

Miyokard Enfarktüsünün Otonom Sinir Sistemi, Gauss Karışım Modeli ve Yapay Sinir Ağı ile Tespiti Detection of Myocardial Infarction using Autonomic Nervous System, Gaussian Mixture Model and Artificial Neural Network

Merve Begüm TERZİ ve Orhan ARIKAN

Elektrik ve Elektronik Mühendisliği Bölümü

Bilkent Üniversitesi

Ankara, Türkiye

mbterzi@ee.bilkent.edu.tr, oarikan@ee.bilkent.edu.tr

Özetçe—Bu çalışmada, miyokard enfarktüsünün (ME) gürbüz tespitini gerçekleştirmek amacıyla cilt sempatik sinir aktivitesindeki (CSSA) ve EKG'deki anomalileri güncel sinyal işleme ve makine öğrenmesi yöntemlerini kullanarak tespit eden yeni bir teknik geliştirilmiştir. Bu amaçla, PTB-EKG veri tabanındaki geniş bantlı kayıtlardan eş zamanlı olarak CSSA'yı ve EKG'yi ön plana çıkaran bir sinyal işleme tekniği geliştirilmiştir. Ön işleme sonucu elde edilen veriler kullanılarak, ME'nin güvenilir tespiti için kritik olan CSSA özniteliklerini elde eden özgün bir öznitelik çıkarım tekniği geliştirilmiştir. Elde edilen öznitelikleri kullanarak, CSSA anomalilerinin gürbüz tespitini gerçekleştiren yapay sinir ağına (YSA) dayalı bir gözetimli öğrenme tekniği ve Gauss karışım modeline (GKM) dayalı bir gözetimsiz öğrenme tekniği geliştirilmiştir. ME'yi temsil eden aykırı değerlerin gürbüz tespitini gerçekleştirmek için Neyman-Pearson tipi bir yaklaşım geliştirilmiştir. Önerilen tekniğin PTB-EKG veri tabanı üzerindeki başarımları, tekniğin CSSA anomalilerinin gürbüz tespitini gerçekleştiren, oldukça güvenilir ME tespiti sağladığını göstermektedir. Bu nedenle, ME'nin güvenilir teşhisi için EKG'nin sağladığı tanısal bilginin yeterli olmadığı durumlarda, önerilen teknik kullanılarak ME'ye erken tanı konulabilir ve kardiyovasküler hastalıkların mortalitesinde belirgin azalma sağlanabilir.

Anahtar Kelimeler—Kardiyoloji, nöroloji, sinyal işleme, yapay zeka, makine öğrenmesi, anomali tespiti.

Abstract—In this study, a new technique which detects anomalies in skin sympathetic nerve activity (SKNA) and ECG by using state-of-the-art signal processing and machine learning methods is developed to perform the robust detection of myocardial infarction (MI). For this purpose, a signal processing technique that simultaneously obtains SKNA and ECG from wideband recordings on PTB-EKG database is developed. By using preprocessed data, a novel feature extraction technique which obtains SKNA features that are critical for the reliable detection of MI is developed. By using extracted features, a supervised learning technique based on artificial neural network (ANN) and an unsupervised learning technique based on Gaussian mixture model (GMM) are developed to perform the robust detection of SKNA anomalies. A Neyman-Pearson type of approach is developed to perform the robust detection of outliers that correspond to MI. The performance results of the proposed technique over PTB-EKG database showed that the technique provides highly reliable detection of MI by performing the robust detection of SKNA anomalies. Therefore, in cases where the diagnostic information of ECG is not sufficient for the reliable diagnosis of MI, the proposed technique can provide early diagnosis of the disease, which can lead to a significant reduction in the mortality rates of cardiovascular diseases.

Keywords—Cardiology, neurology, signal processing, artificial intelligence, machine learning, anomaly detection.

I. GİRİŞ

Miyokard enfarktüsü (ME), koroner arterlerdeki kan akışının kesilmesine bağlı olarak gelişmekte ve miyokardiyumda iskemik nekroza yol açarak, kalıcı hasar oluşmasına neden olmaktadır. ME sırasında oluşan intrasellüler değişiklikler subendokardiyal bölgedeki miyositlerde geri dönüşümsüz morfolojik değişikliklere ve miyokardiyal relaksasyonda ve kontraksiyonda anomalilere yol açmaktadır [1]. Dünya Sağlık Örgütü (WHO) verilerine göre dünyada koroner arter hastalığından kaynaklanan ölümler tüm ölümlerin %38'ini oluştururken, Türkiye'de %44'ünü oluşturarak, ilk sırada yer almaktadır [2]. Bu nedenle, ME'nin güvenilir bir şekilde erken teşhis edilmesi önemli bir klinik ihtiyaçtır.

Literatürdeki son çalışmalar, cilt sempatik sinir aktivitesi (CSSA) olarak adlandırılan yüksek frekanslı sinyallerin insanlarda cilt yüzeyinden invazif olmayan şekilde geniş frekans bant genişliğine, yüksek örnekleme frekansına ve düşük gürültü seviyesine sahip bir cihaz vasıtasıyla kaydedilebileceğini göstermektedir [3], [4]. İnsanlarda, CSSA ile kardiyovasküler hastalıklar arasındaki ilişkiyi araştıran çalışmalar yeni başlamıştır ve bu çalışmalar CSSA ile kardiyak aritmiler arasındaki ilişkiyi araştırmıştır [3], [4]. Ancak, ME'nin güvenilir teşhisi için güncel makine öğrenmesi tekniklerini kullanarak CSSA'daki anomalileri tespit eden bir çalışma henüz bulunmamaktadır.

Literatürde, EKG'deki anomalileri tespit ederek ME'nin teşhisini gerçekleştirmek için çeşitli teknikler önerilmiştir. Farklı metodolojik yaklaşımları içeren bu teknikler kural-bazlı teknikleri [5], destek vektör makinelerini (DVM) [6], bulanık mantık yöntemlerini [7], yapay sinir ağlarını (YSA) [8] ve diğer makine öğrenmesi tekniklerini [9] kapsamaktadır. Bu teknikler arasında, YSA birçok sınıflandırma probleminin çözümünde yüksek başarımlar gösteren ve veri kümesinde eksik veri olduğu durumlarda bile yüksek genelleme kabiliyetine sahip gürbüz bir makine öğrenmesi tekniği olarak literatürdeki yerini almıştır [7].

II. AMAÇ VE YÖNTEM

Bu çalışmada, ME'nin gürbüz tespitini gerçekleştirmek amacıyla göğüs ön duvarı CSSA'sındaki anomalileri güncel sinyal işleme, gözetimli ve gözetimsiz öğrenme yöntemlerini kullanarak tespit eden özgün bir anomali tespit tekniği geliştirilmiştir.

A. Veri Tabanının Oluşturulması

Önerilen tekniğin geliştirilmesi sırasında, koroner arter hastalığı tanısı konulan 52 hastadan ve 52 sağlıklı gönüllüden geniş frekans

bant genişliğine, yüksek örnekleme frekansına ve düşük gürültü seviyesine sahip veri alım ekipmanları kullanılarak elde edilen ham kayıtları içeren PTB-EKG veri tabanı kullanılmıştır [10]. Veri tabanı, koroner arter oklüzyonu sonucunda gerçekleşen miyokard nekrozu öncesinde elde edilen geniş bantlı verilerdeki iskemik EKG anomalilerini araştırmak amacıyla Benjamin Franklin Üniversitesi Tıp Fakültesi, Kardiyoloji Ana Bilim Dalı tarafından yürütülen klinik araştırma çalışması kapsamında oluşturulmuştur.

Koroner arter hastalarında miyokardiyal kan akışının azalması sonucunda, ME öncesinde geçici göğüs ağrıları ile birlikte EKG'nin ST segmentinde ve T dalgasında anomaliler meydana gelmektedir [6]. Veri tabanı, ME öncesinde EKG verilerindeki repolarizasyon anomalilerini göstermesi nedeniyle çeşitli ME tespit tekniklerinin geliştirilmesi ve başarımlarının değerlendirilmesi için oldukça uygun bir test ortamı sunmaktadır. Buna ek olarak, ME öncesinde gerçekleşen iskemik EKG anomalilerini gösteren en büyük veri tabanıdır ve hastaların koroner arter patolojileri ile ilgili detaylı klinik bilgiler içermektedir. Veri alımı sırasında ventriküler taşikardi veya atrial fibrilasyon geçiren hastalar veri tabanına dahil edilmemiştir. Kayıtların sayısallaştırılması sırasında, yüksek çözünürlüğe sahip sinyallerin elde edilebilmesi için 10 kHz örnekleme frekansı, 16-bit örnekleme çözünürlüğü ve $0.5 \mu V$ genlik çözünürlüğü kullanılmıştır.


B. Sinyal İşleme Tekniği

Geniş frekans bant genişliğine ve yüksek örnekleme frekansına sahip cihazlar kullanılarak, koroner arter hastalarının ve sağlıklı gönüllülerin göğüs ön duvarından kaydedilen elektriksel sinyallerden CSSA'yı ve EKG'yi eş zamanlı olarak elde eden özgün bir sinyal işleme tekniği geliştirilmiştir. Bu amaçla, PTB-EKG veri tabanında bulunan geniş bantlı kayıtlardaki sempatik sinir aktivitesini ön plana çıkararak, iskelet kası (EMG) gürültüsünü ve hareket artefaktını elimine eden yüksek geçiren süzgeçler geliştirilmiştir. Ayrıca, veri tabanında bulunan geniş bantlı kayıtlardaki kalbe ait elektriksel aktiviteyi ön plana çıkararak, solunum sinyalini, taban hattı kaymasını ve 50 Hz'lik güç hattı girişimini elimine eden bant geçiren ve çentik süzgeçler geliştirilmiştir.

Önerilen sinyal işleme tekniğinin PTB-EKG veri tabanındaki ham kayıtlara uygulanması sonucunda, sağlıklı gönüllülerin göğüs ön duvarı CSSA sinyalleri referans alındığında, ME öncesinde koroner arter hastalarının göğüs ön duvarı CSSA genliklerinde artış olduğu görülmüştür. Ayrıca, ME öncesinde göğüs ön duvarı CSSA genliklerinde meydana gelen artış ile eş zamanlı olarak, hastaların EKG sinyallerinin ST segmentinde ve T dalgasında anomaliler meydana gelmiştir. Önerilen sinyal işleme tekniği kullanılarak elde edilen sonuçlar, ME öncesinde hastaların göğüs ön duvarı CSSA genliklerinde meydana gelen anomaliler ile EKG'deki ST/T anomalilerinin ilintili olduğunu göstermiştir. Şekil 1'de önerilen sinyal işleme tekniğinin, veri tabanındaki bir sağlıklı gönüllünün ve koroner arter hastasının ham kayıtlarına uygulanmasıyla elde edilen göğüs ön duvarı CSSA ve EKG sinyalleri gösterilmektedir.

C. Öznitelik Çıkarım Tekniği

Sinyal işleme tekniğinin veri tabanındaki sağlıklı gönüllülerden ve koroner arter hastalarından alınan yüksek frekanslı ham kayıtlara uygulanmasıyla elde edilen göğüs ön duvarı CSSA sinyallerinden, ME'nin güvenilir tespiti için kritik olan bazal ve iskemik özniteliklerin çıkarılmasını sağlayan özgün bir öznitelik çıkarım tekniği geliştirilmiştir. Öznitelik çıkarım tekniğinin, veri tabanındaki deneklere ait göğüs ön duvarı CSSA sinyallerine uygulanması sonucunda, ME'nin gürbüz tespiti için ayrılcılığı en yüksek olan öznitelikler tüm denekler için elde edilmiştir.



Şekil 1: Önerilen sinyal işleme tekniğinin, PTB-EKG veri tabanındaki bir sağlıklı gönüllünün (BC) ve koroner arter hastasının (MI) geniş bantlı kayıtlarına uygulanmasıyla elde edilen göğüs ön duvarı CSSA ve EKG sinyalleri.

1) *CSSA Tepe Sayısı (numCSSA)*: Veri tabanındaki her bir deneye ait göğüs ön duvarı CSSA sinyaline ($s[n]$) özgü olarak uyarlanmış eşik değerler (ξ) belirlenmiş ve bir zaman penceresi (N) boyunca CSSA genliklerinin uyarlanmış eşik değerden büyük olduğu sinyal değerlerinin bulunmasıyla, CSSA tepelerinin ($p[n]$) zaman düzlemindeki tespiti gerçekleştirilmiştir.

$$p[n] = \begin{cases} 1, & s[n+k] \geq \xi, \\ 0, & s[n+k] < \xi \end{cases} \quad k = 0, \dots, N-1 \quad (1)$$

$$\text{numCSSA}[n] = \sum_{m=0}^{N-1} p[n+m] \quad (2)$$

2) *Ortalama CSSA (aveCSSA)*: Göğüs ön duvarı CSSA sinyalinin ($s[n]$) bir zaman penceresi (N) boyunca integrali alınarak, toplam genliğin aynı zaman aralığındaki örnek sayısına bölünmesiyle elde edilmiştir.

$$\text{aveCSSA}[n] = \frac{1}{N} \sum_{m=0}^{N-1} |s[n+m]| \quad (3)$$

3) *Maksimum CSSA (maxCSSA)*: Göğüs ön duvarı CSSA sinyalinin ($s[n]$) bir zaman penceresi (N) boyunca en büyük sinyal genliğinin tespiti edilmesiyle elde edilmiştir.


$$\text{maxCSSA}[n] = \max_{0 \leq m \leq N-1} (s[n+m]) \quad (4)$$

D. Sınıflandırma Tekniği

Öznitelik çıkarım tekniğinin, veri tabanındaki sağlıklı gönüllülerden ve koroner arter hastalarından elde edilen CSSA sinyallerine uygulanmasıyla elde edilen kritik bazal ve iskemik CSSA özniteliklerini kullanarak, ME'nin gürbüz tespitini gerçekleştiren YSA'ya dayalı bir gözetimli öğrenme tekniği geliştirilmiştir. Geliştirilen tekniğin, veri kümesindeki farklı sınıflara ait verilere aynı önemi vermesini ve farklı sınıflara ait verilerin aynı aralıkta ölçeklendirilmesini sağlamak amacıyla veriler min-max normalizasyon yöntemi kullanılarak normalize edilmiştir.

Tekniğin daha önce görmediği veriler üzerindeki başarımını ve genelleme kabiliyetini belirlemek amacıyla her hastaya ait veri kümesi k -katlı çapraz geçerlilik yöntemi kullanılarak, eğitim kümesine ve test kümesine ayrıştırılmıştır. Bu amaçla, her hastaya ait veri kümesi rastgele bir şekilde $k=5$ eşit alt kümeye bölünmüş ve alt kümelerden biri tekniğin genelleme kabiliyetini göstermek için kullanılan test kümesini oluştururken, geriye kalan alt kümeler ağırlık eğitimi için parametrelerinin en iyilenmesi için kullanılan eğitim kümesini oluşturmuştur. Buna ek olarak, ağırlık eğitimi kümesine aşırı uyum sağlamasını engellemek amacıyla, eğitim kümesi rastgele bir şekilde eğitim (70%) ve doğrulama (30%) alt kümelerine ayrıştırılmıştır.

Geliştirilen ileri-beslemeli çok katmanlı ağ, üç girdi nöronu bulunan girdi katmanı, gizli katman ve bir çıktı nöronu bulunan çıktı katmanı olmak üzere üç katmandan oluşmaktadır. En iyilenmiş gizli katman sayısını belirlemek amacıyla, tek ve çoklu sayıda gizli katmana sahip çok katmanlı algılayıcılar (ÇKA) geliştirilmiş ve her bir deneye ait veri kümesi üzerindeki başarımları hesaplanmıştır. Elde edilen sonuçlar, tek gizli katmana sahip ÇKA'nın daha yüksek başarıma ve daha kısa eğitim süresine sahip olduğunu göstermiştir. Ayrıca, gizli katmandaki en iyilenmiş nöron sayısını belirlemek amacıyla, farklı sayıda gizli nörona sahip ÇKA'lar geliştirilmiş ve her deneye ait veri kümesi üzerindeki başarımları hesaplanarak, en yüksek genelleme kabiliyetine sahip ÇKA belirlenmiştir. Gizli ve çıktı katmanlarındaki en iyilenmiş aktivasyon fonksiyonunu belirlemek amacıyla, farklı aktivasyon fonksiyonlarına sahip ÇKA'lar geliştirilmiş ve her deneye ait veri kümesi üzerindeki başarımları hesaplanarak, en yüksek başarıma sahip ÇKA deneye özgü olarak belirlenmiştir.



Şekil 2: Çok katmanlı algılayıcının yapısı [8].

YSA'nın eğitimi ileri-beslemeli kısımdan ve bir gözetimli öğrenme yöntemi olan geri-yayımlı kısımdan oluşmaktadır. Eğitim sırasında, belirlenen ileri-beslemeli ve geri-yayımlı iterasyon sayısı boyunca eğitim kümesi kullanılmıştır. İleri-beslemeli eğitim sırasında YSA'dan elde edilen çıktı hesaplanırken, geri-yayımlı eğitim sırasında çıktıdaki hata YSA'nın gelecekteki hesaplamalarını düzeltmek ve istenilen çıktıya yakınsamak amacıyla kullanılmıştır. Başka bir deyişle, geri-yayımlı eğitim sırasında, YSA tarafından gerçekleştirilen hesaplamaları en iyilemek ve YSA'nın tahmini çıktısı ile çıktı değişkeninin bilinen değeri arasındaki farkı en küçükleme amacıyla ağırlıklar kademeli olarak değiştirilmiştir. YSA'nın maliyet fonksiyonu E olarak bilinen bu fark, M 'nin eğitim kümesindeki örnek sayısı, \mathbf{o}_i 'nin çıktı vektörü ve \mathbf{d}_i 'nin hedef vektör olduğu durumda her bir eğitim verisi i için (5)'de gösterildiği şekilde ifade edilmektedir.

$$E = \frac{1}{M} \sum_{i=1}^M \|\mathbf{d}_i - \mathbf{o}_i\|^2 \quad (5)$$

Geri-yayımlı algoritması (6)'da ve (7)'de gösterilen \mathbf{w} 'nin katmanlar arasındaki ağırlıklara ait ağırlık vektörü ve η 'nin ağırlık öğrenme oranı olduğu durumda ortalama karesel hata E 'yi en küçükleme için kullanılan bir gradyan iniş yöntemidir [8], [9].

$$\Delta \mathbf{w}_i = -\eta \frac{\partial E}{\partial \mathbf{w}_i} \quad (6)$$

$$\mathbf{w}_{(i+1)} = \mathbf{w}_i - \eta \frac{\partial E}{\partial \mathbf{w}_i} \quad (7)$$

Tekniğin başarımlarını en iyilemek ve YSA'nın eğitim kümesine aşırı uyum sağlamasını engellemek için eğitim süresi periyodik olarak test edilmiştir. Bu amaçla, belirlenen sayıda ileri-beslemeli ve geri-yayımlı iterasyon sonrasında mevcut ağırlıklar kaydedilmiş ve YSA'nın başarımlarını doğrulama kümesi kullanılarak değerlendirilmiştir. YSA'nın eğitimi, doğrulama kümesi üzerindeki hata en küçükleme zamanı sonlandırılmıştır. Böylece, tüm başarımlar ölçütleri için en yüksek başarıma ve en iyilenmiş parametrelere sahip YSA bağımsız bir doğrulama kümesi kullanılarak deneye özgü olacak şekilde belirlenmiştir.

En iyilenmiş YSA'nın daha önce görülmemiş bir veri kümesi üzerindeki başarımlarını ve genelleme kabiliyeti, tüm veri kümesinin temsili altkümesini oluşturan bağımsız test kümesi kullanılarak gösterilmiştir. Geliştirilen tekniğin test kümesi üzerindeki başarımlarını belirlemek için istatistiksel başarımlar ölçütleri olan doğruluk, isabet oranı, yanlış alarm oranı, pozitif tahmin değeri, negatif tahmin değeri, özgüllük ve hata oranı her bir çapraz-geçerlilik katında hesaplanmıştır. En iyilenmiş YSA'nın farklı çapraz geçerlilik katlarında test kümesi üzerinde elde edilen başarımların ortalaması alınarak, her bir başarımlar ölçütü için geliştirilen tekniğin başarımlarını gösteren tek bir kestirim değeri elde edilmiştir.

E. Kümeleme Tekniği

Buna ek olarak, iskemik CSSA verilerinin eksik olduğu durumlarda, sadece bazal CSSA verilerini kullanarak ME'nin gürbüz tespitini gerçekleştiren Gauss karışım modeline (GKM) ve Neyman Pearson yaklaşımına dayalı bir gözetimsiz öğrenme tekniği geliştirilmiştir. GKM, eğitim kümesini birbirinden bağımsız birden fazla Gauss dağılımının karışımını kullanarak modelleyen bir kümeleme yöntemidir. Bu yöntemde, eğitim kümesindeki örneklerin Gauss dağılımı ile örnek üreten birden fazla bağımsız kaynaktan üretildiği varsayılarak, bu kaynaklara ait Gauss parametrelerinin (Υ) optimizasyonu karışımın olasılık yoğunluk fonksiyonunu en büyüleyecek şekilde gerçekleştirilir [11]. Bu sayede, veri kümesinin tek bir dağılımdan üretildiğini varsayarak, dağılım parametrelerinin kestirimiyle modelleme yapan yöntemlerin yetersiz kaldığı durumlarda, GKM yüksek başarımlar gösteren bir makine öğrenmesi tekniği olarak literatürdeki yerini almıştır [11]. Karışımın olasılık yoğunluk fonksiyonu (8)'deki gibi K adet Gauss yoğunluk bileşeninin ağırlıklandırılmış toplamı olarak ifade edilmekte ve \mathbf{x} D -boyutlu veri vektörünü, π_k karışım katsayılarını, μ_k ortalama değer vektörünü, Σ_k kovaryans matrisini göstermektedir. Her bir bileşenin yoğunluğu aşağıdaki çok değişkenli Gauss dağılımı ile ifade edilmektedir.

$$\mathcal{N}(\mathbf{x} | \mu_k, \Sigma_k) = \frac{1}{(2\pi)^{\frac{D}{2}} |\Sigma_k|^{\frac{1}{2}}} \exp\left\{-\frac{1}{2}(\mathbf{x} - \mu_k)^T \Sigma_k^{-1} (\mathbf{x} - \mu_k)\right\}$$

$$g(\mathbf{x} | \Upsilon) = \sum_{k=1}^K \pi_k \mathcal{N}(\mathbf{x} | \mu_k, \Sigma_k) \quad (8)$$

Karışımın olasılık yoğunluk fonksiyonu, her bir bileşene ait karışım katsayıları, ortalama değer vektörü ve kovaryans matrisi kullanılarak (9)'da gösterildiği şekilde parametrelendirilir. Toplam olasılık dağılımının normalleştirilmesi için karışım katsayıları (10)'da gösterilen eşitliği sağlamaktadır. Optimum parametrelerin kestirimi, parametrelerin en büyük olasılık kestirimini bulmak için kullanılan yinelemeli bir yöntem olan Beklenti-Enbüyükleme (BE) algoritması ve eğitim kümesi kullanılarak gerçekleştirilir.

$$\Upsilon = (\pi_k, \mu_k, \Sigma_k), \quad k = 1, \dots, K \quad (9)$$

$$\sum_{k=1}^K \pi_k = 1, \quad 0 \leq \pi_k \leq 1 \quad (10)$$

ME'nin güvenilir tespiti için kritik olan bazal CSSA özneliklerinin birleşik olasılık yoğunluk fonksiyonunun kestirimi GKM kullanılarak gerçekleştirilmiştir. Şekil 3'de veri tabanındaki bir gönüllüye ait bazal CSSA özneliklerinin birleşik olasılık yoğunluk fonksiyonunun en iyilenmiş parametrelere sahip GKM ile kestirimi gösterilmektedir.

ME'yi temsil eden aykırı değerlerin gürbüz tespitini gerçekleştirmek için Neyman-Pearson tipi bir yaklaşım geliştirilmiştir [12], [13]. Bu amaçla, veri tabanındaki her gönüllünün bazal CSSA sinyali eşit uzunluğa sahip N farklı segmente $X = \{\mathbf{x}_1, \dots, \mathbf{x}_N\}$ bölünmüştür.

Neyman-Pearson karar stratejisi, CSSA segmentlerinin ortalama log-olabilirlik değerlerinin (12)'de gösterildiği şekilde hesaplanmasıyla ve bu değerlerin farklı ayırım eşik değerleri (Γ) ile (13)'deki gibi kıyaslanmasıyla uygulanmıştır [12], [13].

$$H_0 : X \in C_0, \quad H_1 : X \notin C_0 \quad (11)$$

$$P(X | H_0) = \frac{1}{N} \log g(X | \Upsilon) = \frac{1}{N} \sum_{i=1}^N \log g(\mathbf{x}_i | \Upsilon) \quad (12)$$


$$\Theta(X) = \begin{cases} H_0, & P(X | H_0) \leq \Gamma \\ H_1, & P(X | H_0) > \Gamma \end{cases} \quad (13)$$

III. SONUÇLAR

CSSA segmentlerinin bağımsız ve özdeşçe dağıldığı varsayılarak [14], [15], ardışık olarak artan CSSA segment sayıları ve farklı ayırım eşik değerleri için GKM'ye dayalı kümeleme yöntemi ile elde edilen isabet oranı ve yanlış alarm oranı değerleri her gönüllü için hesaplanmıştır. Geliştirilen gözetimsiz öğrenme tekniğinin PTB-EKG veri tabanı üzerindeki başarımları, CSSA segment sayısındaki artışın GKM'ye dayalı kümeleme yönteminin başarımlarını ve genelleme kabiliyetini büyük ölçüde arttırdığını göstermiştir.

Ayrıca, ME'nin ayrıricılığı en yüksek olan birleşik CSSA öznitelikleri ile GKM'ye dayalı kümeleme yöntemi ve YSA'ya dayalı sınıflandırma tekniği kullanılarak PTB-EKG veri tabanı üzerinde elde edilen en düşük (GK_D , YS_D) ve en yüksek (GK_Y , YS_Y) başarımları Tablo I'de gösterilmiştir. Geliştirilen gözetimli ve gözetimsiz öğrenme tekniklerinin veri tabanı üzerindeki başarımları kıyaslandığında, YSA'ya dayalı sınıflandırma tekniğinin daha yüksek başarımlara sahip olduğu görülmektedir.

Sonuç olarak, kritik birleşik CSSA özniteliklerini kullanan en iyilenmiş parametrelere sahip YSA'nın PTB-EKG veri tabanı üzerindeki başarımları, tekniğin CSSA anomalilerinin gürbüz tespitini gerçekleştirerek, oldukça güvenilir ME tespiti sağladığını göstermektedir. ME'nin güvenilir tespiti için EKG'nin sağladığı tanısal bilginin yeterli olmadığı durumlarda, bu çalışmada önerilen CSSA tabanlı anomali tespit tekniği kullanılarak, hastalığın gürbüz tespitinin başarımlarını artırılabilir. Böylece, ME'ye erken ve doğru tanı konulması sağlanarak, oklüzyon meydana gelen koroner arterde reperfüzyon tedavilerine erken başlanabilir ve kardiyovasküler hastalıkların mortalitesinde belirgin azalma sağlanabilir.



Şekil 3: PTB-EKG veri tabanındaki bir gönüllüye ait bazal CSSA özniteliklerinin birleşik olasılık yoğunluk fonksiyonunun en iyilenmiş hiperparametrelere sahip GKM ile kestirimi.

TABLO I: GKM'YE DAYALI KÜMELEME YÖNTEMİ VE YSA'YA DAYALI SINIFLANDIRMA TEKNİĞİ İÇİN EN DÜŞÜK VE EN YÜKSEK BAŞARIM SONUÇLARI (%)

Başarım Ölçütleri	GK_D	GK_Y	YS_D	YS_Y
Doğruluk	73.4	79.5	77.4	89.7
İsabet Oranı	77	82.1	79.8	92.3
Yanlış Alarm Oranı	30.1	25	27.2	14.8
Pozitif Tahmin Değeri	78.6	83.5	81.6	93.4
Negatif Tahmin Değeri	64.7	69.9	68	80
Özgüllük	69.9	75	72.8	85.2
Hata Oranı	26.6	20.5	22.6	10.3

BİLGİLENDİRME

Bu çalışma, Bilkent Üniversitesi Elektrik ve Elektronik Mühendisliği Bölümü tarafından desteklenmiştir.

KAYNAKLAR

- [1] M. B. Terzi, O. Arıkan, A. Abacı, M. Candemir and M. Dedoğlu, "Early diagnosis of acute coronary syndromes with automatic ST/T classifier", *2014 18th National Biomedical Engineering Meeting*, Istanbul, 2014, pp. 1-4.
- [2] D. K. Arnett, et al., "2019 ACC/AHA guideline on the primary prevention of cardiovascular disease: a report of the American College of Cardiology/American Heart Association Task Force on Clinical Practice Guidelines", *Journal of the American College of Cardiology*, 2019.
- [3] T. Kusayama, et al., "Skin sympathetic nerve activity and the temporal clustering of cardiac arrhythmias", *JCI Insight*, 2019.
- [4] M. B. Terzi, M. K. Korkmaz, O. Arıkan, S. Topal and A. Abacı, "Detection of Myocardial Ischaemia based on Artificial Neural Networks and Skin Sympathetic Nerve Activity", *EasyChair*, Preprint No. 2165, 2019.
- [5] M. Xu, et al., "Rule-based method for morphological classification of ST segment in ECG signals", *Journal of Medical and Biological Engineering*, 2015.
- [6] M. B. Terzi and O. Arıkan, "Detection of acute myocardial ischemia based on support vector machines", *2018 26th Signal Processing and Communications Applications Conference (SIU)*, Izmir, 2018, pp. 1-4.
- [7] Y. C. Yeh, et al., "Heartbeat Case Determination Using Fuzzy Logic Method on ECG Signals", *International Journal of Fuzzy Systems*, 2009.
- [8] M. Raihan, et al., "Risk Prediction of Ischemic Heart Disease Using Artificial Neural Network," *2019 International Conference on Electrical, Computer and Communication Engineering (ECCE)*, Bangladesh, 2019, pp. 1-5.
- [9] J. She, et al., "Recognition of Myocardial Ischemia Electrocardiogram Signal Based on Deep Learning," *2019 12th International Congress on Image and Signal Processing, BioMedical Engineering and Informatics (CISP-BMEI)*, China, 2019, pp. 1-6.
- [10] R. Bousseljot, et al., "Nutzung der EKG-Signaldatenbank Cardiodat der PTB über das Internet", *Biomedizinische Technik Biomedical Engineering*, 1995.
- [11] M. B. Terzi and O. Arıkan, "Coronary Artery Disease Detection by using Support Vector Machines and Gaussian Mixture Model", *2019 Medical Technologies Congress (TIPTEKNO)*, Izmir, Turkey, 2019, pp. 1-4.
- [12] M. B. Terzi and O. Arıkan, "Detection of Myocardial Ischaemia by using ECG, Artificial Neural Network and Gaussian Mixture Model", *2020 28th Signal Processing and Communications Applications Conference (SIU)*, Gaziantep, Turkey, 2020, pp. 1-4.
- [13] M. B. Terzi and O. Arıkan, "Anomaly Detection Technique Based on Sympathetic Nerve Activity for Detection of Cardiac Arrhythmia", *2020 28th Signal Processing and Communications Applications Conference (SIU)*, Gaziantep, Turkey, 2020, pp. 1-4.
- [14] M. B. Terzi, O. Arıkan, S. Karatay, F. Arıkan and T. Gulyaeva, "Classification of Regional Ionospheric Disturbance Based on Machine Learning Techniques", *European Space Agency, (Special Publication) ESA SP-740*, 2016.
- [15] M. B. Terzi, F. Arıkan, O. Arıkan and S. Karatay, "Classification of Regional Ionospheric Disturbances Based on Support Vector Machines", *41st COSPAR Scientific Assembly*, vol. 41, 2016.