

# Kardiyak Aritminin Otonom Sinir Sistemi, Gauss Karışım Modeli ve Yapay Sinir Ağı ile Tespiti Detection of Cardiac Arrhythmia 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, kardiyak aritminin (KA) gürbüz tespitini gerçekleştirmek amacıyla cilt sempatik sinir aktivitesindeki (CSSA) anomalileri güncel sinyal işleme ve makine öğrenmesi yöntemlerini kullanarak tespit eden yeni bir teknik geliştirilmiştir. Bu amaçla, MIT-BIH 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, KA'nın 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. KA'yı temsil eden aykırı değerlerin gürbüz tespitini gerçekleştirmek için Neyman-Pearson tipi bir yaklaşım geliştirilmiştir. Önerilen tekniğin MIT-BIH veri tabanı üzerindeki başarımları, tekniğin CSSA anomalilerinin gürbüz tespitini gerçekleştirecek, oldukça güvenilir KA tespiti sağladığını göstermektedir. Bu nedenle, KA'nın güvenilir teşhisi için EKG'nin sağladığı tanısal bilginin yeterli olmadığı durumlarda, önerilen teknik kullanılarak KA'ya erken tanı konulabilir ve kardiyovasküler hastalıkların mortalitesinde belirgin azalma sağlanabilir.

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

**Abstract**—In this study, a new technique which detects anomalies in skin sympathetic nerve activity (SKNA) by using state-of-the-art signal processing and machine learning methods is developed to perform the robust detection of cardiac arrhythmia (CA). For this purpose, a signal processing technique that simultaneously obtains SKNA and ECG from wideband recordings on MIT-BIH database is developed. By using preprocessed data, a novel feature extraction technique which obtains SKNA features that are critical for the reliable detection of CA 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 CA. The performance results of the proposed technique over MIT-BIH database showed that the technique provides highly reliable detection of CA 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 CA, 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

Kalp elektrik akımı üreten özelleşmiş hücreler, kimyasal değişiklikleri elektriksel ve mekanik bir uyarıya dönüştürerek, kalp kasının kasılmasını ve gevşemesini sağlamaktadır [1]. Her kalp atımı kalbin sağ üst köşesinde yer alan doğal uyarı merkezi sinoatrial (SA) düğümünden çıkan uyarı dalgası ile tetiklenmektedir. Uyarı dalgasının kalp içi uyarı yolları vasıtasıyla tüm kalbi uyarması sonucunda, kalp kasılarak içindeki kanı vücuda pompalamaktadır. Kalp atımlarını düzenleyen elektriksel uyarıların üretimindeki veya iletimindeki bir bozukluk sonucunda kalp atışları düzensizleşerek, kardiyak ritim bozukluğu olarak tanımlanan kardiyak aritmi (KA) meydana gelmektedir [1].

EKG'deki tanısal bilgilerin 150 Hz altındaki frekanslarda bulunması nedeniyle, Amerikan Kalp Derneği (AHA) EKG sinyallerinin görüntülenmesi için 0.5 Hz ile 150 Hz aralığında frekans bant genişliği önermektedir [2]. Geleneksel EKG cihazları kullanılarak yüksek frekanslı sinyalleri elde etmek amaçlanmadığından, bu cihazlar geniş frekans bant genişliğine ve yüksek örnekleme frekansına sahip değildir. Bu nedenle, yüksek frekanslı sinyaller, klinik açıdan önemli oldukları halde geleneksel EKG cihazlarındaki süzgeçleme sonucunda kayıtlı edilememektedir ve iskelet kasına ait aktiviteler (EMG) ile sinir sistemine ait aktiviteler büyük oranda gözlenmemektedir [1], [3].

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 [1], [3]. İnsanlarda, CSSA ile kardiyovasküler hastalıklar arasındaki ilişkiyi araştıran çalışmalar yeni başlamıştır ve bu çalışmalar CSSA ile KA arasındaki ilişkiyi araştırmıştır [1], [3]. Ancak, KA'nın güvenilir teşhisi için güncel makine öğrenmesi tekniklerini kullanarak CSSA'daki anomalileri tespit eden bir çalışma henüz bulunmamaktadır.

Literatürde, EKG'deki anomalileri tespit ederek KA'nın teşhisini gerçekleştirmek için çeşitli teknikler önerilmiştir. Farklı metodolojik yaklaşımları içeren bu teknikler bulanık mantık yöntemlerini [4], kural-bazlı teknikleri [5], destek vektör makinelerini (DVM) [6], yapay sinir ağlarını (YSA) [7] ve diğer makine öğrenmesi tekniklerini [8] kapsamaktadır. Bu teknikler arasında, YSA birçok sınıflandırma probleminin çözümünde yüksek başarımla 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, KA'nın 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, Boston Beth Israil Hastanesi (BIH), Kardiyoloji Anabilim Dalı'ndaki (ABD) 47 denekten KA öncesinde ve sırasında geniş frekans bant genişliğine ve düşük gürültü seviyesine sahip veri alım ekipmanları kullanılarak kaydedilen ham kayıtları içeren MIT-BIH veri tabanı kullanılmıştır [9]. Veri tabanı, KA sırasında elde edilen geniş bantlı verilerdeki aritmik EKG anomalilerini araştırmak amacıyla Massachusetts Teknoloji Enstitüsü (MIT) ve BIH Aritmi Laboratuvarı tarafından yürütülen klinik araştırma çalışması sonucunda oluşturulmuştur [9]. KA sırasında elde edilen geniş bantlı EKG verilerindeki indüklenmiş ritim değişikliklerini gösteren en büyük veri tabanıdır ve nadir olarak bulunan, ancak klinik olarak önemli olan KA'ları da içermektedir. KA'nın göğüs ön duvarı CSSA'sında yol açtığı yapısal anomalileri göstermesi nedeniyle çeşitli KA tespit tekniklerinin geliştirilmesi ve başarımlarının değerlendirilmesi için oldukça uygun bir test ortamı sunmaktadır. Veri tabanındaki deneklere ait tüm kayıtlar, KA'nın başlangıç ve bitiş zamanlarını göstermek üzere Kardiyoloji Anabilim Dalı uzmanlarınca etiketlenmiştir. Veri alımı sırasında, iskelet kasından kaynaklanan hareket artefaktlarını azaltmak amacıyla, prekordiyal EKG derivasyonları için standart elektrot konfigürasyonu kullanılırken, ekstremite derivasyonları için Mason-Likar elektrot konfigürasyonu kullanılmıştır. Kayıtların sayısallaştırılması sırasında, yüksek çözünürlüğe sahip sinyallerin elde edilebilmesi için 360 Hz örnekleme frekansı, 11-bit örnekleme çözünürlüğü ve 10  $\mu V$  genlik çözünürlüğü kullanılmıştır.


### B. Sinyal İşleme Tekniği

Geniş frekans bant genişliğine sahip cihazlar kullanılarak, KA öncesinde ve sırasında deneklerin göğüs ön duvarından kaydedilen elektriksel sinyallerden CSSA'yı ve EKG'yi eş zamanlı olarak elde eden özgün bir sinyal işleme tekniği geliştirilmiştir. Bu amaçla, MIT-BIH 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 60 Hz'lik güç hattı girişimini elimine eden bant geçiren ve çentik süzgeçler geliştirilmiştir.

Önerilen sinyal işleme tekniğinin, MIT-BIH veri tabanındaki ham kayıtlara uygulanması sonucunda, KA sırasında deneklerin göğüs ön duvarı CSSA genliklerinde artış olduğu görülmüştür. Ayrıca, KA sırasında göğüs ön duvarı CSSA genliklerinde meydana gelen artış ile eş zamanlı olarak, deneklerin kalp ritimlerinde artış olduğu görülmüştür. Önerilen sinyal işleme tekniği kullanılarak elde edilen sonuçlar, KA sırasında deneklerin göğüs ön duvarı CSSA sinyallerinde meydana gelen anomaliler ile EKG'deki kalp ritim değişikliklerinin ilintili olduğunu göstermiştir. Şekil 1'de önerilen sinyal işleme tekniğinin, veri tabanındaki iki farklı denneğin KA öncesinde ve sırasında kaydedilen ham kayıtlarına uygulanmasıyla elde edilen EKG ve göğüs ön duvarı CSSA sinyalleri gösterilmektedir.

### C. Öznitelik Çıkarım Tekniği

Sinyal işleme tekniğinin, veri tabanındaki deneklerden kaydedilen yüksek frekanslı ham kayıtlara uygulanmasıyla elde edilen göğüs ön duvarı CSSA sinyallerinden, KA'nın güvenilir tespiti için kritik



**Şekil 1:** Önerilen sinyal işleme tekniğinin, MIT-BIH veri tabanındaki iki farklı denneğin KA öncesinde ve sırasında kaydedilen geniş bantlı kayıtlarına uygulanmasıyla elde edilen EKG ve göğüs ön duvarı CSSA sinyalleri.

olan bazal ve aritmik özniteliklerin çıkarılmasını sağlayan özgün bir öznitelik çıkarım tekniği geliştirilmiştir. Öznitelik çıkarım tekniğinin, veri tabanındaki deneklere ait göğüs ön duvarı CSSA sinyallerine uygulanması sonucunda, KA'nın gürbüz tespiti için ayıricılığı en yüksek olan öznitelikler tüm denekler için elde edilmiştir.

1) *CSSA Tepe Sayısı (numCSSA)*: Veri tabanındaki her deneye ait göğüs ön duvarı CSSA sinyaline ( $s[n]$ ) özgü olarak uyarlanmış eşik değerler ( $\xi$ ) 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.

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

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

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.

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

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

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

### D. Sınıflandırma Tekniği

Öznitelik çıkarım tekniğinin, veri tabanındaki deneklerden elde edilen CSSA sinyallerine uygulanmasıyla elde edilen kritik bazal ve aritmik CSSA özniteliklerini kullanarak, KA'nın 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 normalleştirilmiştir.

Tekniğin daha önce görmediği veriler üzerindeki başarımını ve genelleme kabiliyetini belirlemek amacıyla her deneğe ait veri kümesi  $k$ -katlı çapraz geçerlilik yöntemi kullanılarak, eğitim kümesine ve test kümesine ayrıştırılmıştır. Bu amaçla, her deneğe 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 ağırlı eğitilmesi ve parametrelerinin en iyilenmesi için kullanılan eğitim kümesini oluşturmuştur. Buna ek olarak, ağırlı eğitim kümesine aşırı uyum sağlamasını engellemek amacıyla, eğitim kümesi rastgele bir şekilde eğitim (70%) ve doğrulama (30%) alt kümelerine ayrıştırılmıştır.

Geliştirilen ileri-beslemeli çok katmanlı ağırlı, 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 deneğe 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 bir deneğe 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 bir deneğe ait veri kümesi üzerindeki başarımları hesaplanarak, en yüksek başarıma sahip ÇKA deneğe özgü olarak belirlenmiştir.

YSA'nın eğitimi ileri-beslemeli kısımdan ve bir gözetimli öğrenme yöntemi olan geri-yayılımlı kısımdan oluşmaktadır. Eğitim sırasında, belirlenen ileri-beslemeli ve geri-yayılımlı iterasyon sayısı boyunca eğitim kümesi kullanılmıştır. İleri-beslemeli eğitim sırasında YSA'dan elde edilen çıktı hesaplanırken, geri-yayılımlı eğitim sırasında çıktıdaki hata YSA'nın gelecekteki hesaplamalarını düzeltmek ve istenilen çıktıya yakınsamak amacıyla kullanılmıştır. Başka bir deyişle, geri-yayılımlı 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-yayılım algoritması, (6)'da ve (7)'de gösterilen  $\mathbf{w}$ 'nin katmanlar arasındaki ağırlıklara ait ağırlık vektörü ve  $\eta$ 'nin öğrenme oranı olduğu durumda ortalama karesel hata  $E$ 'yi en küçükleme için kullanılan bir gradyan iniş yöntemidir [7].

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

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

Tekniğin başarımını 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-yayılımlı iterasyon sonrasında mevcut ağırlıklar kaydedilmiş ve YSA'nın başarımı doğrulama kümesi kullanılarak değerlendirilmiştir. YSA'nın eğitimi, doğrulama kümesi üzerindeki hata en küçükleme zaman sonlandırılmıştır. Böylece, en yüksek başarıma ve en iyilenmiş parametrelere sahip YSA bağımsız bir doğrulama kümesi kullanılarak deneğe özgü olacak şekilde belirlenmiştir.

En iyilenmiş YSA'nın daha önce görülmemiş bir veri kümesi üzerindeki başarımı ve genelleme kabiliyeti, tüm veri kümesinin temsili altkümelerini oluşturan bağımsız test kümesi kullanılarak gösterilmiştir. Geliştirilen tekniğin test kümesi üzerindeki başarımını 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 başarımını gösteren tek bir kestirim değeri elde edilmiştir.

### E. Kümeleme Tekniği

Buna ek olarak, aritmetik CSSA verilerinin eksik olduğu durumlarda, sadece bazal CSSA verilerini kullanarak KA'nın 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 ( $\Upsilon$ ) optimizasyonu karışımın olasılık yoğunluk fonksiyonunu en büyüleyecek şekilde gerçekleştirilir [10]. 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 [10]. Karışımın olasılık yoğunluk fonksiyonu (8)'deki gibi  $K$  adet Gauss yoğunluk bileşeninin ağırlıklandırılmış toplamı olarak ifade edilmekte ve  $\mathbf{x}$   $D$ -boyutlu veri vektörünü,  $\pi_k$  karışım katsayılarını,  $\mu_k$  ortalama değer vektörünü,  $\Sigma_k$  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.

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

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

KA'nın güvenilir tespiti için kritik olan bazal CSSA özneliklerinin birleşik olasılık yoğunluk fonksiyonunun kestirimi GKM kullanılarak gerçekleştirilmiştir. Şekil 2'de veri tabanındaki bir deneğe ait bazal CSSA özneliklerinin birleşik olasılık yoğunluk fonksiyonunun en iyilenmiş hiperparametrelere sahip GKM ile kestirimi gösterilmektedir.

KA'yı temsil eden aykırı değerlerin gürbüz tespitini gerçekleştirmek için Neyman-Pearson tipi bir yaklaşım geliştirilmiştir [11]–[13]. Bu amaçla, veri tabanındaki her deneğin bazal CSSA sinyali eşit

uzunluğa sahip  $N$  farklı segmente  $X = \{\mathbf{x}_1, \dots, \mathbf{x}_N\}$  bölütlenmiştir. Neyman-Pearson karar stratejisi, CSSA segmentlerinin ortalama log-olabilirlik değerlerinin (12)'de gösterildiği şekilde hesaplanmasıyla ve bu değerlerin farklı ayırım eşik değerleri ( $\Gamma$ ) ile (13)'deki gibi kıyaslanmasıyla uygulanmıştır [11]–[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 bir denek için hesaplanmıştır. Geliştirilen gözetimsiz öğrenme tekniğinin MIT-BIH veri tabanı üzerindeki başarımları, CSSA segment sayısındaki artışın GKM'ye dayalı kümeleme yönteminin başarımlarını ve genelleme kabiliyetini büyük ölçüde arttırdığını göstermiştir.

Ayrıca, KA'nın ayıricılığı en yüksek olan birleşik CSSA öznitelikleri ile GKM'ye dayalı kümeleme yöntemi ve YSA'ya dayalı sınıflandırma tekniği kullanılarak MIT-BIH 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 başarıma sahip olduğu görülmektedir.

Sonuç olarak, kritik birleşik CSSA özniteliklerini kullanan en iyilenmiş parametrelere sahip YSA'nın MIT-BIH veri tabanı üzerindeki başarımları, tekniğin CSSA anomalilerinin gürbüz tespitini gerçekleştirecek, oldukça güvenilir KA tespiti sağladığını göstermektedir. KA'nın güvenilir tespiti için EKG'nin sağladığı tanısal bilginin yeterli olmadığı durumlarda, bu çalışmada önerilen CSSA tabanlı anormali tespit tekniği kullanılarak, hastalığın gürbüz tespitinin başarımlarını artırılabilir. Böylece, KA'ya erken ve doğru tanı konulması sağlanarak, gerekli tedavilere erken başlanılabilir ve kardiyovasküler hastalıkların mortalitesinde belirgin azalma sağlanabilir.



**Şekil 2:** MIT-BIH veri tabanındaki bir deneye 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            | $GK_D$ | $GK_Y$ | $YS_D$ | $YS_Y$ |
|------------------------------|--------|--------|--------|--------|
| <b>Doğruluk</b>              | 69.1   | 75.2   | 73.1   | 85.4   |
| <b>İsabet Oranı</b>          | 72.8   | 77.8   | 75.4   | 88.1   |
| <b>Yanlış Alarm Oranı</b>    | 34.4   | 29.1   | 31.4   | 19.1   |
| <b>Pozitif Tahmin Değeri</b> | 74.3   | 79.2   | 77.3   | 89.1   |
| <b>Negatif Tahmin Değeri</b> | 60.3   | 65.7   | 63.8   | 75.7   |
| <b>Özgüllük</b>              | 65.6   | 70.9   | 68.6   | 80.9   |
| <b>Hata Oranı</b>            | 30.9   | 24.8   | 26.9   | 14.6   |

### BİLGİLENDİRME

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

### KAYNAKLAR

- [1] T. Kusayama, et al., "Skin sympathetic nerve activity and the temporal clustering of cardiac arrhythmias", *JCI Insight*, 2019.
- [2] 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.
- [3] A. Doytchinova, et al., "Simultaneous noninvasive recording of skin sympathetic nerve activity and electrocardiogram", *Heart Rhythm*, vol. 14, 2017.
- [4] B. Anuradha, et al., "Cardiac Arrhythmia Classification using Fuzzy Classifiers", *Journal of Theoretical and Applied Information Technology*, 2008.
- [5] A. Khelassi, et al., "Multi-arrhythmias detection with an XML rule-based system from 12-Lead Electrocardiogram", *Electronic Physician*, 2017.
- [6] M. B. Terzi and O. Arıkan, "Detection of Acute Coronary Syndrome Based on Support Vector Machines and ECG", *2019 27th Signal Processing and Communications Applications Conference (SIU)*, Sivas, Turkey, 2019, pp. 1-4.
- [7] 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.
- [8] 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.
- [9] G. B. Moody, et al., "The impact of the MIT-BIH Arrhythmia Database", *IEEE Engineering in Medicine and Biology Magazine*, 2001.
- [10] M. B. Terzi and O. Arıkan, "Coronary Artery Disease Detection by using Support Vector Machines and Gaussian Mixture Model", *2019 Medical Technologies Congress (TIPEKNO)*, Izmir, Turkey, 2019, pp. 1-4.
- [11] 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.
- [12] 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.
- [13] M. B. Terzi, O. Arıkan, S. Karatay and F. Arıkan, "Classification of Regional Ionospheric Disturbances based on Support Vector Machines," *8th International Union of Radio Science (URSI) Turkey'2016 National Committee*, Ankara, 2016.
- [14] 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.
- [15] 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.