

Gerçek Zamanlı Aritmi Tespitinde Farklı Sınıflandırma Yöntemlerinin Karşılaştırılması

Özgür TOMAK^{1*}, Temel KAYIKÇIOĞLU²

¹Giresun Üniversitesi, Elektrik ve Enerji Bölümü, Giresun, Türkiye

²Karadeniz Teknik Üniversitesi, Elektrik ve Elektronik Mühendisliği Bölümü, Trabzon, Türkiye

Geliş Tarihi: 10.04.2017

Kabul Tarihi: 18.08.2017

***Sorumlu Yazar:** ozgur.tomak@giresun.edu.tr

Özet

Tıptaki gelişmeler ve sağlık bilincinin artması sonucunda sağlık hizmeti için talep artmıştır. Ancak bunu karşılayacak yeterli insan kaynağı, cihaz ve sağlık kuruluşu bulunmamaktadır. Tele-tıp sayesinde bu ihtiyaç azaltılabilir. Özellikle kırsal bölgedeki kalp rahatsızlıklarına sahip hastalarının EKG sinyallerinin izlenmesi çok önemlidir. Bilgi teknolojisindeki gelişmeler, erken teşhis ve tanı için klinik karar destek sistemlerine önemli katkılar sağlamaya başlamıştır. Özellikler Hjorth tanımlayıcılar, sinyalin yapay EKG sinyali ile korelasyonu, içkin kip işlevinden standart sapma, gücün aktiviteye oranı ve standart sapmadan oluşmaktadır. Farklı sınıflandırma yöntemleri bu özellikleri kullanarak karşılaştırılmıştır. Özellik çıkartma ve sınıflandırma için Matlab kullanıldı. Yöntemin performansı PhysioNet veri tabanından elde edilen kullanılan veriler üzerinde test edilmiştir.

Anahtar Kelimeler: Elektrokardiyogram (EKG), Aritmi, Sınıflandırılma.

Comparison of Different Classification Methods in Real Time Arrhythmia Detection

Abstract

Developments in medicine and increased health awareness has increased demand for health care. However, there is not enough human resources, device, and health care organizations to cover it. This demand can be reduced through telemedicine. Especially the monitoring of the ECG signal of the patient with heart disorders in rural areas is very important. Developments in information technology starts to provide important contribution to the clinical decision support systems for early detection and diagnosis. Features are composed of Hjorth descriptors, correlation of signal with an artificial ecg signal, standard deviation of intrinsic mode function, ratio of power to activity and standard deviation. Different classification methods are compared using these features. Matlab is used for feature extraction and classification. The performance of the method is tested on data used obtained from the PhysioNet database.

Keywords: Electrocardiogram (ECG), Arrhythmia, Classification.

1. Giriş

Nüfus devamlı bir artış eğilimindedir ve bu artış son zamanlarda daha çok hız kazanmıştır. Bunun en önemli nedeni yaşam düzeyindeki artış, tıptaki gelişmeler ve teknolojik ilerleme sonucunda ölüm yaş ortalamasında artıştır. Nüfus ve ölüm yaş ortalaması artışına bağlı olarak kronik hastalıkların ve kronik hastaların sayısı artmaktadır. Bu nedenle, ülkelerin sağlık bütçeleri ekonomik ve sosyal açıdan derinden etkilenir. Tele-tıp teknolojisi yardımıyla özellikle kronik hastalıkların klinik tedavi süreci daha iyi hale getirilebilir, giderler azaltılabilir ve kaliteli sağlık hizmetlerine erişim genişletilebilir (Wootton, 2012).

Tele-tıp teknolojisi ve gelişen giyilebilir teknolojiler ve cep telefonları yardımıyla hastaların uzaktan takibi mümkündür. Sağlıkçılar tarafından bu teknoloji kullanılarak hastalar günlük faaliyetlerini sürdürürken hastalıklarının erken teşhisi ve tanısı yapılabilmektedir. Tele-tıp teknolojisini kullanarak kalp hastalığı olan hastaların uzaktan izlenmesi ve sonucunda erken aritmi teşhisi süreci çok önemlidir. Hızlı ve doğru tanı için geliştirilmiş olan Klinik Karar Destek Sistemleri, biyolojik sinyal işleme ve makine öğrenimine dayanan bilgisayar uygulamalarıdır (Debusse ve ark., 2013). Bu uygulamalar sağlıkçıları doğru ve hızlı karar vermesine yardımcı olmak için geliştirilmiştir.

EKG sinyallerinin incelenmesinde morfolojik öznitelikler sıklıkla incelenmiştir. EKG'nin temel yapısında P, Q, R, S, T, U olarak adlandırılan noktalar sinyalimiz için önemli noktalardır. Bunlar arasında R tepe noktası sinyali incelemek için kullandığımız en önemli noktadır. Bundan dolayı genelde EKG incelemesinde öncelikle bulmayı planladığımız nokta R tepe noktasıdır. Sinyalde R tepe noktasından sonra sinyalimizin diğer önemli noktalarını, P, Q, S, T, U noktalarını bularak sinyali daha iyi tanımlayabiliriz. Bu noktaların varlığı ya da yokluğu, bulunduğu yer, özellikle QRS kompleksinin yapısı bize aritminin varlığı ve cinsi hakkında önemli bilgiler verir. Bu çalışmada farklı özelliklere odaklanılmıştır. Kullandığımız özellikler Hjorth tanımlayıcılar, sinyalin yapay ekg sinyali ile korelasyonu, içkin kip işlevinden standart sapma, gücün aktiviteye oranı ve standart sapmadan oluşmaktadır.

Elektrokardiyografi sinyallerinin incelenmesi ve aritmi analizi pek çok çalışmanın konusu olmuştur. Bunlardan bazıları aşağıda belirtilmektedir.

Ani kardiyak ölüm için riski için belirleyici olan T dalga alternansının incelendiği Barner ve ark. (2010) tarafından yapılmış çalışmada Ampirik Mod Ayırma (Empirical Mode Decomposition) tekniği ve Hjorth tanımlayıcılar kullanıldı. Gürültülü EKG verilerinde R tepe noktasını bulmak için yapılmış çalışmada De Cooman ve ark. (2014), tarafından hareketlilik (mobility) parametresi kullanıldı. Hjorth tanımlayıcılardan yararlanan başka bir çalışma Hidayat ve ark. (2015) tarafından yapıldı. Hjorth tanımlayıcıları, zaman alanı ve frekans alanı içinde ölçüldü, K ortalama kümeleme yöntemi kullanılarak kümelendi ve bu parametreler, özellik olarak işlev görebilecekleri konusunda

test edildi. Elektroensefalografi (EEG), elektromiyogram (EMG), akciğer ses işleme gibi pek çok biyolojik sinyal işleme alanlarında Hjorth tanımlayıcıların kullanımına rastlamak mümkündür.

Tele-tıp'ın kalp rahatsızlıkları alanındaki kullanımları ile ilgili çeşitli çalışmalar mevcuttur. Tele-kardiyolojiyi teknoloji ve kardiyoloji birleşmesi şeklinde özetleyebiliriz. Bu alanda yapılmış çalışmalardan biri Backman ve ark. (2010) tarafından yapılmış olan telekardiyoloji ile kalp bilgilerinin teknoloji yardımıyla bir uzmana aktarılmasının avantajları konusundaki çalışmadır. Bu konuda yapılmış çeşitli çalışmaları birleştiren ve kullanılmasının avantajlarını belirten bir başka çalışmada Hailey ve ark. (2004) tarafından yapıldı.

2. Materyal ve Metot

Elektrokardiyografi (EKG) tıp dünyasında en çok bilinen biyomedikal sinyaldir. Kalp hastalığının teşhisinde sıkça kullanılmaktadır. Özellikle aritmi teşhisinde sıkça kullanılır ve hastaya zarar verme ihtimali olmayan bir yöntemdir.


Yöntem dört aşamadan oluşmaktadır. İlk aşama EKG verisinin veri tabanından alınmasıdır. İkinci aşama verinin ön işleme sürecinden geçirilmesi, üçüncü aşama veriye ait özelliklerin hesaplanmasıdır. Son aşamada ise bu özellikler kullanılarak sınıflandırma yapılır.

Bu çalışma için geniş bir veri tabanı kullanılması hedeflenmiştir ve 98260 ekg sinyalinden oluşan bir veri tabanı oluşturulmuştur. Veri tabanı benzer çalışmalarda kullanılan veri tabanlarına göre daha büyüktür. Bu sayede sonuçlar daha güvenilir ve doğru olmaktadır.

Bu çalışmada daha hızlı hesaplanabilen özellikler kullanılmıştır. Bu sayede gerçek zamanlı olarak aritmi tespiti, yani bir kalp atışı süresinde kalp atışına ait özelliklerin hesaplanabilmesi hedeflenmiştir. Kullanılan özellikler Hjorth tanımlayıcılar, sinyalin yapay ekg sinyali ile korelasyonu, içkin kip işlevinden standart sapma, gücün aktiviteye oranı ve standart sapmadan oluşmaktadır. Bu özellikleri temel alarak sınıflandırma yapan başka bir çalışmaya rastlanmamıştır. Bu özelliklerin daha kolay ve hızlı bir şekilde hesaplanabilir olması sayesinde, aritmi hızlı tespit edilebilir ve gömülü sistemlerde bile rahat çalışabilir.

2.1. Veri Tabanı

EKG verisi MIT/BIH Aritmi veri tabanından alınmıştır. Önemli noktaları belirlenmiş örnek bir sinyal Şekil 1'de verilmiştir. Veri tabanında değişik aritmi çeşitleri bulunmaktadır. Veri seti 98260 RR tepe aralığından oluşmaktadır. 29746 tanesinde aritmi tespit edilmiştir. Geri kalan 68514 RR tepe aralığından 29746 tanesi seçilerek toplam 59492 adet veri sistemde kullanılmıştır. Sonrasında her sinyal beş eşit parçaya bölünerek özellikler hesaplanmıştır.



Şekil 1. Önemli noktaları işaretlenmiş bir EKG sinyali.

2.2. Önışleme

EKG kaydının otomatik analizi için yapılacak çalışmada sınıflandırmanın daha az hata ile yapılabilmesi için öncelikle sinyalin bir ön işlemeden geçirilmesi ve sinyaldeki gürültü ve istenmeyen etkilerden arındırılması gerekmektedir. Sinyalin bu yeni halinden çeşitli özellikler seçilerek sinyalin incelenmesi ve sınıflandırılması gerekmektedir. Bu konuda pek çok araştırmacı farklı özellikler ve sınıflandırma yöntemleri kullanarak ekg kayıtlarını incelemiş, pek çok olası aritmi tespitinde kullanabilecek yöntem önermiştir. Ancak ekg sinyalleri genel bir formu olmasına rağmen kişiden kişiye oldukça önemli değişiklikler gösterme eğilimi söz konusudur. Ayrıca ekg sinyalleri her zaman çeşitli şekillerde gürültüden etkilenir. Düşük frekans gürültüleri (vücut ve elektrot arasındaki empedans değişiminden kaynaklanır), kas gürültüleri (hastanın hareketlerinden kaynaklanır), elektromanyetik gürültüleri (çevredeki cihazların elektromanyetik alanlarından kaynaklanır) ekg kaydında karşılaştığımız en önemli gürültü kaynaklarıdır. Bu nedenlerden dolayı her dalga formunu inceleyebilen ve yüksek başarıya sahip otomatik bir aritmi sınıflandırma yöntemi geliştirilmesi oldukça zordur.

Sinyalden daha iyi yararlanabilmek için MIT/BIH Aritmi veri tabanından alınan EKG verimizi ön işlemeden geçirdik. Yüksek ve düşük frekanslı gürültüleri temizlemek için yüksek ve alçak geçiren filtreler tasarlandı. Tarak (comb) filtre şebeke frekansı için kullanılmıştır. Filtrelerden geçirilen sinyalden ortalaması çıkarılır ve standart sapmaya bölünürse, sinyal özellik çıkarmaya hazır olur.

2.3. Seçilen Öznitelikler

Hjorth tanımlayıcılarını hesaplama süreci varyansa dayandığı ve basit olduğu için hesaplamalar daha hızlı yapılabilmektedir. Bu parametreler etkinlik (activity), hareketlilik (mobility), karmaşıklık (complexity veya form factor) olarak bilinir.

Etkinlik sinyal gücünü gösterir. Zaman fonksiyonun varyansı olarak ifade edilir.

Etkinlik (Activity)

$$A_x = \sigma_x^2 \quad (1)$$

Hareketlilik güç spektrumun standart sapmasının oranını veya ortalama frekansı ifade eder.

Hareketlilik (Mobility)


$$M_x = \sigma_{x'} / \sigma \quad (2)$$

Karmaşıklık frekanstaki değişimi gösterir. Bu parametre sinyalin saf sinüs dalgası ile benzerliğini karşılaştırır.

Karmaşıklık (Complexity, Form Factor)

$$FF = M_{x'} / M_x = (\sigma_{x''} / \sigma_x) / (\sigma_{x'} / \sigma_x) \quad (3)$$

Hjorth değişkenlerini özellik olarak kullanırsak (Activity Mobility Form factor), ve her RR aralığında sinyali parçalayarak Activity Mobility Form factor parametreleri hesaplayarak oluşturduğumuz örnek veri tablosunu kullanarak oluşturulmuş karar verme ağacı (Decision Tree) Şekil 2’de verilmiştir verilmiştir.



Şekil 2. Hjorth değişkenleri ile örnek veriler kullanılarak oluşturulmuş karar verme ağacı.

Ampirik Mod Ayırma tekniği (Empirical Mode Decomposition) veya diğer şekilde Hilbert–Huang dönüşümü sinyali içkin kip işlevlerine (intrinsic mode functions (IMF)) ayırma yoludur. Doğrusal olmayan ve durağan olmayan ve veriler için iyi çalışacak şekilde tasarlanmıştır. IMF'lerin uzunluğu orijinal sinyal ile aynı olduğundan ve sinyal zaman alanında ayrıştırıldığından değişen frekansın özelliklerini korur. Ampirik Mod Ayırma tekniği kullanarak, karmaşık veri kümeleri sonlu ve çoğu zaman az sayıda bileşene ayrılabilir. Bu bileşenler yani içkin kip işlevleri, orijinal sinyal için tam ve neredeyse dik bir temel oluşturmaktadır.

Sinyalin yapay bir EKG sinyali ile kolerasyon değeri sınıflandırmada kullandığımız bir diğer özelliktir. Kolerasyon bir ilişkiyi ifade eder ve bu ilişkinin gücünü ve yönünü belirtir. Korelasyon katsayısı hesaplanması

$$r = \frac{\sum_m \sum_n (A_{mn} - \bar{A})(B_{mn} - \bar{B})}{\sqrt{(\sum_m \sum_n (A_{mn} - \bar{A})^2)(\sum_m \sum_n (B_{mn} - \bar{B})^2)}} \quad (4)$$

Ekg sinyal şablonu ve sinyalin ilişkisini kolerasyon değeri olarak kullanabiliriz. Sağlıklı sinyaller ve hastalıklı sinyaller için şablonlar oluşturularak, korelasyon ile ilişkileri tanımlanmış ve özellik olarak kullanılmıştır.

Sinyal gücünün aktiviteye oranı ve standart sapma kullandığımız diğer özelliklerdir.

2.4. Sınıflandırma

Önerilen yöntemin eğitim ve test performansını ölçmek için Matlab kullanılmıştır. Veri setinin yarısı eğitim olarak diğer yarısı da test için seçilmiştir. Eğitimde 10 kat katlama (10 fold) yaklaşımı

kullanılmıştır. Sınıflandırma tiplerine göre eğitim doğruluğu ve hassaslık, özgünlük, doğruluk yüzdeleri Tablo1’de verilmiştir.

Sınıflandırma aşamasında karar ağaçları (decision trees) için maksimum bölünme sayısı basit ağaç (simple tree) için 4, orta ölçekli ağaç (medium tree) için 20, kompleks ağaç (complex tree) için 100 olarak belirlenmiştir. Karar ağaçlarında bölünme ölçütü Gini çeşitlilik indeksi olarak seçilmiştir.

Destek vektör makinelerinde (Support Vector Machines, SVM) çekirdek ölçek modu doğrusal SVM (Linear SVM), kuadratik SVM (Quadratic SVM), kübik SVM (Cubic SVM) için otomatik, Hassas Gauss SVM (Fine Gaussian SVM) için 1.6, Orta Ölçekli Gauss SVM (Medium Gaussian SVM) için 6.6, kaba Gauss SVM (Coarse Gaussian SVM) için 26 olarak belirlenmiştir. Kernel fonksiyonu Linear SVM’de doğrusal, Quadratic SVM’de kuadratik, Cubic SVM’de kübik, Fine Gaussian, Medium Gaussian, Coarse Gaussian SVM’de gauss olarak belirlenmiştir. SVM’de kutu kısıtlama düzeyi 1 olarak seçilmiştir.

En yakın komşuluk (Nearest Neighbor), için, mesafe önemi eşit seçilmiştir. Hassas KNN (Fine KNN), orta ölçekli KNN (Medium KNN) , kaba KNN (Coarse KNN), ağırlıklı KNN (Weighted KNN) için metrik mesafe öklid, kosinüs KNN (Cosine KNN) için kosinüs, kübik KNN (Cubic KNN) için minkowski olarak belirlenmiştir. Komşu sayısı Fine KNN için 1, Medium, Cosine, Cubic, Weighted KNN için 10, Coarse KNN için 100 seçilmiştir.

Grup sınıflandırmada (Ensemble classifiers) Hızlandırılmış Ağaçlar (Boosted Trees) için grup metodu AdaBoost, öğrenme tipi karar ağacı, öğrenen sayısı 30, öğrenme oranı 0.1, maksimum bölünme sayısı 20 seçilmiştir. Bağlı Ağaçlar (Bagged Trees) için grup metodu Bag, öğrenme tipi karar ağacı, öğrenen sayısı 30 seçilmiştir. Altuzay Diskriminant (Subspace Discriminant) için grup metodu altuzay, öğrenme tipi diskriminant, öğrenen sayısı 30, altuzay boyutu 22 seçilmiştir. Subspace Discriminant için grup metodu altuzay, öğrenme tipi en yakın komşu, öğrenen sayısı 30, altuzay boyutu 22 seçilmiştir. RUSBoosted Trees için grup metodu RUSBoost, öğrenme tipi karar ağacı, öğrenen sayısı 30, maksimum bölünme sayısı 20 öğrenme oranı 0.1 seçilmiştir. Discriminant Analizde düzenleme için çapraz kovaryans kullanılmıştır.

Grup sınıflandırma (Ensemble classifiers) altında geliştirilmiş ağaç (Boosted Trees), torbalı ağaçlar (Bagged Trees), altuzay ayırım (Subspace Discriminant), altuzay KNN, RUS geliştirilmiş ağaç (RUS Boosted Trees) sınıflandırma yöntemleri bulunmaktadır. Son olarak da lojistik regresyon (Logistic Regression) sınıflandırması kullanılmıştır.

Tablo 1. Sınıflandırma tiplerine göre eğitim doğruluğu ve hassaslık, özgünlük, doğruluk yüzdeleri.

Sınıflandırma	Eğitim		Test	
	Doğruluk	Doğruluk	Hassaslık	Özgünlük
Nearest Neighbor (En Yakın Komşu)				
Fine KNN	96.2±1.1	90.1±4.5	84.1±13	94.6±2.1
Medium KNN	95.7±0.8	89.3±4.9	81.2±12	97.4±0.7
Coarse KNN	94.6±1.2	86.5±3.7	77.4±11	94.6±0.5
Cosine KNN	96.0±2.6	87.3±4.6	80.1±13	94.8±4.0
Cubic KNN	95.0±2.9	89.1±4.0	85.6±4.0	92.2±4.0
Weighted KNN	92.7±5.1	87.0±5.0	81.4±12	91.0±6.1
Support Vector Machines(Destek Vektör Makineleri)				
Linear SVM	85.5±3.9	79.3±0.6	74.4±1.3	84.6±1.6
Quadratic SVM	92.5±1.6	88.2±2.9	82.6±7.6	93.2±1.9
Cubic SVM	79.5±5.6	72.4±4.9	64.1±6.1	84.8±4.2
Fine Gaussian	92.5±1.8	84.1±6.5	72.2±6.4	94.8±1.9
Medium Gaussian	95.6±2.4	89.4±2.7	78.4±5.2	95.2±2.3
Coarse Gaussian	90.0±2.1	81.4±1.6	74.6±3.9	88.4±1.8
Ensemble classifiers (Grup Sınıflandırma)				
Boosted Trees	87.2±5.2	79.1±0.9	65.2±1.8	90.0±2.0
Bagged Trees	98.8±1.4	92.6±6.1	86.8±7.9	95.6±3.7
Subspace Discriminant	79.7±2.4	72.5±2.6	66.1±4.2	80.2±5.6
Subspace KNN	81.0±4.2	73.8±3.2	62.8±6.8	86.6±2.8
RUSBoosted Trees	77.8±8.6	68.0±4.8	55.2±9	83.4±3.0
Decision Trees (Karar Ağaçları)				
Simple Tree	79.6±2.9	75.8±2.1	66.8±3.8	81.6±2.5
Medium Tree	86.3±3.4	79.9±2.3	68.2±4.2	92.4±2.8
Complex Tree	89.7±3.2	81.9±2.6	71.9±3.8	95.0±2.0
Logistic Regression (Lojistik Regresyon)				
Logistic Regression	87.9±1.9	79.9±3.0	81.5±4.8	79.1±2.5
Discriminant Analysis (Diskriminant Analiz)				
Linear Discriminant	87.4±3.2	78.1±3.4	72.5±3.2	82.1±3.9
Quadratic Discriminant	85.6±3.9	77.2±3.6	72.9±4.2	81.2±3.8

3. Bulgular ve Tartışma

Yapılan çalışmada diğer çalışmalara göre daha geniş bir veri kümesinde çalışma yapılmıştır. Bu sonuçların daha gerçekçi olmasını sağlamıştır. Ancak veri miktarının daha da artırılması gerekmektedir. Ayrıca diğer çalışmalarda tek bir sınıflandırma yöntemi vurgulanırken, bu çalışmada yaygın sınıflandırma yöntemlerinin çoğu test edilmiştir. Sonuçlar umut verici seviyededir. Ancak geliştirilmesi gerekmektedir. Özellik sayısı PCA gibi bir yöntemle azaltılması performansı artırıp, çalışmanın özgünlüğünü geliştirecektir.

4. Sonuçlar ve Öneriler

Değişik sınıflandırma incelediğimizde grup sınıflandırma (Ensemble classifiers) altındaki torbalı ağaçları (Bagged Trees) kullandığımızda diğerlerinden daha iyi eğitim ve test başarısı elde

ettik. Ayrıca hassaslık değerinin daha iyi olduğu görüldü. Özgünlük değeri olarak en yakın komşu (Nearest Neighbor) altında orta ölçekli KNN (Medium KNN) sınıflandırma yöntemi diğerlerinden daha iyi bir değere sahip olduğu görüldü.

Genel anlamda torbalı ağaçları (Bagged Trees) sınıflandırma yöntemi başarılı bulunmuştur. Bu başarıyı özelliklerimizi geliştirerek, farklı karar verme mekanizmaları kullanarak artırmamız mümkündür. Bu çalışmada aritmi tespiti yapılmakta ama aritminin cinsi henüz tespit edilmemektedir. Bu çalışmanın aritmi tipini tespit edecek şekilde geliştirilmesi planlanmaktadır.

Tele-tıp uygulamalarında hızlı olmak önemlidir. Bu sayede erken teşhis mümkün olmakta, kalp krizi, anevrizma ve diseksiyon gibi ölümcül kalp rahatsızlıklarından ölen kişi sayısını azaltmak hedeflenmektedir. Hızlı olabilmeye en önemli aşama çabuk hesaplanabilen özellikler seçebilmektir. Bu çalışmada R tepe noktalarının hesaplanması gerekmemektedir ancak R tepe noktalarının hesaplanacağı koşulda bile RR tepe noktaları arası sinyalin özelliklerinin hesaplanması için bir saniye civarında bir süre yeterli olmaktadır. Kod üzerinde performansı artıracak düzenlemeler yaparak ve C koduna çevirerek süreyi daha da azaltmak mümkün olabilir.

Teşekkür

Yazarlar 1003 programı kapsamındaki 114E452 numaralı projeye desteklerinden dolayı TÜBİTAK'a teşekkür ederler.

Kaynaklar

- Backman, W., Bendel, D., and Rakhit, R. (2010). The telecardiology revolution: improving the management of cardiac disease in primary care. *Journal of the Royal Society of Medicine*, 103(11), 442-446.
- Barner, K. E., Blanco-Velasco, M., Cruz-Roldan, F., and Godino-Llorente, J. I. (2010). Nonlinear trend estimation of the ventricular repolarization segment for T-wave alternans detection. *IEEE Transactions on Biomedical Engineering*, 57(10), 2402-2412.
- De Cooman, T., Goovaerts, G., Van Huffel, S., Varon, C., and Widjaja, D. (2014, September). Heart beat detection in multimodal data using signal recognition and beat location estimation. *In Computing in Cardiology Conference (CinC)*, 2014 (pp. 257-260). IEEE.
- Debuse, J., Lawley, M., and Shibl, R. (2013). Factors influencing decision support system acceptance. *Decision Support Systems*, 54(2), 953-961.
- Hailey, D., Ohinmaa, A., and Roine, R. (2004). Published evidence on the success of telecardiology: a mixed record. *Journal of telemedicine and telecare*, 10(1_suppl), 36-38.
- Hidayat, R., Nugroho, H. A., and Rizal, A. (2015, August). Determining lung sound characterization using Hjorth descriptor. *In Control, Electronics, Renewable Energy and Communications (ICCEREC)*, 2015 International Conference on (pp. 54-57). IEEE.
- Wootton, R. (2012). Twenty years of telemedicine in chronic disease management—an evidence synthesis. *Journal of telemedicine and telecare*, 18(4), 211-220.