN)	Doğru Negatif (DN)

$$\text{doğruluk} = \frac{DP + DN}{DP + YP + DN + YN} \quad (1)$$

$$\text{özgüllük} = \frac{DN}{YP + DN} \quad (2)$$

$$\text{duyarlılık} = \frac{DP}{DP + YN} \quad (3)$$

DN: Doğru negatif, YN: Yanlış negatif,  
DP: Doğru pozitif, YP: Yanlış pozitif

Tanı testi sonucu sağlıklı olarak teşhis edilmiş bir denegin gerçekte de sağlıklı olma olasılığı şeklinde tanımlanan negatif yorum gücü (NPV) Denklem 4’de ve test sonucu sağlıklı olarak teşhis edilen bir denegin gerçekte de sağlıklı olma olasılığı şeklinde tanımlanan pozitif yorum gücü (PPV) Denklem 5’te verilmiştir.

$$NPV = \frac{DN}{DN + YN} \quad (4)$$

$$PPV = \frac{DP}{DP + YP} \quad (5)$$

NPV: Negatif yorum gücü, PPV: Pozitif yorum gücü

ROC analizi, klinik çalışmalarda tanı testinin sağlıklı (negatif) ve hastalıklı (pozitif) iki durumu ne kadar doğru bir şekilde ayırdığını ölçmede kullanılır. Analiz genellikle ROC eğrisi kullanılarak yapılır. ROC eğrisi, doğru pozitif oranının yanlış pozitif oranına göre

değişiminin çizilmesiyle elde edilir. Eğrinin altında kalan alanın fazlalığı tanı testinin başarısını gösterir. ROC eğrisi altında kalan 0.9-1 arasında ise tanı testinin performansı “Mükemmel”, 0.8-0.9 arasında ise “Çok iyi”, 0.7-0.8 arasında ise “İyi”, 0.6-0.7 arasında ise yeterli, 0.5-0.6 arasında ise “Kötü” ve 0.5’ten küçük ise “Kullanışsız” olarak nitelendirilir.

Yapılan yarışmada doğruluk yerine skor olarak adlandırılan ve duyarlılık ile özgüllüğün aritmetik ortalaması kullanılmıştır. Sağlıklı bir karşılaştırma

yapılabilmesi açısından bu çalışmada da skor değeri hesaplanmıştır (Liu vd., 2016).

### Uygulama ve Başarımlar

Bu çalışmada Physionet.org tarafından 2016’da yapılan yarışmada kullanılan PCG kayıtları kullanılmıştır. Üç farklı sınıflandırıcı kullanılarak patolojik kayıtların tespit edilmesi amaçlanmıştır. Önerilen algoritmanın eğitilmesinde beş katlı çapraz doğrulama kullanılarak tüm verilerin hem eğitim hem de test için kullanılması sağlanmıştır. Elde edilen ortalama performans değerleri Tablo 9’da verilmiştir.

Tablo 9. Tanı testinin farklı kurallar kullanılarak elde edilen performans sonuçları


Kural	Doğruluk (%)	Özgüllük (%)	Duyarlılık (%)	PPV (%)	NPV (%)	ROC (%)	Skor (%)
Kural-1	91.04	95.91	71.18	82.05	93.01	84.05	84.05
Kural-2	92.58	<b>97.86</b>	72.18	89.72	93.15	85.02	85.02
Kural-3	<b>94.59</b>	97.86	81.95	<b>90.83</b>	95.44	89.91	89.91
Kural-4	91.34	95.14	76.69	80.31	94.04	85.91	85.91
Kural-5	92.89	94.94	84.96	81.29	96.06	89.95	89.95
Kural-6	94.43	96.50	86.47	86.47	96.50	91.48	91.48
Kural-7	93.04	94.36	<b>87.97</b>	80.14	96.81	91.16	91.16
Kural-8	94.28	95.91	<b>87.97</b>	84.78	<b>96.87</b>	<b>91.94</b>	<b>91.94</b>

İlk üç kurala ait performans sonuçları sırasıyla destek vektör makineleri, k en yakın komşular ve sınıflandırıcı metotları toplulukları tek başına kullanıldığında elde edilen sonuçlara denk gelmektedir. Bu sonuçlar incelendiğinde hem doğruluk hem de skor anlamında en başarılı sonuçları sınıflandırıcı metotları topluluğu vermiştir. Ayrıca, bu sınıflandırıcı tüm tanı testleri içinde en yüksek doğruluk ve en yüksek pozitif yorum gücü elde edilmesini sağlamıştır. kNN sağlıklı denekleri en iyi teşhis ederken, sağlıklı denekler ise üç

sınıflandırıcı bir arada kullanıldığında en iyi teşhis edilmiştir. Yarışma skoru, ROC eğrisi altında kalan alan ile negatif ve pozitif yorum gücü açısından bakıldığında ise kural-8 en iyi sonuçların elde edilmesini sağlamıştır. Bu durum her veri bankası için farklı özellik ve sınıflandırıcı seçiminin performans artırıcı etkisini gözler önüne sermektedir. ROC eğrisi altında kalan alan incelendiğinde bütün kurallar mükemmel veya çok iyi bir performans sergilediği görülmektedir. Sekiz kurala ilişkin ROC eğrisi Şekil 9’da verilmiştir. Verilen ROC eğrileri, sadece

algoritmanın farklı durumlarda performansını karşılaştırılma amacıyla kullanıldığından her bir kural için çizdirilen ROC eğrileri

algoritmanın o kural için en iyi sonucu verdiği parametreler üzerinden çizdirilmiştir.



Şekil 9. Sekiz kurala ilişkin ROC eğrisi

Elde edilen en iyi sonuçlar, yarışmada dereceye giren çalışmalar ile yarışma sonrası yapılan çalışmaların sonuçları Tablo 10'da verilmiştir.

Tablo 10. Farklı çalışmaların performans sonuçları

Çalışma	Duy	Özg	Doğ
Potes vd. (2016)	88.0	82.0	85.0
Zabihi vd. (2016)	94.2	88.8	91.5
Kay ve Agarwal (2017)	84.8	83.3	84.1
Whitaker vd. (2017)	88.8	88.2	88.4
Beritelli vd. (2018)	93.0	91.0	92.0
Langley ve Murray (2017)	94.0	65.0	79.5
Homsı ve Warrick (2017)	95.9	90.5	93.2
Önerilen algoritma	88.0	95.9	91.9

Tablo 10'da da görülebileceği üzere önerilen algoritma yarışmada dereceye giren çalışmalardan daha yüksek performans göstermiştir. Ayrıca, önerilen algoritma yarışma sonrasında aynı veriler ile yapılan çalışmalar ile kıyaslandığında bu çalışmalara oldukça benzer sonuçlar elde etmiştir.

## Sonuçlar ve Tartışma

Bu çalışmada, Physionet.org tarafından 2016'da yapılan yarışmaya kalp sesi kayıtları kullanılmıştır. Çalışmanın amacı patolojik kalp sesi kayıtlarının segmantasyon yapılmadan, yani alt kalp seslerine ayrılmadan tespit edilmesidir. Bunun için altı adet veri bankasından alınan, farklı cihazlar ve vücudun farklı yerleri kullanılarak kaydedilen toplam 3240 adet PCG kaydı önışlem, özellik çıkarma-1, veri bankası sınıflandırması, özellik çıkarma-2, nihai sınıflandırma ve oylama aşamalarından

geçirilerek DVM, kNN ve SMT kullanılarak sınıflandırılmıştır.

Algoritmanın eğitilmesinde ve test edilmesinde beşli çapraz doğrulama kullanılarak tüm verilerin hem eğitim aşamasında hem de test aşamasında kullanılması sağlanmıştır. Algoritmanın tanı testi performans sonuçları Tablo 9’da verilmiştir. Elde edilen sonuçlar göz önünde bulundurulduğunda algoritmanın oldukça başarılı sonuçlar elde ettiği görülmektedir. Bu yüzden, algoritmanın hekimlere ikinci bir görüş sağlamak amacıyla kullanılacağı düşünülmektedir.

## Teşekkür

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

## Kaynaklar

Beritelli, F., Capizzi, G., Sciuto, G. L., Napoli, C. ve Scaglione, F., (2018). Automatic heart activity diagnosis based on Gram polynomials and probabilistic neural networks. *Biomedical Engineering Letters*, **8**, 1, 77–85.

Homsı, M. N. ve Warrick, P., (2017). Ensemble methods with outliers for phonocardiogram classification. *Physiological Measurement*, **38**, 8, 1631–1644.

Jain, A. ve Zongker, D., (1997). Feature selection: evaluation, application, and small sample performance. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, **19**, 2, 153–158.

Johnston, M., (2007). The third heart sound for diagnosis of acute heart failure. *Current Heart Failure Reports*, **4**, 3, 164–169.

Kay, E. ve Agarwal, A., (2017). DropConnected neural networks trained on time–frequency and inter–beat features for classifying heart sounds. *Physiological Measurement*, **38**, 8, 1645–1657.

Langley, P. ve Murray, A., (2017). Heart sound classification from unsegmented phonocardiograms. *Physiological Measurement*, **38**, 8, 1658–1670.

Lekram, B. ve Abhishek, M., (2014). Heart sound segmentation techniques: a survey. *IOSR Journal of Electrical and Electronics*

*Engineering (IOSR-JEEE)*, **4**, Electronics Eng., 46–49.

Liu, C., (2016). An open access database for the evaluation of heart sound algorithms. *Physiological Measurement*, **37**, 12, 2181–2213.

Lubaib, P. ve Ahammed, V. D., (2015). The heart defect analysis based on PCG signals using pattern recognition techniques. *Procedia Technology*, **24**, 2016, 1024 – 1031.

Maglogiannis, I., Loukis, E., Zafiropoulos, E. ve Stasis, A., (2009). Support Vectors Machine-based identification of heart valve diseases using heart sounds. *Computer Methods and Programs in Biomedicine*, **95**, 1, 47–61.

Nabih–Ali, M., El-Sayed, A., Yahiba, A. 2017. A review of intelligent systems for heart sound. *Journal of Medical Engineering & Technology*, **41**, 7, 553–563.

Nigam, V. ve Priemer, R., (2007). A simplicity–based fuzzy clustering approach for detection and extraction of murmurs from the phonocardiogram. *Physiological Measurement*, **41**, 7, 29–33.

Potes, C., Parvaneh, S., Rahman, A. ve Conroy, B., (2016). Ensemble of feature–based and deep learning–based classifiers for detection of abnormal heart sounds. 2016 Computing in Cardiology Conference (CinC), 621–624, Vancouver.

Schmidt, S. E., Holst–Hansen, C., Graff, C., Toft, E. ve Struijk, J. J., (2010). Segmentation of heart sound recordings by a duration–dependent. *Physiological Measurement*, **3**, 4, 513–542.

Whitaker, B. M., Suresha, P. B., Liu, C., Clifford, G. D., Anderson, D. V. 2017. Combining sparse coding and time–domain features for heart sound classification. *Physiological Measurement*, **38**, 8, 1701–1713.

Wong, H. B. ve Lim, G. H. 2011. Measures of diagnostic accuracy: sensitivity, specificity, PPV and NPV. *International Federation of Clinical Chemistry and Laboratory Medicine*, **19**, 4, 316–318.

World Health Organization. The Impact of Chronic Disease In Turkey. [http://www.who.int/chp/chronic\\_disease\\_report/turkey.pdf?ua=1](http://www.who.int/chp/chronic_disease_report/turkey.pdf?ua=1). Yayın tarihi 2002. Erişim Tarihi Ekim 10, 2018.

Zabihi, M., Rad, A. B., Kiranyaz, S., Gabbouj, M. ve Katsaggelos, A. K., (2016). Heart sound anomaly and quality detection using ensemble of neural networks without segmentation. 2016

Computing in Cardiology Conference (CinC),  
613–616 Vancouver.

Zhongwei, J., Samjin, C., (2006). A cardiac sound  
characteristics waveform. *Expert Systems with  
Applications*, **31**, 2, 286–298.

Zhukov, A., Tomin, N., Kurbatsky, V., Sidorov,  
D., Panasetsky, D. ve Foley, A., (2017).  
Ensemble methods of classification for power  
systems security assessment. *Applied  
Computing and Informatics*, **15**, 2, 100–106.

## Detection of pathological heart sound without segmentation by using SVM, kNN and ensemble methods of classification

### Extended abstract

Cardiovascular disorders or heart diseases are main culprit behind many deaths in the world. Every year, in Turkey, number of people dying due to heart diseases is more than number of people dying because of any other diseases.

In addition to advanced methods such as ECG, MRI, computed tomography and exercise test, there are simple methods like auscultate heart sounds. Furthermore, recently, many experts have been working on automatic heart diseases detection techniques based on machine learning.

Phonocardiogram (PCG) is non-stationary and complex signal which is recorded by an electronic stethoscope and converted to digital signal. PCGs are formed by physical activity of body and contain useful information for heart diseases detection. A PCG may consists of four heart sounds called S1, S2, S3 and S4, and abnormal sounds called murmur which indicates abnormality.

In this work, Training set of Physionet.org 2016 challenge is used to develop, train and test an algorithm that can detect pathological or abnormal heart sounds. This set contains 3240 PCG recordings which 2514 of them are normal and 662 of them are abnormal from six databases around the world. Different body location and devices are used when these databases are created. In order minimize negative effects of these differences, one additional classification phase is added to the algorithm. Therefore, the algorithm consists of six phase which are preprocess, feature extraction-1, database classification, feature extraction-2, ultimate classification and voting.

In preprocess phase, PCG recordings are denoised by a special technique developed by Schmidt at al. (2010) and normalized by minmax normalization.

In feature extraction-1 phase, statistical features (minimum, maximum, mean, median, skewness, kurtosis, RMS, ratio of RMS to maximum) of frequency domain between 0-200 Hz and 800-1000 Hz of signal that is calculated by fast

Fourier transform (FFT) are calculated ( $8 \times 2 = 16$  features) to feed input of database classifier.

In database classification phase, PCG recordings are classified by ensemble method of classifier (EMC) as per databases which are recordings obtained from. Therefore, different features can be extracted; different classifier can be trained and tested for different databases. Parameters of ensemble classifier are as flow: algorithm used to ensemble weak classifiers is AdaBoostM2, weak classifier is decision tree, number of weak classifier is 487 and learning rate is 0.4591.

In feature extraction-2 phase, RMS, zero crossing rate, skewness, kurtosis, mean, standard deviation, variance, entropy, maximum, median and total harmonic distortion of frequency domain are calculated. Same statistical features given above except median and total harmonic distortion of detail and approximation coefficients of third and fourth level discrete wavelet transform are extracted. Same statistical feature given above except zero crossing rate, median and total harmonic distortion of mel frequency cepstrum coefficients are calculated. After feature extraction, sequential forward feature selection is applied, and number of features is reduced.

In ultimate classification phase, three classifiers (SVM, kNN and ensemble of classification) for each database, total 18 classifiers are trained to detect abnormal heart sound recordings.

In voting phase, predefined rules are used to vote each classifier results. Rule acquired best performance is as follow: for database-a: "if any result of classifier is abnormal then recording is abnormal", for database-b: "if result of kNN or EMC is abnormal then recording is abnormal", for database-c: "if result of SVM is abnormal then recording is abnormal", for database-d: same as database-a, for database-e: "if result of kNN is abnormal then recording is abnormal", for database-f: "if result of EMC is abnormal then recording is abnormal".

An accuracy of 94.28%, a specificity of 95.91%, a sensitivity of 87.97%, a PPV of 84.78%, a NPV of 96.87%, area under ROC curve 91.94% and a score of 91.94% are best result obtained. These results are better than first three entries of challenge and very close to work completed after challenge.

**Keywords:** Heart sound, PCG, Fourier transform, MFCC, SVM, kNN, EMC, Classification