



Yapay Zeka Tabanında Otomatik QT zaman aralığı Ölçümü

Automatic QT interval Measurement Based on Neural Networks

Mehmet İŞCAN¹, Cüneyt YILMAZ¹, Faruk YİĞİT¹

¹Mekatronik Mühendisliği Bölümü, Yıldız Teknik Üniversitesi, İstanbul, Türkiye
{miscan,cuneyt,fyigit}@yildiz.edu.tr

Özetçe— Günümüzde olasılıksal yapay ağlar sinyal işlemede zamana göre değişen deterministik olmayan sinyallerin sınıflandırılmasında sıklıkla kullanılmaktadır. Bu çalışmada, önemli elektrokardiyogram aralıklarından olan QT zaman aralığının tespiti amacıyla Gauss karışım modeliyle sınırlandırılmış yapay ağlar metodu önerilmektedir. Bu bağlamda, hem QRS kalıbının başlangıç noktasını, hemde T-dalgasının sonunu aynı anda bulabilen bir yapay sinir ağı modeli kurulmuştur. Ayrıca yapay ağın eğitimi için standard bir Pan-Tompkins algoritması kullanılmıştır. Sunulan algoritma, PhisoNet QT-veritabanından elde edilmiş sinyallerde denenmiştir. Algoritmanın tanıma sonuçları sırası ile gerçek kişilerden elde edilmiş veriler için 9.14 ortalama hata ve 14.45 standart sapma hatası ile, QT-veritabanı içinse 7.22 ortalama hata ve 11.36 standart sapma hatası ile tespit edilmiştir. Ayrıca, önerilen algoritma herhangi bir filtreleme işlemi içermemekte ve frekans değişimlerinden bağımsız olarak çalıştırılmaktadır. Diğer yandan herhangi bir derivatif ayar veya gecikme periyodu işlemine tabi tutulmamaktadır. Bu sonuçlardan yola çıkarak, sunulan algoritma değişik hastalık türlerindeki EKG sinyallerinin QT zaman aralığının tespitini yüksek performansta gerçekleştirebilmiştir.

Anahtar Kelimeler — EKG sinyali, QT zaman aralığı, Gauss Karışım Modeli, Yapay Ağlar, EKG sinyali sınıflama

Abstract—Nowadays, probabilistic neural networks have been utilized to classify non-deterministic and non-stationary signals. In this study, the method consisting of neural network constrained by Gaussian mixture model was proposed to determine QT interval which is the most important duration in ECG. In this context, the neural network was established to find both the onset of QRS complex and T-wave end. In order to obtain training data, standard Pan-Tompkins algorithm was used. The presented algorithm was tested with ECG signal both obtained by PhisoNet QT-database and real ECG device measurement. The algorithm had an achievement at 9.14 mean error and 14.45 standard deviation error for real subjects, at 7.22 mean error and 11.36 standard deviation error. It is noteworthy that the proposed algorithm is applied regardless

of frequency change without filtering. In addition, the algorithm does not require refractory period searching and derivative calculation to detect the boundary of ECG signal. As a result, the presented algorithm can be performed to measure QT interval in various kinds of abnormalities.

Keywords—QT interval, ECG, ECG signal classification, Gauss Mixture Model, Neural Network

I. GİRİŞ

Elektrokardiyogram (EKG) sinyali kalbin elektriksel aktivitesini gösteren bir betimleme olarak kullanılmaktadır. Kalbin belirli periyotlarda kasılmasını kaydedip doktorlara vermektedir. Bu periyotlardan biri olan QT zaman aralığı ventriküllerin kasılıp gevşemesinin süresini göstermektedir ve birçok kalp ritim bozukluğunun tespiti ile ilişkilendirilmiştir [1]. Bundan dolayı elle yapılan ölçümler ile QT zaman aralığı tespiti gerçekleştirilmektedir. Ancak bu ölçümler gürültü seviyesi, kağıt hızı, yükseltme katsayısı ve okuyucu kişinin gözlemlerine göre değişmektedir [2]. Ayrıca elle yapılan ölçümlerin çok uzun kayıtlarda uygulanması pek pratik olmamaktadır[3]. Bundan dolayı otomatik olarak QT zaman aralığı ölçümü yapabilmeye ihtiyacı duyulmuştur.

Bundan dolayı günümüze değin çeşitli çalışmalar yapılmıştır. McLaughlin ve diğerleri üç algoritma üzerinde bir çalışma yapmışlardır(EKG'nin türevi, T dalgasının izoelektrik seviye kesişmesi ve T dalgasının eşik değerinin uygulanması) [4]. Hesaplama maliyeti düşük olmasına rağmen isoelektrik seviyeye bağlı olunması, T dalgasının sürekli değişmesinden dolayı her kayıt üzerinde iyi performans elde edilememiştir. Zhou ve diğerleri ise yardımcı çizgiler kullanarak QT zaman aralığını üç farklı tipte EKG kayıt cihazında denemişlerdir. Yöntem basit olmasına rağmen, EKG'nin isoelektrik seviyesine bağımlılığı, T-dalgasının eğiminin değişmesinden dolayı hatalı sonuçlar elde edilmiştir [5].

Bunların dışında bazı çalışmalar dalgacık modeli ve frekans tabanında gerçekleştirilmiştir. Chen ve diğerleri



Sistem Modelleme 1

1. Gün / 27 Ekim 2016, Perşembe

kalman filtresi ve dalgacık modeli yardımı ile local ve minimum ve maksimum noktalara bakarak QT zaman aralığını tespit etmişlerdir [3]. Ancak frekansa bağımlığın olması, bazı T-dalgalarının filtreleme işlemi ile ortadan kalkmasından dolayı tam performansta bir değerlendirmeye ulaşamamışlardır. Aynı şekilde Chesnokov ve diğerleri sürekli ve fourier dalgacık modeli kullanarak farklı frekans aralıklarında QT zaman aralığını aramışlar, ancak yukarıda açıklanan sebeplerden dolayı yüksek performansta tanıma yapmalarına rağmen bazı sinyallerde doğru sonuca ulaşamamışlardır [6].

Diğer yandan Hayn ve diğerleri Gauss olasılık dağılımını şablon olarak kullanıp T dalgasının sonunu belirli bir standart değerde tespit etmişlerdir. Ancak bu yöntemde de standard bir QRS ve T dalga maksimum noktasının öncelikle tespit edilmesini gerekli kılmıştır [7]. Bunun dışında, Clifford ve diğerleri matematiksel model tabanında eğri uydurma yöntemi kullanarak QRS ve T dalga sonunu tespit etmişlerdir [8].

Bu yöntemlerden farklı olarak yapay ağırlar tabanında Leon ve diğerleri T dalgasının sonunu tespit etmeye çalışmışlardır [9]. İki RR zaman aralığının arasında pekçok T dalgasının eğitimi yapılmış ve yüksek performansta tanıma işlemi gerçekleştirilmiştir.

Bu çalışmada Gauss karışım modeli ve logaritmik lineerleştirme tabanında iki farklı kalıp olan QRS ve T dalgasının sınıflamasını yapabilen bir algoritma önerilmiştir. Algoritmanın tabanı Tsuji ve diğerleri tarafından yayınlanan logaritmik lineerleştirilmiş Gauss karışım modelinden (LLGKM) alınmıştır [10,11]. Ek olarak eğitim verileri standard Pan-Tompkins algoritmasından elde edilmiş ve yapay ağı eğitilmiştir. Ayrıca QT zaman aralığının belirlenmesi için algoritmanın çıktılarının başlangıç ve bitiş noktaları işaretlenmiştir. İşcan ve diğerleri tarafından bu algoritma çeşitli EKG kalıpları üstünde denenmiş ve yüksek performansta tanıma işlemi gerçekleştirilmiştir [12,13,14]. Sunulan algoritma örnekleme frekansından, değişen kişilerin EKG sinyallerinden bağımsız işletilebilmekte, ve herhangi bir filtrelemeye ihtiyaç duymamaktadır. Ayrıca önemli bir özellik olarak tanınmanın tek bir katsayı matrisi ile yapılması, gerçek zamanlı uygulamalar için önemli bir araç olarak gösterilebilmektedir.

II. METOT

A. Standard Pan-Tompkins Algoritması

Standard Pan-Tompkins algoritması derivatif yöntemlere dayanarak EKG'nin QRS kompleksinin tespitinin yapılabilmesi için geliştirilmiştir [15]. Bu algoritmanın kullanımı ile eğitim verileri olarak QRS kompleksler ve T dalgaları elde edilmiştir. Detaylı bilgi verilen referansta mevcuttur.

B. LLGKM Yapısı

LLGKM yapısı [10] Gauss karışım modelinin parametrelerinin yapay sinir ağı katsayılarına çevrilmesi

ile oluşturulmaktadır. Verilen eğitim setlerinden oluşturulan sınıflar için sonsal olasılıklar üretilerek tanıma işlemi gerçekleştirilmektedir. Geri yayımlı öğrenme metodu ile eğitim verileri yapay ağı eğitmekte ve Gauss karışım modelinin matematiksel sınırları kaldırılmaktadır.

Önerilen algoritma sınır koşullarının verilmesi açısından gözetimsiz olarak, yapay zeka tarafından gözetimli olarak eğitilmektedir. Sunulan algoritmanın belirli T ve QRS kompleks kalıplarını tanıması için Pan-Tompkins algoritmasından elde edilen veriler öncelikle Gauss karışım modelinde karıştırılmak, oluşan küme diyagramını temsil eden yapay zeka katsayıları dönüşümü yapılmaktadır. Bu dönüşümler yapıldıktan sonra algoritma yapay zeka katsayılarını eğitecek şekilde tekrardan sırası ile Pan-Tompkins algoritmasından elde edilen QRS ve T dalgaları ile eğitilmektedir.

III. DENEY

Deneyler QT-veritabanından ve gerçek kişilerden elde edilmiş veriler ile yapılmıştır. Deneylerde 4 gerçek kişiden alınmış V2 kanalı, ve QT-veritabanından elde edilen verilerden bütün açık EKG kanalları değerlendirmeye alınmıştır [16]. QT-veritabanında işaretlenmiş alt veritabanlarından bazıları sonuçlara sinyal özelliklerinden dolayı sonuçlara katılmamıştır.

EKG cihazı (Pulse&More Corporation) 250 Hz örnekleme frekansında ve 0-100 Hz aralığında filtreleme yapmaktadır. Gerçek kayıtlarda 5120 elle işaretlenmiş kalp atımı incelenmiştir.

Normal kullanımdan farklı olarak, yapay ağı öğrenimi iki kademeli olarak tanımlanmıştır. Öncelikle QRS kompleks'in eğitim verileri Pan-Tompkins algoritmasından elde edilmiş ve oluşturulan iki sınıftan birine QRS, diğer sınıfa ise T-dalgaları eğitim için verilmiştir. Böylelikle QRS kompleks ve T-dalgası ayrı ayrı verilere entegre edilmiştir. LLGKM algoritması için eğitim parametreleri aşağıda verilmiştir.

Parametreler	Öğrenme Oranı	Maliyet	Öğrenme Vektörü
QRS	0.001	0.001	[1 0]
T	0.001	0.001	[0 1]

Tablo 1. Eğitim Parametreleri

Tablo 1'de verilen öğrenme parametreleri ağı eğitime önemli bir etkide bulunmaktadır. Normal olarak eğitim setleri standart değerlerden seçildiği için durağan olmayan EKG sinyalinde tanıma işlemi bazen hataya uğramaktadır. Çünkü eğitim verileri çok sıkı bir şekilde ağı düzenlerse sadece bu kalıplarda çalışacak, ancak çok küçük değişikliklerde bile agresif davranacaktır. Bundan dolayı öğrenme oranı ve maliyet oranı 0.0001 seviyesinde tutulmuştur. Algoritmanın genel karakteristiği gereği bu şekilde belirli bir alan agresif olmayan katsayılar ile taranabilecektir.


Pan-Tompkins algoritmasından elde edilen veriler ile toplam olarak 30 adet elle işaretlenen veri QRS ve T-



Sistem Modelleme 1

1. Gün / 27 Ekim 2016, Perşembe

dalgasını eğitim işleniminde kullanılmıştır. Şekil 1'de algoritmanın örnek sonuçları gösterilmiştir.



Şekil 1. QT-Veritabanı QRS Kompleks ve T-dalga Tanıma Sonuçları

Şekil 1'de düşey eksen normalize edilmiş EKG sinyalinin ve olasılık çıkışı göstermekte, ve yatay eksen ise zamanı temsil etmektedir. Algoritma çıkış olarak gürültülü bir olasılık sonucu vermektedir. Bundan dolayı eşik değeri uygulaması ile sinyal düzeltilmiştir. Eşik değerinin formülü aşağıda verilmiştir.

$$TH = O_{QRS} * 0.1 \quad (1)$$

Burada O_{QRS} herbir QRS kompleksin olasılık değeridir. %10 oranında bir eşik değeri uygulaması ile sinyalin sonuçları düzeltilmiştir. Bu düzeltme ile sinyalin olasılık değerlerinin başlangıç ve bitiş noktaları işaretlenmiştir. Burada ki sayı yapılan testler sonucunda deneysel olarak seçilmiştir. Bu işaretlemelere göre gerçek verilerden elde edilen sonuçlara göre QT intervalin hata oranları Tablo 2'de verilmiştir.

	Gerçek Kişiler	QT-Veritabanı
Ortalama Hata	9.14	7.22
Standard Sapma Hatası	14.45	11.36

Tablo 2. QT Zaman Aralığı Test Sonuçları

Bu sonuçlara göre ortalama hata değeri 9.14 ve standart sapma değeri 14.45 olmuştur. Gerçek zamanlı kişilerden elde edilen veriler herhangi bir hastalık taşımayan insanlardan seçilmiştir. Diğer yandan QT-veritabanından betimlenen sonuca göre 7.22 ortalama değer ve 11.36 standart sapma değer hatası ile tespit işlemi gerçekleştirilebilmiştir. Bu sonuçlara göre işlemlerin gerçekleşme kabiliyetleri standart hata değerlerinin tespitleri ile alakalı anlamlı yorumlar vermektedir. Gelecek bölümde bu bölümün tartışması yapılacaktır.

IV. TARTIŞMA

Bu çalışmada olasılıksal yöntemler ile sınırlandırılmış yapay zeka tabanlı QT zaman aralığı testi yapabilen ve bu testlere dair bize zaman aralıklarını söyleyebilen bir algoritma tasarlanmıştır. Bu metod ile standart QT veritabanı incelenmiş, ayrıca gerçek kişilerden alınan veriler ile çeşitli çalışmalar gerçekleştirilmiştir.

QT veritabanı kayıtları 6 çeşit T-dalga formu içermektedir, bunlar sırası ile normal, ters çevrilmiş, sadece yükselen, sadece azalan, iki fazlı negatif pozitif ile iki fazlı pozitif negatif sinyaller olarak sıralanmaktadır.

Kayıtlar incelendiğinde, MIT-BIH ST-T ve MIT ani ölüm veritabanları işlemlerden çıkarılmıştır. Sebebi ise hastalıklardan dolayı ST-T segmentinde oluşan bozulmalar ve T dalgasının son noktasının gözlemle bile doğru bir şekilde okunamamasıdır. Diğer kayıtlarda sinyal bozuk olmasına rağmen herhangi bir sorun ile karşılaşılmaştır. Çünkü sinyal hem yüksek değerde olması hemde isoelektrik seviyesinin düzgün bir düzeyde olması bize çok büyük kolaylık sağlanmaktadır. Bunun dışında ters çevrilmiş sinyallerde algoritma hem kovaryans hemde ortalama değere göre eğitim işlemini gerçekleştirdiği için ortalama değerler tutmasa bile kovaryans yani şekil vektörüne göre yapay zeka ağında tanıma işlemini gerçekleştirebilmiştir. Aynı şekilde sadece yükselen ve sadece azalan dalga formlarında algoritmanın belirli bir kalıbı değil, belirli alandaki EKG veri değerlerinin küme diyagramlarında araması yapıldığı için herhangi bir sorun ile karşılaşılmaştır.

Algoritmanın güçlü bir özelliği olarak herhangi bir filtreleme işlemine tabi tutulmamasıdır. EKG filtre değerleri T-dalgasının sonu için 0.01, 0.02, 0.25, 0.5-40 Hz değerleri arasında filtreleme işlemi gerçekleştirilmektedir [17]. Bu işlem yapıldığında zaten hassas olan T dalgasının sonu kayma yapmaktadır. Sunulan algoritma da verilerin sadece kendi değerleri ile belli bir küme diyagramı içerisinde değerlendirilmesi amaçlanmıştır. Yani belirli bir kalıbın verilerin belirli bir alana girip girmediği test edilmiş, bu test edilen alan ise geniş bir veri kümesi ile eğitildiğinde değişen T-dalga formları için bazı veriler yanlış gelse bile kararlı hale gelmiştir. Tanıma oranı olarak çok büyük bir olasılıksal değerlere sahip olunamasa bile doğru bir biçimde değerlendirilmiştir. Ayrıca bu katsayıların tek bir matriste toplanması, sadece veri girişlerine göre bir çarpım işlemi yapılması algoritmanın gerçek zamanlı uygulamalarda mükemmel bir araç olarak kullanılabileceğini göstermektedir.

Önceki metodlar ile karşılaştırıldığında derivatif yöntemler değişen sinyal formlarına göre gürbüz bir sonuç sağlamamaktadır. Çünkü sinyalin herhangi bir değişimi, algoritmanın yanlış sonuçlar vermesine sebep olmaktadır. Sunulan algoritmada değişen kalıplar için olasılık değerleri bu sorunu çözmektedir. Ayrıca derivatif yöntemlerde sinyal büyüklüğü, kendi içindeki değişimi ve uygulanan eşik değeri algoritmanın performansını doğrudan etkilemektedir [4, 5, 15, 18]. Ayrıca filtreleme işlemlerine bağlı olarak bu algoritmaların performansları çok büyük bir şekilde etkilenmektedir.

Dalgacık modeli ile oluşturulmuş algoritmalar incelendiğinde frekansa olan bağımlılık algoritmayı ciddi biçimde etkilemektedir. Kişiyi bağımlılık, sinyalin kendi içindeki değişimleri ve diğer yandan örnekleme frekansı önemli bir ölçüt olarak karşımıza çıkmaktadır [7,8].

Bunun yanında sunulan algoritma bazı avantaj ve dezavantajlara sahiptir. Elde edilen verilerin birbirine çok yakın değerlerde olması, QRS kompleks ve T dalgasının



Sistem Modelleme 1

1. Gün / 27 Ekim 2016, Perşembe

şekil olarak benzer olması, yani Gauss ortalama değer parametrelerinin birbirine yakın fakar kovaryans vektörünün birbirinden farklı olması beklenti maksimizasyonunda yakınsama sorununu ortaya çıkarmaktadır. Bundan dolayı algoritma uygun yakınsama yapılarına kadar işletilmektedir. Ayrıca sonuçlar grafikler üzerinde incelendiğinde bazı QRS ve T dalgalarının birbirine karıştığı gözlemlenmiştir. Bunun sebebi ise algoritmanın benzer parametre değerleri ile ilk değer ataması (gözetimsiz öğrenme) olduğu tespit edilmiştir.

V. SONUÇ

Bu çalışma, önemli bir EKG zaman aralığı olan QT süresinin otomatik olarak saptanması için Gauss karışım modeli ve yapay zeka tabanında sınıflama yapabilen bir algoritma önermektedir. Bu algoritmanın temel kısmı daha önce çeşitli biyolojik sinyallerin sınıflama işleminde de kullanılmıştır [19,20]. Algoritma olasılık tabanında sonuçları bildiren ve eğitim işlemlerinin gözetimli olarak yapılabileceği bir taban sunmaktadır.

Testler iki farklı kaynak kullanılarak yapılmıştır. Bunlardan birisi gerçek kişilerden alınmış veriler, diğeri ise PhysioNet QT veritabanından elde edilmiş hastalıklı ve hastaliksız veriler üzerinde gerçekleştirilmiştir. Gerçek kişilerden alınan sonuçlara göre 9.14 ortalama hata ve 14.45 standard sapma hatası ile algoritmanın çalıştığı gözlemlenmiştir. Bunun sebebi olarak kişiden alınan her QT zaman aralığının değerlendirilmesi, ve ayrıca gürlüğe bağlı olarak taban oynaması da bu performansı etkilemektedir. Diğer yandan QT veritabanı üzerinde yapılan testlerde 6 farklı T dalga modeli ve 2 farklı QRS kompleks tipi 7.22 ortalama hata ve 11.36 standard sapma hatası ile işlemler gerçekleştirilmiştir. İşaretleme işlemleri gerçek verilerde uzman doktor tarafından, QT veritabanında ise PhysioNet'in kendi işaretleme tarafından sağlanmıştır.

Algoritma tek bir yapay sinir ağı katsayısına sahip olmasından dolayı ve herhangi bir filtreleme işlemi ile belirli derivatif yöntemlerin kullanılmamasından dolayı gerçek zamanlı uygulamalarda işlem maliyetini azaltmak ve doğruluğu arttırmak için mükemmel bir araç olarak karşımıza çıkmaktadır. Ancak QRS kompleks ve T dalgasının şekil benzerliğinden dolayı bazı yakınsama problemlerine de maruz kalmaktadır. Ayrıca olasılık tabanında sonuç alındığı için eşik değeri ile algoritmanın sonuçlarının düzeltilmesine ihtiyaç duyulmaktadır.

İleri ki çalışmalarda eşik değerinin devreden çıkarılması, algoritmanın yapısı olarak noktasal değil, birden çok veri içeren zaman serileri üzerinde çalışılması için çalışılacaktır. Ayrıca farklı tür sinyallerin incelenmesi ve hastalık tespiti için uygun bir araç olarak algoritmanın iyileştirilmesi amaçlanmaktadır.

KAYNAKÇA

- [1] McLaughlin N.B, Campbell R.W.F, Murray A.; "Accuracy of four automatic QT measurement techniques in cardiac patients and healthy subjects". Heart. 76:422-426., 1996
- [2] Murray A, McLaughlin N.B, Bourke J.P, Doig J.C, Furniss S.S, Campbell R.W.F; "Errors in manual measurement of QT intervals". Br Heart J. 71:386-390.,1994
- [3] Chen, X., Xie, W., Dong, L., Tin, Z. K., & Sankaranarayanan, M. "Reliable automated QT interval measurement for clinical evaluation". In 2006 Computers in Cardiology, pp 373-376,2006
- [4] McLaughlin, N. B., Campbell, R. W. F., & Murray, A. "Accuracy of automatic QT measurement techniques". In Computers in Cardiology 1993, Proceedings. (pp. 863-866).,1993
- [5] Zhou, S. H., Helfenbein, E. D., Lindauer, J. M., Gregg, R. E., & Feild, D. Q. "Philips QT interval measurement algorithms for diagnostic, ambulatory, and patient monitoring ECG applications". Annals of Noninvasive Electrocardiology, 14(s1):3-8., 2009.
- [6] Mneimneh Ma et. al., "Integrative Technique for the Determination of QT Interval" Comput. in Card., 33:329-332.,2006
- [7] Hayn D, Kollmann A. and Schreier G. , "Automated QT interval measurement from multilead ECG signals Comp. Card. 33 381-385, 2006
- [8] G. D. Clifford and M. Villarreal, "Model-based determination of QT intervals," Comput. Cardiol., 33:357-360,2006
- [9] Su, A. A., Molina, D. M., Goovaerts, G., Vandeput, S., & Van Huffel, S. (2015, September). "Neural network approach for T-wave end detection: A comparison of architectures". Computing in Cardiology, pp. 589-592,2015
- [10] Tsuji, T., Fukuda, O., Ichinobe, H., & Kaneko, M. "A log-linearized Gaussian mixture network and its application to EEG pattern classification". IEEE Trans. on Sys., Man, and Cybern., Part C, 29(1):60-72. 1999.
- [11] Tsuji, T., Bu, N., Fukuda, O., & Kaneko, M. (2003). "A recurrent log-linearized Gaussian mixture network". IEEE Trans. on Neural Net., 14(2), 304-316.
- [12] İscan, M., Yılmaz C., Yigit, F."Arrhythmic and Non-Arrhythmic Heartbeat Classification based on Gaussian Mixture Model", In 2016 Electric Electronics, Computer Science, Biomedical Engineerings' Meeting (EBBT) (pp. 1-4) 2016
- [13] İscan, M., Yılmaz C., Yigit, F., " T-wave end pattern classification based on Gaussian mixture model. In 2016 24th Signal Processing and Communication Application Conference (SIU) (pp. 1953-1956),2016
- [14] İscan, M., Yigit, F, Yılmaz C., "Heartbeat Pattern Classification Algorithm Based on Gaussian Mixture Model", Inter. Symp. on Med. Meas. and App., Italy,2016
- [15] Pan J. and Tompkins W. J., "A real-time QRS detection algorithm, IEEE Trans. Biomed. Eng",32(3):220-236, 1985
- [16] Laguna P. R. G. Mark, Goldberger A., Moody G. B., "A database for evaluation of algorithms for measurement of QT and other waveform intervals in the ECG", Comput. in Card., 1997.
- [17] McLaughlin, N. B., Campbell, R. W. F., & Murray, A. "Effects of filtering and algorithm parameters on automatic QT measurement techniques". Computers in Cardiology 1994 (pp. 221-224)
- [18] Xue, Q., & Reddy, S.. "Algorithms for computerized QT analysis. Journal of electrocardiology", 30:181-186.,1998
- [19] Shima, K., Tsuji, T., Kandori, A., Yokoe, M., & Sakoda, S. "Measurement and evaluation of finger tapping movements using log-linearized Gaussian mixture networks." Sensors, 9(3):2187-2201, 2009
- [20] Okamoto, M., Shima, K., Matsubara, Y., & Tsuji, T."Pattern discrimination method with a boosting approach using hierarchical neural trees". Proceedings of the Inst. of Mech. Eng., Part I: Jour. of Syst. and Cont. Eng., 222(7):701-710, 2008