

Araştırma / Research**QT ZAMAN ARALIĞININ GAUSS KARIŞIM MODELİ VE YAPAY SİNİR AĞI TABANLI TESPİTİ**

Mehmet İŞCAN (ORCID: 0000-0003-2261-8218)
Cüneyt YILMAZ (ORCID: 0000-0002-4263-8411)*

Mekatronik Mühendisliği Bölümü, Makine Fakültesi, Yıldız Teknik Üniversitesi, İstanbul, Türkiye

Geliş / Received: 05.05.2017

Düzeltilmelerin gelişi / Received in revised form: 28.06.2017

Kabul / Accepted: 29.06.2017

ÖZ

Günümüzde yarı-parametrik tanımlanan yapay sinir ağı tabanlı olasılıksal yöntemler biyolojik sinyallerin işlenmesi örüntü tanınmasında aktif olarak kullanılmaktadır. Bu çalışmada, EKG sinyallerinin önemli bir zaman aralığı olan QT süresinin belirlenmesi ve sınıflandırılması için yarı-parametrik Gauss karışım modeli tabanlı yapay sinir ağı modeli gerçekleştirilmiştir. Bu kapsamda, zamana bağlı değişen kalp ritim sinyallerinin, eğitimi ve sınıflandırılması olasılıksal metotların gözetimli ve gözetimsiz eğitimi ile tamamlanmış, ayrıca yeni bir fikir olarak karşılaştırma algoritması statik yapay sinir ağları için sunulmuştur. Önerilen algoritma ile 105 PHYSIONET QT veritabanı verileri ve 4 gerçek denekten alınmış veriler işlenmiştir. Gerekli eğitimler tamamlandıktan sonra, sunulan algoritma %97,11 hassasiyet, %94,27 pozitif belirleyicilik ve %4,2 hata oranı ile QRS kompleksi ve T dalgasını saptayabilmiş, ayrıca 3,1 milisaniye ortalama hata değeri ve 5,62 milisaniye standart sapma değeri ile QT zaman aralığını bulabilmiştir. Sonuçlara göre, önerilen algoritma değişik EKG sinyalleri için yüksek performansta sınıflama ve ayrıştırma işlemini gerçekleştirebilmiştir.

Anahtar Kelimeler: QT ölçümü, T-dalgası, EKG sinyal sınıflaması, yapay sinir ağları, Gauss karışım modeli

GAUSSIAN MIXTURE MODEL AND NEURAL NETWORK BASED DETERMINATION OF QT DURATION**ABSTRACT**

Nowadays, probabilistic methods based on semi-parametric neural networks have been used to signal processing in biological signals with individual characteristics. The main objective of this study was to develop a semi-parametric neural network based on Gaussian mixture model to perform the QT measurement and classification. For this purpose, a comparison algorithm evaluating time-series cardiac signals was established with training by supervised and unsupervised learning, and the comparison algorithm was presented in order to static neural networks. The proposed algorithm has been tested on the data from 4 normal subjects and 105 additional normal data sets from PHYSIONET QT database. After the improvement by the proposed algorithm, we observed that the QT-measurements were done with 3.1 milliseconds of the mean values and 5.62 milliseconds of standard errors, when QRS complexes and T waves are detected at the rate of 97.11% sensitivity, 94.27% positive predictivity and 4.2% error value, respectively. The results suggested that the proposed algorithm achieved a classification and discrimination of various ECG signals at a high performance level.

Keywords: QT measurement, T wave, ECG signal classification, artificial neural networks, Gaussian mixture model


*Corresponding author / Sorumlu yazar. Tel.: +90 541 566 6831; e-mail / e-posta: cylvz2010@gmail.com

1. GİRİŞ

Günümüzde kardiyovasküler rahatsızlıklara bağlı olarak oluşan ani ölümler dünyada ilk sırada yer almaktadır. İnsan yaşamına ve genetik faktörlerine bağlı olarak gelişen bu oran pek çok türde ve şiddette gerçekleşmektedir. Hastalıkların nedenlerinde bilimsel perspektifler göz önüne alındığında temel olarak mekanik ve elektriksel bozukluklar büyük rol oynamaktadır ve bu normal olmayan değişimlerin incelenmesine ihtiyaç duyulmaktadır [1].

Kardiyovasküler sistemler incelendiğinde, kalp bir pompa görevi görmektedir ve tek amacı vücutta bulunan kanın basınçlandırılması ve akışın sürekli olarak devam ettirilmesiyle vücudun beslenmesini sağlamaktır. Bu açıdan incelendiğinde kalp kanı toplayan (atriyum) ve kanı akciğer ile vücuda basan (karıncık) iki kısımdan oluşmaktadır. Ritmik olarak kalbe gelen kan basınçlandırılır ve belli bir akış değerinde (5 L/dk) vücudun beslenebileceği bir seviyede kanı kardiyovasküler sistemde dolaştırmaktadır. Bu açıdan incelendiğinde kalbin mekanik özelliklerinde bir performans düşümü olduğunda kalp işlevine devam edememekte ve buna bağlı olarak vücut ve aynı zamanda kalp tehlikeli durumlara sürüklenmektedir [2].

Yukarıda belirtilen tehlikeli durumların sebebi mekanik ve elektriksel olabilmektedir. Mekanik yöntemler ile yapılan anlamlı ve detaylı tespitler ancak invazif (vücut içi) operasyonlar ile yapılabilmekte ve hem hastanın hayatını, hem de ilerleyen dönemlerde yaşam kalitesini düşürebilecek tehlikeli durumlara sebebiyet verebilmektedir. Bu yüzden çoğunlukla vücut dışından gerçekleştirilebilen ve elektriksel olarak kardiyak seviyeyi ölçebilen yöntemlerin önemi artmıştır. Bu yöntemlerden biri olan elektrokardiyografi (EKG), kalbin elektriksel depolarizasyonunun (kasılma) ve repolarizasyonunun (gevşeme) bir oranı olarak karşımıza çıkmaktadır. EKG'nin kullanımı ile kalbin elektriksel yolları üzerindeki akımların oluşturduğu gerilim farkları incelenebilmekte, normal yolunu tamamlayamayan ve elektriksel olarak uyarılamayan bölümlerin tespitleri yapılabilmektedir [3]. Şekil 1'de EKG grafiğine ait örnek bir görüntü verilmiştir.



Şekil 1. EKG sinyali ve dalga formları

Şekil 1'de gösterilen grafikte yatay eksen zamanı (saniye) ve dikey eksen ise normalize edilmiş gerilim değerini göstermektedir. EKG temel olarak 3 adet dalgadan oluşmaktadır: P dalgası (atriyumun kasılması), QRS dalgası (ventriküllerin kasılması) ve T dalgası (ventriküllerin gevşemesi). Her dalga kendine özel bir formu bulunmakta ve normal bir insan için yaşa, genetik ve yaşam koşullarına göre farklı boyutlarda ve aralıklarda olmaktadır.

EKG sinyal türlerinden birisi olan T dalgası kalbin ventriküllerinin repolarizasyonunu temsil eden bir gösterge olarak karşımıza çıkmaktadır. Kalbin elektro-potansiyellerindeki değişimlere bağlı olarak, akım, iyon dengesizliği veya zarar görmüş besleme yollarından dolayı T dalgasının büyüklüğünün ve genişliğinin değişmesi, T dalgasının birçok normal olmayan kardiyak durumların tespitinde bir referans noktası olmasını sağlamaktadır [4]. Ancak, EKG ölçümünün standartlarından dolayı elektrokardiyogramın kayıt hızı, yükselme oranı, örnekleme aralığı ve diğer elektronik sorunlardan dolayı T dalgasının tespitini yapabilen bir standart algoritmanın yapımını zorlaştırmaktadır [5]. Ayrıca biyolojik sebeplerden ötürü (kalp atım hızı, cinsiyet, genetik faktörler) T dalgasının gerilim değeri ve süresi fizyolojik olarak kişiden kişiye, hatta aynı hastaların farklı kayıtlarında bile farklılıklar göstermektedir [6, 7].

Diğer yandan, ventriküllerin kasılması ve gevşemesi mekanik olarak temizlenen kanın vücuda basılmasını göstermektedir ki bu da kalbin %75 işini yapan ventriküllerin toplam işini bize vermektedir [8]. Bu yüzden QRS

kompleksinin başlangıcı ile T dalgasının sonunun tespiti, önemli bir değişken olarak karşımıza çıkmaktadır ve QT zaman aralığı şeklinde ifade edilmektedir. QT zaman aralığı kalbin ventriküllerinin gevşeme ve kasılması sürecini gösterdiği için, bazı genetik hastalık ve aritmi türlerinin saptanmasında aktif olarak kullanılmaktadır [9]. Normal olarak QT aralığının bulunması için QRS kompleksinin başlangıç noktasının (Q noktası) ve T dalgasının sonunun elde edilmesi gerekmektedir. Ventriküler kasılmanın başlangıç noktasının bulunması algoritmalar için sorun oluşturmamaktadır, çünkü QRS kompleksi yeterince büyük ve zaman aralığı olarak geniş değildir. Diğer yandan T dalgasının sonunun bulunması, nefes alma ve düşük frekanslı gürültülere bağlı seviye değişimi, iyonların gevşemedeki transferlerinin düşük frekans bölgesinde ve küçük gerilim genliğinde olması, gevşemenin son noktasının tespitini EKG sinyallerinin en zor problemlerinden biri haline getirmektedir. Ayrıca, EKG okuma işlemleri genellikle standartlar altında gerçekleşen ve uzman kişiler ile elektrofizyolojistler tarafından yapılması gereken işlemlerdir. Yapılan bir çalışmaya göre uzman olmayan kişilerin ancak ve ancak %25'lik bir kısmı T'nin sonuna bağlı değişimleri doğru bir şekilde anlamlandırabilmiştir [10]. Ek olarak, hastaların EKG takipleri çok uzun zaman aralıklarında kaydedilmektedir, herhangi bir uzman veya elektrofizyolojistin tek başına, kardiyak durumu gösteren temsili atımları tespit edebilmesi zor ve yorucu bir problem haline dönüşebilmektedir [11]. Bütün bu sebeplerden ötürü ve QRS kompleksinin başlangıcının kolay bulunmasından dolayı, otomatik olarak T dalgasının sonunu tespit edebilen bir algoritmanın geliştirilmesine ihtiyaç duyulmuş ve tanı programlarında aktif olarak kullanılmıştır.

Literatürde QT zaman aralığının tespiti derivatif yöntemlerin kullanılması, dalgacık ve Fourier dönüşümü tabanında frekans modeli olarak incelenmesi, deterministik matematiksel model çıkarımı, olasılıksal yöntemlerin işletilmesi ve deterministik olmayan modellerin gerçekleştirilmesi ile yapılmıştır.

Derivatif yöntemler yüksek performans ile QT zaman aralığını tespit edebilmiş, ayrıca işlem maliyetlerini oldukça düşürmüştür. Ancak EKG sinyalindeki genlik değişimlerine, nefes alma ve düşük gürültülü frekans değerlerinin yarattığı izoelektrik kaymaya ve eğim değerlerinin varyasyonlarına bağlı olarak performansı çok etkilenmektedir [12-16].

Diğer yandan, frekans tabanlı olarak gerçekleşen QT zaman aralığı algoritmaları, eğim ve genlik sorunlarından uzak çalıştırılabilmektedir. Ancak, frekans bölgesine bağlı değişimlerin çok olması, farklı kanallardan alınan verilerin farklı örneklemelerde gerçekleşmesi, varyasyona bağlı frekans gürültüleri ve ekstra yapılan işlemler temel olarak T dalgasının sonunun tespiti zorlaştırmaktadır [17, 18].

Belirli bir kalıbın izlenmesi ve ritmik oluşan EKG sinyali, araştırmacıları matematiksel modeller ve olasılık tabanlı çözümler sunmaya itmiştir. Bu algoritmaların performansı incelendiğinde sabit dalgalarda (QRS ve T) iyi sonuçlar elde edilmiş ancak bozuk sinyallerin tanınmasında zorluk yaşanmıştır. Ayrıca EKG sinyali doğası gereği hem deterministik hem de deterministik olmayan özellikler gösterdiğinden dolayı T dalgasının sonu efektif bir biçimde tespit edilmekten uzak kalmıştır [19-21].

Yapay sinir ağları, modellenemeyen veriler üzerinde mutlak ve iyi sonuçlar alabilen ve doğası gereği efektif sınıflama kapasitesine sahip araçlar olarak karşımıza çıkmaktadır. T dalgasının son noktasının tespitinde aktif olarak kullanılmış ve kabiliyeti geçmiş algoritmalar ile karşılaştırıldığında yüksek performanslarla tanıma işlemi gerçekleştirebilmiştir. Ancak bu işlem için çok fazla eğitim verisinin gerekliliği, T dalgasının değişik formlarda ve kanallarda farklı özellikler göstermesi performansın bütün EKG kayıtları üzerinde işletilebilmesini engellemiştir. Ayrıca eğitim yapılması durumunda sadece tek eğitim değeri için yapay sinir ağları kararlı kılınabilmektedir, bu yüzden varyasyona bağlı değişimler verilerin dağılımının düzgün olmasına bağlı olarak tespit edilebilmektedir ki bu kişinin farklı zamanlarındaki sinyallerinde bile farklı değerlere ulaşmaktadır [22-24].

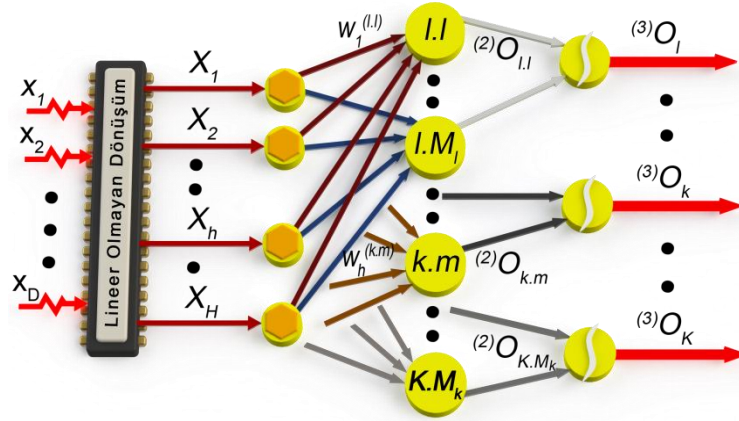
Son yıllarda olasılık tabanlı yöntemlerin yapay sinir ağları ile birleştirilmesi ile yarı-parametrik yöntemler üretilmiştir [25]. Bu yöntemlerin en önemli özelliği, yapay sinir ağının eğitiminin standart gözetimli öğrenme tabanında yapılması ile aynı zamanda olasılıksal karar verebilmeye olanak sağlaması olarak görülmektedir. Bu açıdan bakıldığında verilerin belirli bir alanda olasılık değeri tabanında bir ihtimal vermesi tanı algoritmaları için zaman içinde değişen biyolojik sinyallerde çok büyük bir avantaj olarak kullanılmaktadır.

Bütün bu sebeplerden ötürü bu çalışmada, logaritmik olarak lineerleştirilmiş Gauss karışım parametreleri tabanında yeni bir eğitim ve karşılaştırma algoritması sunulmuştur. Önerilen algoritma temelinde standart bir geri-yayımlı öğrenme algoritması ile Gauss parametrelerinden olan ortalama değer (μ), kovaryans matrisi (σ) ve karışım oranını (α) eğitmekte ve yeni sunulan karşılaştırma algoritması ile T dalgasının sonunu tespit edebilmektedir. Yapay sinir ağlarına oranla bu sunulan algoritma, az sayıda parametre ile dağılım verilerini yüksek performansla oluşturabilmekte ve yüksek sayıda verinin kullanımını zorunlu kılmamaktadır. Ayrıca eğitim algoritmaları EKG'nin farklı kanallarından beslenmekte ve karşılaştırmalı olarak sonuçların karışım değerleri ile tanı performansı artırılmaktadır. Sunulan yeni karşılaştırma algoritması için parametre değerleri üretilmiş ve bu değerlere bağlı olarak sonuçların olasılık tabanında değerlendirilmesi sağlanmıştır.

2. MATERYAL VE METOT

2.1. LLGKM Yapısı

LLGKM [25], logaritmik-lineerleştirilmiş Gauss karışım modelinden oluşmaktadır. Algoritma örnek olarak T dalgasının sonundan alınan verilerin önsel olasılıkları ile Gauss modeli tarafından önerilen koşullu olasılık fonksiyonu kullanarak Bayes kuralına göre nihai olasılık değerlerini vermektedir. Yapay sinir ağının eğitimi için standart geri yayımlı öğrenme algoritması kullanılmıştır. Bu çalışmada LLGKM ve öğrenme algoritması geliştirilen yöntem için taban olarak kullanılmıştır. Sunulan modele ait yapay sinir ağı modeli Şekil 2’de verilmiştir.



Şekil 2. LLGKM yapay sinir ağı yapısı [24]

Sunulan ağ modeli, temel olarak 3 katmandan oluşmaktadır: giriş katı ve lineer olmayan dönüşüm işlemi, Gauss bileşenlerinin saklı katman katsayılarına dönüştürüldüğü 2. katman ve lineer olarak çıkış veren son çıkış katmanından oluşmaktadır.

Giriş katmanında standart olarak istediğimiz kadar farklı giriş tanımlanabilmektedir, ancak bu girişlerin Gauss karışım modeline uygulanabilmesi için lineer olmayan bir dönüşüm yapılması gerekmektedir ki, bu işlem Denklem 1 ile gösterilmiştir.

$$X = \{1, X^T, x_1^2, x_1x_2, \dots, x_1x_d, \dots, x_d^2\} \quad (1)$$

Denklem 1’de d modele verilen farklı giriş sayısını göstermektedir. Modifiye edilmiş vektörün boyutu $H = 1 + d(d + 3) / 2$ ifadesi ile hesaplanabilir.

Saklı katman Gauss karışım modelini ifade eden yapay sinir ağı katsayıları $(w_h^{c,m})$ ile modellenmiştir. Sırası ile w_h, c ve m , yapay sinir ağı katsayısını, sınıf sayısını ve Gauss bileşen sayısını temsil etmektedir. Bu ifadelerden yola çıkarak saklı katman çıkışı

$$I_{c,m}^{(2)} = \sum_{h=1}^H O_h^{(1)} w_h^{c,m} \quad (2)$$

$$O_{c,m}^{(2)} = \frac{\exp[I_{c,m}^{(2)}]}{\sum_{c=1}^C \sum_{m=1}^M \exp[I_{c,m}^{(2)}]} \quad (3)$$

Denklemleri ile hesaplanabilir. Burada $I_{c,m}^{(2)}$ saklı katmanın girişini, $O_h^{(1)}$ modifiye edilmiş giriş değerlerini ve $O_{c,m}^{(2)}$ saklı katman çıkışını göstermektedir. Ayrıca yapay sinir ağı katsayılarının lineer bağımlılıktan

M. İŞCAN, C. YILMAZ

kurtulabilmesi için $w_h^{C,M} = 0$. denkleminin sağlanması gerekmektedir.

Son olarak, nihai olasılıkların Gauss bileşenleri cinsinden hesaplanabilmesi için sınıflara ayrılan saklı katman çıkışlarının toplanması gerekmektedir.

$$Y_c = \sum_{m=1}^M O_{c,m}^{(2)} \quad (4)$$

Burada Y_c değeri öngörülen sınıf için nihai olasılık değeri olarak karşımıza çıkmaktadır.

Eğitim işlemi öncelikle Gauss karışım modelinin gözetimsiz olarak EKG veri setlerinden beklenti maksimizasyonu algoritması ile yapılmıştır [25]. Bu yöntem ile belirli dağılımlar şeklinde veri setlerinin tekil değerleri değil, belirli bir alandaki dağılımı da geçerli T-dalga sinyali olarak algılanmasına olanak tanımıştır. Bu işlemlerden sonra gözetimli olarak geri-yayımlı öğrenme algoritması T dalgalarından oluşturulmuş olan öğretici vektörü $\{x^n, T_c^n\}$ ile giriş ve çıkış arasından bir harita oluşturacak şekilde eğitim işlemi gerçekleştirilmiştir. Eğer x^n değeri c sınıfında ise, $T_c^n = 1$ ve $T_{c+1}^n = 0$ olarak atanmıştır. Uygulanan model lineer olarak ayrılmadığı için bir maliyet fonksiyonu uygulanmıştır.

$$J = \sum_{n=1}^N J_n = - \sum_{n=1}^N \sum_{c=1}^C T_c^{(n)} \log(Y_c^{(n)}) \quad (5)$$

Denklem 5'te logaritmik bir entropi fonksiyonu kullanılmıştır. Standart maliyet fonksiyonlarından farklı olarak 2 adet sınıfın bulunması, bu maliyet fonksiyonunu şart koşmaktadır.

2.2. Karşılaştırma Algoritması

Standart modelde, LLGKM algoritması [25] sınıflara ayırma işlemini gerçekleştirebilmektedir, çünkü verilen girişler için çıkışlarda bize nihai olasılık değerlerini ağ vermektedir. EEG ve EMG verilerinden farklı olarak, EKG verileri zamana bağlı olarak işlenmelidir, çünkü fizyolojik olarak kalp kasları darbe atımları ile değil, birbiri arasında haberleşen sınıyüm hücreleri ile kasılma işlemini gerçekleştirmektedir, ki bu özellik seri örüntü işlemeden anlamlı bir veri oluşumuna engel olmaktadır. EKG'nin önemli özelliklerinde biri olan kasılma ve gevşemenin başlangıç ve bitiş noktalarının tespit edilme zorunluluğundan dolayı, LLGKM algoritması seri örüntü sinyallerini (zamanda sıralı olarak anlam ifade eden sinyaller) işleyecek şekilde iyileştirilmelidir.

Literatürde, Tsuji ve ark. [26] sıralı biyolojik motiflerin analizi için yeni bir yöntem geliştirmiştir ve bunu EEG ve EMG verileri üzerinde denemiştir. Ancak bu karmaşık eğitim aşamalarını içermektedir. Ayrıca yinelenen yapay sinir ağlarının eğitim işlemleri, motif bulma, geriye yönelik arama yapma ve fizyolojik olarak motif sınırlarının EKG'de kişiden kişiye değişmesinden dolayı çok zor bir eğitim halini almaktadır. Ayrıca sınırların verilmesinde motiflerin takibinden çok verilerin varyasyonlarının etkileri, tanı performansını bozmaktadır. Bu çalışmada, iyileştirmeler yapıldıktan sonra kolayca sıralı EKG verilerini sınıflayabilen bir algoritma önerilmiştir. Temel olarak LLGKM bir statik sınıflayıcıdır, yani, her nokta diğerinden bağımsız olarak yapay sinir ağında işlenmektedir. Bu nedenle, sıralı EKG verileri arasında bir ilişki kurulmalıdır. Bu ilişki birden çok LLGKM sınıflayıcısı kullanılarak gerçekleştirilmiştir. Herbir LLGKM her bir eğitim veri seti için eğitilmiştir. Bundan dolayı, LLGKM birimleri çalıştırıldığında, seçilmiş EKG verileri yapay sinir ağı eğitimi için kullanılmıştır. Sonrasında, zaman seri motiflerini niteleyen birleştirilmiş nihai olasılık karşılaştırma kuralları kullanılarak elde edilmiştir. Böylece, EKG verileri tekil olarak değil, sıralı bir bütün olarak işlenmiştir. Bunlardan dolayı, birleştirilmiş nihai olasılık değerini oluşturmak için aşağıdaki fonksiyon önerilmiştir:

$$Y_c = \prod_{i=1}^{TN} Y_c^{(i)CV} \quad (6)$$

Burada Y_c genelleştirilmiş nihai olasılığı, TN eğitim veri sayısını, Y_c^i LLGKM biriminden gelen tekil nihai olasılığı ve CV ise bitiş noktasının doğru bir şekilde saptanması için karşılaştırma parametresi olarak karşımıza çıkmaktadır. Ancak, sıralı olarak işlenen verilerinden dolayı yapay sinir ağı, doğru sonuçları eğitim veri sayısının yarısı kadar ötelemektedir. Bundan dolayı $SPT = TN/2$ kadar birleştirilmiş nihai olasılık değeri ötenmelidir.

QT ZAMAN ARALIĞININ GAUSS KARIŞIM MODELİ VE YAPAY SİNİR AĞI TABANLI TESPİTİ

Yapay sinir ağının katsayıları LLGKM'nin birden fazla kullanımından dolayı artırıldığından, öğrenme zamanı düşmektedir ve kararlı öğrenme performansı iyileştirilmektedir.

3. BULGULARI VE TARTIŞMA

Önceki çalışmada, MIT-DB ve gerçek kişilerden elde edilen toplam 26 kayıt üzerinden algoritmanın performansı ölçülmüştü [24]. Toplam olarak 96000 atım kullanılmış ve hepsi de hastaliksız olan normal sinüs ritim veritabanından elde edilmişti. Ayrıca performans ölçümleri için 5120 adet doktor tarafından T-dalgasının sonu işaretlenmiş gerçek kayıt teste tabi tutulmuştu (Pulse&More ARGE ve Danışmanlık Şti. Ltd, İstanbul).

Bu çalışmada PHYSIONET QT veritabanının hepsi, algoritmanın performansının değerlendirilmesi için kullanılmıştır. Bu kayıtlardan sadece 441 atım doktorlar tarafından işaretlenmiş T-dalgası sonu bilgisini içermekte, geri kalan 105 kayıt için ise standart kabul edilen algoritmaların sonuçları ile karşılaştırma yapılmıştır. Gümüş standart için verilen bu algoritma ile ilgili detaylı bilgi [27]'de bulunabilir.

Gerçek test verileri için, geçmiş çalışmadaki veri setleri yeniden kullanılmıştır. EKG cihazı elektrokardiyogram verilerini 0-150 Hz aralığında filtrelemekte ve 250 Hz örnekleme zamanı ile işlemlerini gerçekleştirmektedir.

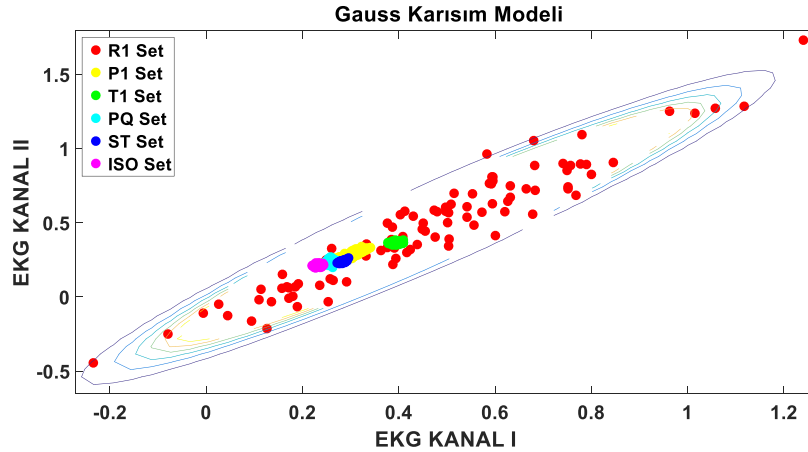
Yapay sinir ağ eğitimi için, öncelikle 2 adet ($d=2$) EKG kanalından elde edilmiş verilerin girişi için 2 ayrı sınıf oluşturulmuştur. İki adet farklı EKG kanal verisi farklı boyutlarda T dalga ve QRS kompleksi sinyalinin tek bir modelde toplanıp, T dalgasının sonunun ayrıştırma performansının artırılması hedeflenmektedir. EKG kanalları vektörel akım ifadeleri olduğu için kanallara göre farklı bilgiler içermektedir. Bazı kanallarda gürültülü ve düşük gerilim değerinde bulunan sinyaller diğer kanallarda yüksek değerlerde olabilmektedir. Bu yüzden derivasyon I ve derivasyon II kanalı seçilmiştir. Gözetimsiz öğrenme için beklenti maksimizasyonu ile en uygun ortalama, kovaryans ve karışım değerleri elde edilmiş, bu değerlere istinaden katsayıların ayarı gözetimli öğrenme çeşitlerinden biri olan geri-yayılımlı öğrenme algoritması ile yapılmıştır [25]. Yapay sinir ağının çıkışında 2 adet sınıf tanımlanmıştır ($C=2$). Her sınıfın genel karakteristik bölgelerinden dolayı 2 adet bileşen ($M=2$) işleme alınmıştır. Önerilen algoritmada kullanılan parametrelerin listesini Tablo 1'de gösterilmektedir.

Tablo 1. Testte kullanılan parametreler

Parametreler	Öğrenme Oranı	Maliyet Değeri	Öğrenme Vektörü	Karşılaştırma Vektörü
Değerler	0,01	0,01	[1 0]	[0,9 0,1]

Yapay sinir ağının eğitim işlemi için 7 adet eğitim veri dizisi seçilmiştir. Eğitim veri dizileri derivasyon I ve derivasyon II'den alınmış QRS kompleksi ve T dalgasının gerilim değerlerinden oluşmaktadır. Bu eğitim verileri T-dalgasının tepe noktasından başlayıp T-dalgasının sonuna kadar olan verileri kapsamaktadır.

Temel yapı olarak sınıflama işleminde yapay sinir ağları, standart bir hiperdüzlem tanımlama işleminden başka bir iş yapmamaktadır. Bu yüzden eğitim süreleri ve yaklaşma parametrelerinin kontrolü çok zor bir biçimde istenen değerlere ulaşmaktadır. Şekil 3 üzerinde EKG verilerinin dağılımları gösterilmektedir.



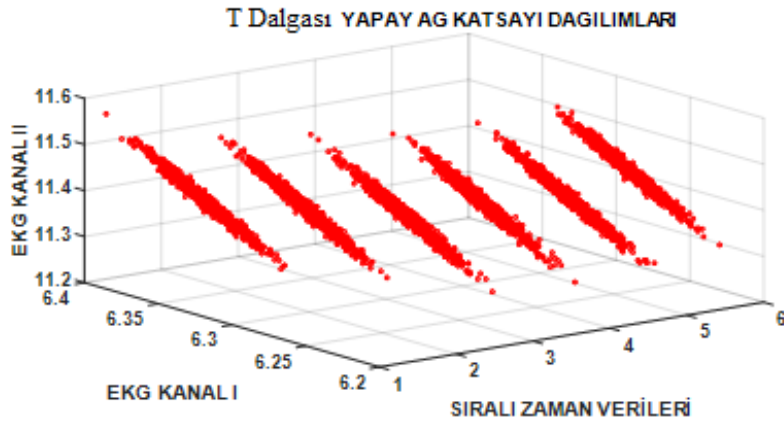
Şekil 3. EKG dalgalarının kümeleme düzleminde gösterimleri

M. İŞCAN, C. YILMAZ


Şekil 3'te yatay eksen EKG kanal I verilerini, dikey eksen ise EKG kanal II verilerini ifade etmektedir. Buna bağlı olarak oluşan kümeler ise bize P, QRS, T ve izoelektrik seviyelerin dağılımını göstermektedir. Sunulan algoritmanın amacı yeşil noktalar ile gösterilen T dalgası örüntülerinin tespit edilmesidir. Standart Gauss karışım modeli ile bu mümkün gözükmemektedir, çünkü T dalgasının verileri aynı zaman da QRS (kırmızı) kompleksi tarafından da kapsamaktadır.

Bu sunulan karşılaştırma algoritmasının avantajı burada kendini göstermektedir. Statik olarak kurulan LLGKM kullanımı ile QRS kompleksi ve T dalgaları birbirinden ayıramamaktadır. Ayrıca Gauss parametrelerinden oluşturulan model (ortalama değerler, kovaryans matrisleri) simetrisini korumak zorundadır ki T dalgası verilen kanal verileri için sabit bir şekil (dairese, elipsoit) ile ifade edilememektedir. Birden fazla hiperdüzlemle lineer olmayan bir şekle bürünebilmesi gerekmektedir.

İşte bu yüzden veriler birden fazla LLGKM parçası ile işleme alınmış ve sıralı olarak Şekil 4 ve 5'teki kümeleme diyagramları, her bir LLGKM için oluşturulmuştur.



Şekil 4. Kümeleme işlemleri – 3 boyutlu gösterim



Şekil 5. Kümeleme işlemleri – 2 boyutlu gösterim

Şekil 4 ve Şekil 5'te gösterilen parametrelere göre, T dalgasının karışım modelinde tek başına bir anlama ifade etmeyen motiflerin zaman içinde belirli kümeler içinde aranabilmektedir. Karşılaştırma fonksiyonu çarpım işlemine sahip olduğu için herhangi uyumsuz bir motifte doğrudan sıralı verilerin olasılık değerini sıfırlamakta, ve uygunsuz bir tespitten kaçınılmakta, ve böylece QRS kompleksi probleminin üstesinden de gelinmektedir. Ayrıca verilerin sadece T dalgasının alanına düşen kısımlarının olasılık değerleri yüksek olduğu için QRS kompleksine bağımlılığa ortadan kalkmaktadır. Dalganın yapısı ve dağılımı itibari ile T dalgası ile QRS kompleksi birbirine çok benzemektedir. Şekil 3'ten de anlaşılacağı üzere aynı ortalama değerlere sahip olup farklı kovaryans matrislerine sahiptir. Gözetimli öğrenme ve karşılaştırma algoritmasının etkisi ile T dalgasının sonunun saptanması kolaylaşmakta ve yapay sinir ağının katsayıları ile ayırt edilebilir hale gelmektedir.

Sunulan algoritmanın karşılaştırılması sırası ile Gauss karışım modeli (GKM), yapay sinir ağları(YSA) ve LLGKM algoritmaları ile yapılmıştır. Buna dair tablo aşağıda verilmiştir.

QT ZAMAN ARALIĞININ GAUSS KARIŞIM MODELİ VE YAPAY SİNİR AĞI TABANLI TESPİTİ

Tablo 2. Yöntemin kendi bileşenleri ile karşılaştırılması

Yöntem	HS	PB	HO
GKM	71,07	69,40	24,13
Yapay sinir ağı	84,22	79,77	13,98
LLGKM	86,59	71,88	8,06
Sunulan	98,33	98,02	2,21

Algoritmanın öncelikle test değerlendirmesi için 3 adet kriter belirlenmiştir: Hassasiyet (HS), Pozitif Belirleyicilik (PB) ve Hata Oranı (HO), ve bunlara ait formüller aşağıda verilmiştir.

$$HS = \frac{DP}{DP + YN} * 100 \quad PB = \frac{DP}{DP + YP} * 100 \quad HO = \frac{YN + YP}{TA} * 100 \quad (7)$$

Denklem 7’de DP (doğru pozitif, tanınması gereken), YP (yanlış pozitif, tanınaması gereken ama tanınan) ve YN (yanlış negatif, tanınması gereken ama tanımayan) olarak kodlanmaktadır. Bütün veritabanları ve gerçek kişilerde alınmış veriler karşılaştırıldığında GKM sadece ayırma işlemini T dalgasının tanınması şeklinde %24.13’lük bir hata oranı ile gerçekleştirebilmiştir. Yapay sinir ağları ile sonuçlar biraz daha iyileştirilebilmiş ancak eğitim verilerinin uzunluğu ve teste harcanan zaman büyük maliyetlere yol açmıştır. Statik LLGKM kullanımında sadece T dalgası ve QRS kompleksi ayrımı 2 EKG kanalının ayrı ayrı beslenmesi ile gerçekleştirilebilmiş, ancak tanınmaması gereken değerlerin çokluğundan dolayı pozitif belirleyicilik değeri çok yüksek çıkmıştır. Sunulan algoritma bütün eşdeğer bileşenlerden daha iyi bir sonuca ulaşabilmeyi başarabilmiştir.

Şu ana kadar verilen sonuçlar sadece QRS ve T dalgasının bulunması ile alakalı idi. QT zaman aralığının hesaplanması için algoritmalar yeniden çalıştırıldığında Tablo 3’teki sonuçlar elde edilmiştir.

Tablo 3. QT zaman aralığının tespiti için QRS-T dalgasının analiz sonuçları

Yöntem	HS	PB	HO
GKM	Yok	Yok	Yok
Yapay sinir ağı	Yok	Yok	Yok
LLGKM	65,24	39,12	38,24
Sunulan	97,11	94,27	4,2
Yöntem	Ortalama hata (mS)	Standart Sapma (mS)	Tanıma Oranı
Sunulan	3,1	5,62	97,11

Tablo 3, GKM ve yapay sinir ağlarının uygulamasını zaman aralığı tespiti için imkansız kılmaktadır, çünkü aynı anda 2 ağda sıralı bir şekilde statik modelden dolayı eğitilememektedir. Statik LLGKM uygulamasında belirli parametreler 105 kayıt üzerinde işaretlenebilmiş, ancak QRS ve T’nin aynı anda tanınma oranı oldukça düşük çıkmıştır. Pozitif belirleyicilik değeri QRS ve T dalgasının sürekli çakışmasından dolayı çok düşük seviyelere ulaşmıştır. Ancak sunulan algoritmanın değerleri incelendiğinde ortalama hata ve standart sapma değerlerinin klinik uygulamalar için kabul edilebilir seviyede olduğu gözlemlenmiştir [10].

Önerilen metot, GKM ve yapay sinir ağlarının karşılaştırma algoritması ile birleştirilmesiyle daha yüksek performansta gerçekleştirilebilmiştir. Tablo 4 şu ana kadar QT zaman aralığı testi yapabilen algoritmaların performanslarının sonuçlarını ve karşılaştırılmasını içermektedir.

Tablo 4. Önceki çalışmalarla karşılaştırma

Yöntem	Ortalama Hata (mS)	Standart Sapma (mS)
Leon ve arkadaşları	-0,12	15,06
İşcan ve arkadaşları (IU)	1,01	12,44
İşcan ve arkadaşları (philips)	11,85	9,91
Zhang ve arkadaşları	0,31	17,43
İşcan ve arkadaşları (SIU)	5,1	12,44
Sunulan algoritma	3,1	5,62

M. İŞCAN, C. YILMAZ

Suarez Leon ve ark. [22], yapay sinir ağı modellerini uygulayarak QT veritabanı üzerinde düşük bir ortalama hata değerinde QT zaman aralığını tespit edebilmiştir. Ancak standart sapma değeri karşılaştırılan diğer yöntemlerinkine göre yüksek bulunmuştur. Şekil 3'te gösterilen EKG veri seti dağılımlarına göre bu işlem lineer olarak ayrıştırılamayan bir problem olarak karşımıza çıkmaktadır. Bundan dolayıdır ki, yapay sinir modelinin katsayılarına bağlı olarak bu sonucun çıkması normaldir, çünkü her zaman elde edilen yapay sinir ağı katsayı değerleri değişik T dalga türlerinde efektif olarak çalıştırılmamaktadır. İşcan ve ark. [28], sürekli dalgacık dönüşümü tabanında bir algoritma uygulamış ve yüksek performansla ortalama hata değerini yakalayabilmiştir. Ancak frekans tabanına bağlı olarak 105 kayıttan sadece 80'i uygulamaya alınabilmiştir. Ani ölüm veritabanının şeklinin bozuk olması ve örüntülerin doğru biçimde tanınmaması, düşük frekanslı bölgelerin çok gürültü içermesi, T dalgasının sonunun tespitini imkansız kılmıştır. Aynı yazarlar tarafından frekansa bağımlılığı azaltmak adına sürekli dalgacık dönüşümü tabanında ve Philips metodu içeren bir algoritma uygulaması yapılmıştır [29]. Bütün kayıtların işleme alınmasına rağmen T dalgasının form değişiklikleri, pozitif veya negatifliği özellikle Ani Ölüm ve Aritmi Veritabanında büyük sorunlara yol açmıştır. Zhang ve ark. [12] yamuk alanlar kullanarak T dalgasının alanını maksimum yapan örüntüler için T'nin sonunu belirlemeye çalışmış ve yüksek performans ile bu işlemi gerçekleştirebilmiştir. Ancak standart sapma değerinin çok yüksek değerlerde olması, bazı kayıtlarda kritik sayılabilecek hatalara yol açabilmektedir. Bu çalışmanın yazarları tarafından önceki çalışmada sadece T dalgasının sonu işleme katılmış ve MIT-NSR verileri ile gerçek verilerin üzerinde testler gerçekleştirilmiştir [23]. Bu değişimlere bağlı olarak ortalama hata ve standart sapma değerleri klinik olarak yeterli bulunmuştur. Diğer yandan bütün veritabanının işleme katılmaması, algoritmanın genelliği adına geçerli bir tabanda kabul edilmesini zorlaştırmaktadır. Sunulan çalışmada ise, örüntülerin katsayıları ile belirli değerler için değil, belirli alan değerleri için sınıflama yapıldığından dolayı hem ortalama hata, hem de standart sapma değerinde iyileşme gözlemlenmiştir.

Yukarıda belirtilen avantajlarına rağmen, sunulan GKM tabanında yapay sinir ağının özellikleri bazı problemlere yol açabilmektedir. Bunlardan biri GKM'nin eğitimi için yapılan beklenti maksimizasyonunun yakınsama sorununa yol açmasıdır. Normal olarak karışım fonksiyonlarına farklı verilerin girilmesi gerekir, çünkü aynı veri setleri girilirse kovaryans matrisinin oluşumu zorlaşmaktadır. Aynı yapıya sahip EKG kanallarından veriler beslendiğinde kovaryans matrisinin zor oluşumu, dar bir alanda olmasından dolayı yapay sinir ağı katsayıları çok yüksek değerler almakta, küçük bir alanı taramak zorunda oldukları için agresif bir yapıya sahip olmaktadır. Bununla beraber küçük varyasyonlara karşı çok hassas duruma gelmektedir. Bu yüzden beklenti maksimizasyonu yapılırken sabit bir eşik değeri kovaryans matrisi için seçilmeli ve bu değer üstündeki değerler sağlanana kadar beklenti maksimizasyonuna devam edilmelidir. Ayrıca, yapılan deneyler sonucu Gauss bileşenlerinin sayısı seçilen sınıfların sayısından fazla olması gerektiği sonucuna varılmıştır. Sebebi ise QRS kompleksinin Şekil 4 ve Şekil 5'te gösterilen alanda dağılmasından dolayı parçalara ayrılması gerekliliğidir. Bu parçalara ayırma işlemi gerçekleştirildikten sonra Gauss bileşenleri T dalgasını kapsayacak şekilde seçilebilmektedir. Sunulan algoritma bunları otomatik olarak yapabilmektedir, ancak deneme-yanılma yoluyla gerçekleştiği için işlemler ilk yapay sinir ağı katsayılarını verme işleminde uzayabilmektedir. Diğer bir sorun ise T-dalgasının şekli P ve QRS kompleksine benzemektedir. Kovaryans matrisi katsayı matrisine dönüştürüldüğü için P dalgası ve QRS kompleksi verilerinde küçükte olsa belirli bir olasılık değerine sahip olacaktır. Her ne kadar modelin bileşenleri ayrı ayrı eğitilse de ve zaman içinde değerler farklı bölgelerde kümelenirse de hatalı bir sonuç, karşılaştırma fonksiyonunun çarpma işleminden dolayı tanınması gereken yerde tanınamama gibi sorunlara yol açabilmektedir. Bundan dolayı iyileştirmelerin yapılması gerekmektedir.

4. SONUÇLAR

Bu çalışmada, yarı-parametrik olarak tanımlanan gözetimsiz öğrenmeye bağlı beklenti maksimizasyonu algoritması ile eğitilmiş Gauss karışım modelinin parametrelerinin yapay sinir ağlarına çevrilerek gözetimli öğrenme sayesinde zamana bağlı EKG verilerini sınıflayabilen, analizini yapabilen, başlangıç ve bitiş noktalarını tespit edebilen bir algoritma önerilmiştir. LLGKM algoritmasından farklı olarak statik değil, dinamik olarak birden fazla sınıflayıcı kullanımı ile zamana bağlı değişimler basit bir şekilde ifade edilebilmiş, farklı kanallardan toplanan EKG verileri tek bir katsayı matrisinde ifade edilebilmiştir. Standart LLGKM uygulamasının dışında karşılaştırma fonksiyonu ile hem QRS kompleksinin hem de T dalgasının sonu tespit edilebilmiş, yazarların önceki çalışmalarında belirtilen problemler büyük ölçüde giderilmiştir.

Bu çalışmada, 4 gerçek kişiden elde edilmiş 5120 T dalgası ile 105 kayıttan oluşan PHYLIONET QT veritabanı işleme alınmıştır. Sunulan algoritma ile toplamda %97,11 Hassasiyet oranı, %94,27 pozitif belirleyicilik ve %4,2 hata oranı ile tanıma performansına sahip olunmuştur. Zaman hataları cinsinden sunulan algoritma bütün veritabanı üzerinde 3,1 milisaniye ortalama hata değeri ve 5,62 milisaniye standart sapma değeri ile işlemleri gerçekleştirebilmiştir.

QT ZAMAN ARALIĞININ GAUSS KARIŞIM MODELİ VE YAPAY SİNİR AĞI TABANLI TESPİTİ

Önceki çalışmalar ile kıyaslandığında frekans tabanlı algoritmalarından performans olarak daha iyi sonuçlar elde edilmiştir, ancak verilerin eğitiminin gerekmesi, tam otomatik çalışmaya engel olmaktadır. Frekans tabanlı yöntemlerin çoğu eğitici veri setine ihtiyaç duymadan işlemlerini gerçekleştirebilmişlerdir. Derivatif yöntemler ile oluşturulan algoritmalara maliyet açısından masrafsız ve gerçek zamanlı uygulamalara çok uygundur. Ancak tek bir katsayı matrisi ile oluşturulan yapay sinir ağı tabanlı Gauss karışım modeli rakip olarak değerlendirmeye alınabilir.

Yazarların önceki çalışmalarına kıyasla bütün veritabanı işleme alınabilmiştir. Ancak eğitim sürecinde gözetimli ve gözetimsiz eğitimin belirli sorunları bulunmaktadır. Bunlardan birisi T dalgasının farklı versiyonlarının kovaryans matrisini oluşturamama sorunudur. Bu yüzden beklenti maksimizasyonu istenen şekilde gerçekleşene kadar deneme-yanılma yöntemi ile işlemlerin gerçekleştirilmesi gerekmektedir. Ancak yöntem herhangi bir filtreleme işlemi, eşik değer kullanımı içermemektedir. En önemli özelliklerinden biri olarak QRS kompleksinin bulunmasını şart koşmamaktadır. Bunun yanında QT zaman aralığının tespiti için QRS'in bulunması şarttır. Yazarların daha önceki çalışmalarında buna dair yapay sinir ağı tabanlı algoritması bulunmaktadır. Ancak eğitim işlemi çok zor gerçekleştirilmektedir ve performans-maliyet grafiği kötüdür.

İleriki çalışmalarda, derin öğrenme ile QRS kompleksinin ve T dalgasının sıralı bulunması amaçlanmaktadır. Ayrıca Gauss karışım modelinin daha gürbüz bir yakınsama yapabilmesi üzerinde çalışmalar gerçekleştirilecektir.

Sonuç olarak, gerçekleştirilen deneyler ile önerilen algoritmanın T-dalgasının son noktasının saptanmasında ve kalbin kasılma ve gevşemesinin süresinin hesaplanmasında verimli bir şekilde işletebileceği kanıtlanmıştır.

KAYNAKLAR

- [1] GOLDBERG, R. J., BENGSTON, J., CHEN, Z., ANDERSON, K.M., LOCATI, E., LEVY, D., "Duration of the QT Interval and Total and Cardiovascular Mortality in Healthy Persons (The Framingham Heart Study Experience)", *The American Journal of Cardiology*, 67(1), 55-58,1991.
- [2] FRAZIER O.H., "Ventricular Assist Devices and Total Artificial Hearts—A Historical Perspective", *Cardiology Clinics*, 21, 1–13, 2003.
- [3] SORIA-OLIVAS, E., MARTINEZ-SOBER, M., CALPE-MARAVILLA, J., GUERRERO-MARTINEZ, J. F., CHORRO-GASCO, J., ESPI-LOPEZ, J., "Application of Adaptive Signal Processing for Determining the Limits of P and T Waves in an ECG", *IEEE Transactions on Biomedical Engineering*, 45(8), 1077-1080, 1998.
- [4] LAGUNA, P., THAKOR, N.V., CAMINAL, P., JANE, R., YOON, H.R., BAYES DE LUNA, A., MARTI, V., GUINDO, J., "New Algorithm for QT Interval Analysis in 24-Hour Holter-ECG: Performance Applications", *Medical and Biological Engineering and Computing*, 28, 67-73, 1990.
- [5] TIRONI, D.A., SASSI, R., MAINARDI, L.T., "Automated QT Interval Analysis on Diagnostic Electrocardiograms", *Computers in Cardiology*, 33, 353-356, 2006.
- [6] CLIFFORD, G. D., AZUAJE, F., MCSHARRY, P. E., *Advanced Methods and Tools for ECG Data Analysis* (1st ed.), Artech House Publishers, Boston, USA, 1989.
- [7] MURRAY, A., MCLAUGHLIN, N.B., BOURKE, J.P., DOIG, J.C., FURNISS, S.S., CAMPBELL, R.W., "Errors in Manual Measurement of QT Intervals", *Heart Journal*, 71, 386-390, 1994.
- [8] SUGA, H., SAGAWA, K., SHOUKAS, A.A., "Load Independence of the Instantaneous Pressure-Volume Ratio of the Canine Left Ventricle and Effects of Epinephrine and Heart Rate on the Ratio", *Circulation Research*, 32(3), 314-322, 1973.
- [9] SCHUARTZ, P.J. and WOLF, S., "QT Interval Prolongation as Predictor of Sudden Death in Patients with Myocardial Infarction", *Circulation*, 57, 1074-1079, 1978.
- [10] WILLEMS, J. L., ARNAUD, P., VAN BEMMEL, J.H., BOURDILLON, P.J., BROHET, C., DALLA VOLTA, S., ANDERSEN, J.D., DEGANI, R., DENIS, B., DEMEESTER, M., "Assessment of the Performance of Electrocardiographic Computer Programs with the Use of a Reference Data Base", *Circulation*, 71(3), 523-534., 1985.
- [11] LAGUNA, P., JANE, R., CAMINAL, P., "Automatic Detection of Wave Boundaries in Multilead ECG Signals: Validation with the CSE Database", *Computers and Biomedical Research*, 27(1), 45-60, 1994.
- [12] ZHANG, Q., MANRIQUEZ, A.I., MEDIGUE, C., PAPELIER, Y., SORINE, M., "An Algorithm for Robust and Efficient Location of T-wave Ends in Electrocardiograms", *IEEE Transactions on Biomedical Engineering*, 53(12), 2544-2552, 2006.
- [13] GOLDENBERG, I. L. A. N., MOSS, A. J., ZAREBA, W., "QT Interval: How to Measure It and what is Normal", *Journal of Cardiovascular Electrophysiology*, 17(3), 333-336, 2006.

M. İŞCAN, C. YILMAZ

- [14] HELFENBEIN, E. D., ZHOU, S. H., LINDAUER, J. M., FIELD, D. Q., GREGG, R. E., WANG, J. J., KRESQUE, S. S., MICHAUD, F. P., "An Algorithm for Continuous Real-Time QT Interval Monitoring". *Journal of Electrocardiology*, 39(4), S123-S127, 2006.
- [15] MURRAY, A., MCLAUGHLIN, N. B., BOURKE, J. P., DOIG, J. C., FURNISS, S. S., CAMPBELL, R. W., "Errors in Manual Measurement of QT Intervals", *British Heart Journal*, 71(4), 386-390, 1994.
- [16] MCLAUGHLIN, N. B., CAMPBELL, R. W. F., MURRAY, A., "Accuracy of Automatic QT Measurement Techniques", *Proceedings of Computers in Cardiology*, Conference by IEEE, 863-866, London, UK, 1993.
- [17] DASKALOV, I.K., CHRISTOV I.I., "Automatic Detection of the Electrocardiogram T-Wave End", *Medical and Biological Engineering and Computing*, 37, 348-353, 1999.
- [18] MARTINEZ, J.P., ALMEIDA, R., OLMOS, S., ROCHA, A.P., LAGUNA, P., "A Wavelet-Based ECG Delineator: Evaluation on Standard Databases", *IEEE Transactions on Biomedical Engineering*, 51(4), 570-581, 2004.
- [19] HAYN, D., KOLLMANN, A., SCHREIER, G., "Automated QT Interval Measurement from Multilead ECG Signals", *IEEE Computers in Cardiology*, 381-384, 2006.
- [20] CLIFFORD, G.D., VILLARROEL, M.C., "Model-Based Determination of QT Intervals", *IEEE Computers in Cardiology*, 357-360, 2006.
- [21] XUE, Q., REDDY, S., "Algorithms for Computerized QT Analysis", *Journal of Electrocardiology*, 30, 181-186, 1998.
- [22] SUAREZ LEON, A.A., MOLINA, D.M., VAZQUEZ SEISDEDOS, C.R., GOOVAERTS, G., VANDEPUT, S., VAN HUFFEL, S., "Neural Network Approach for T Wave End Detection: A comparison of Architectures", *Computing in Cardiology*, Conference by IEEE, 42, 589-592, Nice, France, 2015.
- [23] İŞCAN, M., YILMAZ, C., YİĞİT, F., "T-Wave End Pattern Classification Based on Gaussian Mixture Model", *Signal Processing and Communication Application (SIU)*, Conference by IEEE, 1953 - 1956, Zonguldak, Türkiye, 2016.
- [24] İŞCAN, M., YİĞİT, F., YILMAZ, C., "Heartbeat Pattern Classification Algorithm Based on Gaussian Mixture Model", *International Symposium on Medical Measurements and Applications (MeMeA)*, Conference by IEEE, 1-6, Benevento, Italy, 2016.
- [25] TSUJI, T., FUKUDA, O., ICHINOBE, H., KANEKO, M., "A log-linearized Gaussian mixture network and its application to EEG pattern classification", *IEEE Transactions on Systems, Man, and Cybernetics, Part C (Applications and Reviews)*, 29(1), 60-72, 1999.
- [26] TSUJI, T., BU, N., FUKUDA, O., KANEKO, M., "A Recurrent Log-Linearized Gaussian Mixture Network", *IEEE Transactions on Neural Networks*, 14(2), 304-316, 2003.
- [27] GOLDBERGER, A.L., LAN, A., GLASS, L., HAUSDORFF, J.M., IVANOV, P.C., MARK, R.G., MIETUS, J.E., MOODY, G.B., PENG, C.K., STANLEY, H.E., "PhysioBank, Physio Toolkit, and PhysioNet: Components of a New Research Resource for Complex Physiological Signals", *Circulation*, 101(23), 215-220, 2000.
- [28] YILMAZ, C., İŞCAN, M., YILMAZ, A., "A Fully Automatic Novel Method to Determine QT Interval Based on Continuous Wavelet Transform", *Istanbul University Journal of Electrical and Electronics Engineering*, 17(1), 3093-3099, 2017.
- [29] İŞCAN, M., YILMAZ, A., YILMAZ, C., "A Novel Algorithm Combining Continuous Wavelet Transform and Philips Method for QT Interval Analysis", *Electrical, Electronics and Biomedical Engineering (ELECO)*, National Conference by IEEE, 507-511, Bursa, Türkiye, 2016.