

# Akut Miyokard İskemisinin Destek Vektör Makinelerine Dayalı Tespiti

## Detection of Acute Myocardial Ischemia Based on Support Vector Machines

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** —Akut miyokard iskemisine sahip hastalarda, miyokard infarktüsü başlangıcından önce göğüs ağrıları ile birlikte EKG sinyalinin ST/T kısmında değişiklikler meydana gelmektedir. Bu çalışmada, akut miyokard iskemisini teşhis etmek amacıyla, EKG sinyalinin ST/T kısmındaki değişiklikleri otomatik olarak tespit eden bir teknik geliştirilmiştir. Bu amaçla, STAFF III veritabanındaki EKG kayıtları kullanılarak, akut miyokard iskemisi teşhisi için kritik olan EKG öznitelikleri belirlenmiştir. Lineer ve radyal tabanlı fonksiyon (RBF) çekirdeklerine sahip destek vektör makineleri (DVM) kullanılarak, EKG sinyalinin ST/T kısmının ayırıcılığı en yüksek iki ve dört özniteliğini kullanan sınıflandırıcılar tasarlanmıştır. Geliştirilen tekniğin STAFF III veritabanındaki EKG sinyalleri üzerinde uygulanması sonucunda kayda değer sayıda hastadan elde edilen sonuçlar önerilen tekniğin oldukça güvenilir akut miyokard iskemisi tespiti sağladığını göstermektedir. Bu nedenle, geliştirilen teknik ile akut miyokard iskemisine erken ve doğru tanı konulması sağlanarak, morbidite ve mortalite oranlarında belirgin azalma sağlanabilir.

**Anahtar Kelimeler**—EKG, akut miyokard iskemisi, öznitelik çıkarımı, destek vektör makineleri, çekirdek fonksiyonları.

**Abstract**—In patients with acute myocardial ischemia, chest pains together with changes in ST/T sections of ECG signal occur before the start of myocardial infarction. In this study, in order to diagnose acute myocardial ischemia, a technique which automatically detects changes in ST/T sections of ECG is developed. For this purpose, by using ECG recordings of STAFF III database, ECG features that are critical in the detection of acute myocardial ischemia are identified. By using support vector machines (SVM) operating with linear and radial basis function (RBF) kernels, classifiers that use two and four most discriminating features of ST/T sections of ECG signal are designed. As a result of implementing the developed technique on ECG recordings of STAFF III database, obtained results over a considerable number of patients indicate that the proposed technique provides highly reliable detection of acute myocardial ischemia. Therefore, by using the developed technique, early and accurate diagnosis of acute myocardial ischemia can be performed, which can lead to a significant decrease in morbidity and mortality rates.

**Keywords**—ECG, acute myocardial ischemia, feature extraction, support vector machines, kernel functions.

### I. GİRİŞ

Akut miyokard iskemisi kalbi besleyen koroner arterlerdeki kan akışının azalması veya tamamen kesilmesine bağlı olarak gelişmekte ve miyokardiyum olarak da bilinen kalp kasında hücre ölümüne yol açarak, kalıcı hasar oluşmasına neden olmaktadır. Günümüzde kardiyovasküler hastalıklar tüm dünyada görülme sıklığı giderek artan başlıca ölüm sebebidir. Dünya Sağlık Örgütü (WHO) verilerine göre dünyada toplam ölümlerin %31'i koroner arter hastalıklarından kaynaklanmaktadır. Türkiye'de ise koroner arter hastalıklarından kaynaklanan ölümler tüm ölümlerin %40'unu oluşturarak, ilk sırada yer almaktadır [1]. Bu nedenle, iskemik kalp hastalıklarının hızlı ve güvenilir bir şekilde erken teşhis edilmesi önemli bir klinik ihtiyaçtır.

Akut miyokard iskemisi olan hastalarda, miyokard infarktüsü başlangıcından önce geçici göğüs ağrıları ile birlikte EKG'de ST segment ve T dalgasında değişiklikler meydana gelmektedir [2]. Bu nedenle, EKG sinyalinin ST segmenti ve T dalgasında meydana gelen değişiklikler sinyal işleme ve makine öğrenmesi teknikleri kullanılarak otomatik olarak tespit edilebilir, böylece miyokard iskemisine erken ve doğru tanı konulması sağlanarak, morbidite ve mortalitede belirgin azalma sağlanabilir.

Literatürde EKG sinyallerinin otomatik sınıflandırılması için çeşitli teknikler önerilmiştir. Bu tekniklerden yakın zamanda kullanılanlar; hibrit bulanık yapay sinir ağı sınıflandırıcısı, sinir bulanık sınıflandırıcı, doğrusal diskriminant sınıflandırıcı, kural bazlı kaba küme karar sistemi ve yüksek dereceli spektrum analiz tekniğidir [3]. DVM diğer sınıflandırma teknikleriyle kıyaslandığında, DVM sınıflandırıcısının, maksimum marjın prensibine dayalı yaklaşımı sayesinde daha yüksek genelleme kabiliyetine sahip olduğu görülmüştür. Ayrıca, geleneksel sınıflandırma tekniklerine göre DVM'nin boyut sayısına karşı hassasiyetinin daha az olduğu gösterilmiştir [4]. Bunun sebebi, DVM'nin maksimum marjın prensibi sayesinde, sınıflandırma görevini gerçekleştirmek için sınıfların istatistiksel dağılımının çok boyutlu öznitelik uzayında tahmin edilmesine gerek kalmamasıdır. Bu nedenlerden ötürü, akut

miyokard iskemisi tespit tekniđi geliřtirilirken, DVM kullanılarak diđer sınıflandırma tekniklerine kıyasla daha gürbüz ve verimli sınıflandırıcılar üretmek mümkündür.

## II. AMAÇ VE YÖNTEM

Bu çalışmada, koroner arter hastalarında veya koroner arter hastalığı riski yüksek olan kişilerde akut miyokard iskemisi teşhisi için EKG sinyalinin ST segmentinde ve T dalgasında oluşan deđişiklikleri otomatik olarak tespit eden gürbüz bir teknik geliřtirilmiştir.

### A. Veri Setinin Oluřturulması

Önerilen teknik, çeřitli fizyolojik sinyaller için araştırma kaynađı olması amacıyla oluşturulan PhysioNet isimli büyük bir veritabanının yapısında bulunan STAFF III EKG veritabanındaki 50 hastanın EKG verileri kullanılarak geliřtirilmiştir [5]. STAFF III EKG veritabanında göđüs ağrısı (angina pectoris) bulgusunu gösteren ve koroner arterinde perkütan transluminal koroner anjiyoplasti (PTCA) yapılan 104 hastanın standard 12-derivasyonlu EKG kayıtları bulunmaktadır [6]. PTCA işleminin sırasında oluşan damar oklüzyonu boyunca hastalardan alınan EKG kayıtları akut miyokard iskemisi için model oluşturulmaktadır. Veritabanındaki tüm hastalardan PTCA işlemi öncesinde 12-derivasyonlu bazal EKG sinyalleri ve PTCA işlemi sırasında 12-derivasyonlu iskemik EKG sinyalleri olmak üzere iki çeřit EKG verisi alınmıştır.

Veri alımı 1 kHz örnekleme sıklığına ve 0.6  $\mu V$  genlik çözünürlüğüne sahip bir EKG cihazı ile gerçekleştirilmiştir. Ekstremitelerden derivasyonları için iskelet kasından kaynaklanabilecek gürültüleri engellemek amacıyla Mason-Likar elektrot konfigürasyonu kullanılarak kayıt alınmış, prekordiyal derivasyonlar için ise standart elektrot konfigürasyonu kullanılarak kayıt alınmıştır. Bazal EKG kayıtları, kateter girişiminden önce hasta hareketsiz şekilde yatar pozisyondayken 5 dakika süreyle alınırken, iskemik EKG kayıtları hastaların ana koroner damarlarından birinde PTCA işlemi gerçekleştirilirken 4 dakika süreyle alınmıştır. Veri alımı sırasında ventriküler taşikardi geçiren hastalar veya sinyal kaybı olan EKG kayıtları veritabanına dahil edilmemiştir.

### B. Ön İşleme Teknikleri ve Öznitelik Tespiti

EKG sinyali ile ilgili bilgi içermeyen düşük ve yüksek frekanslı sinyal bileşenleri olan taban hattı kayması, hareket girişimi ve kas (EMG) gürültüsü alt kesim frekansı  $f_L = 0.05$  Hz üst kesim frekansı ise  $f_H = 150$  Hz olan bir bant geçiren süzgeç kullanılarak EKG sinyalinden çıkarılmıştır. Ayrıca, 50 Hz'lik güç hattı girişiminin EKG sinyalinden çıkarılması için Notch süzgeç kullanılmıştır. Sinyalin başlangıcındaki ve sonundaki ani deđişikliklerden kaynaklanan Gibbs etkisini azaltmak amacıyla, EKG sinyalleri süzgeçlenmeden önce başlangıç ve bitiři yumuřatılmış bir zaman penceresiyle çarpılmıştır. Süzgeçlenen EKG sinyallerinde QRS kompleks tespiti yapılmıştır. QRS kompleksinin tespiti için, genliđi P ve T dalgalarından yüksek ve QRS kompleksinden düşük olan bir eşik deđer belirlenmiştir. EKG sinyal genliklerinin belirlenen eşik deđer seviyesinden yüksek olduđu sinyal deđerleri bulunarak, QRS komplekslerinin zaman düzlemindeki tespiti gerçekleştirilmiştir. QRS kompleksi tespit edilen EKG sinyalleri bölütlenecek, periyotlarına ayrıştırılmıştır. EKG sinyalindeki izoelektrik

seviyesinin bulunması, akut miyokard iskemisi belirtisi olan ST segmentindeki çökmeyi ya da yükselmeyi belirlemek için önem taşıdığından, tüm periyotlar için izoelektrik seviye bulunarak EKG sinyalinden çıkarılmıştır. Ön işleme aşamalarının tamamlanmasından sonra akut miyokard iskemisi teşhisi için ayrılcılığı en yüksek olan dört EKG özniteliđi tüm hastalar için elde edilmiştir.

## III. DESTEK VEKTÖR MAKİNELERİ

Son yıllarda, sınıflandırma problemlerinin çözümü için geliřtirilmiş en başarılı makine öğrenimi algoritmalarından biri DVM'dir. DVM, birçok sınıflandırma probleminin çözümünde başarıyla uygulanmış, genelleme başarımı yüksek ve etkin bir makine öğrenimi algoritması olarak literatürdeki yerini almıştır. DVM'nin sahip olduđu algoritmalar başlangıçta iki sınıflı doğrusal verilerin sınıflandırılması problemi için tasarlanmış, daha sonra çok sınıflı ve doğrusal olmayan verilerin sınıflandırılması için genelleştirilmiştir [7]. DVM'nin çalışma ilkesi, iki sınıflı birbirinden en uygun şekilde ayırabilen ötelenmiş düzlemin tanımlanması esasına dayanmaktadır.

### A. Doğrusal Olarak Ayrılabilen Veriler İçin DVM

Eđitim verisini oluřturan  $n$  nokta Denklem 1'de gösterildiđi şekilde tanımlandığında,

$$D = \{(\mathbf{x}_m), y_m \mid \mathbf{x}_m \in R^p, y_m \in \{-1, 1\}\}_{m=1}^n \quad (1)$$

her bir  $\mathbf{x}_m$   $p$ -boyutlu öznitelik vektörünü,  $y_m$  ise 1 ya da -1 deđerini alarak,  $\mathbf{x}_m$  noktasının hangi sınıfa ait olduđunu gösterir. Amaç,  $y_m = 1$  ve  $y_m = -1$  deđerlerine sahip noktaları birbirinden ayıran, en büyük paya sahip ötelenmiş düzlemi belirlemektir. Her bir ötelenmiş düzlem Denklem 2'de gösterilen eşitliđi sađlayan nokta kümeleri kullanılarak tanımlanabilir:

$$\mathbf{w}^T \mathbf{x} = b \quad (2)$$


Denklem 2'de  $\mathbf{w}$  ötelenmiş düzleme normal olan vektörü gösterir. Ötelenmiş düzlemin normal vektör  $\mathbf{w}$  boyunca orijinden ofseti  $\frac{b}{\|\mathbf{w}\|_2}$  parametresi ile tanımlanır. Eđitim verisinin doğrusal olarak ayrılabildeđi durumlar için veriyi ayıran iki ötelenmiş düzlem seçilebilir ve bu iki ötelenmiş düzlem arasındaki uzaklık en büyüklenebilir. İki ötelenmiş düzlem arasındaki bölgeye "pay" denir. Denklem 3 ve 4 ötelenmiş düzlemleri ifade etmektedir.

$$\mathbf{w}^T \mathbf{x} - b = 1 \quad (3)$$

$$\mathbf{w}^T \mathbf{x} - b = -1 \quad (4)$$

Şekil 1'de görüldüđu üzere, bu iki ötelenmiş düzlem arasındaki uzaklık  $\frac{2}{\|\mathbf{w}\|_2}$  olduđu için, amaç  $\|\mathbf{w}\|_2$  parametresini en küçüklemeektir. Bu durumda en iyileme problemi Denklem 5'de gösterilen kořula bađlı kalarak,  $\|\mathbf{w}\|_2$  parametresini en küçükleme olarak tanımlanabilir.

$$y_m(\mathbf{w}^T \mathbf{x} - b) \geq 1 \quad \text{her } 1 \leq m \leq n \quad \text{için} \quad (5)$$



Şekil 1: İki sınıftaki örnekler ile eğitilen DVM için pay ve en büyük pay ötelenmiş düzlem.

#### B. Doğrusal Olarak Ayrılamayan Veriler İçin DVM

Verilerin doğrusal olarak ayrılmasının mümkün olmadığı problemlerde eğitim verilerinin bir kısmının en iyi ötelenmiş düzlemin diğer tarafında kalmasından kaynaklanan problem pozitif bir yapay değişkenin ( $\xi_m$ ) tanımlanması ile çözülmektedir. Payın maksimum hale getirilmesi ve yanlış sınıflandırma hatalarının minimum hale getirilmesi arasındaki denge bir düzenleme parametresinin ( $C$ ) tanımlanmasıyla kurulmaktadır. Doğrusal olarak ayrılamayan veriler için en iyileme problemi Denklem 6'da gösterildiği şekilde ifade edilmektedir.

$$\arg \min_{w, \xi, b} \left\{ \frac{1}{2} \|w\|_2^2 + C \sum_{m=1}^n \xi_m \right\} \quad (6)$$

Buna bağlı sınırlamalar ise Denklem 7'de gösterildiği şekilde ifade edilebilir.

$$y_m(\mathbf{w}^T \mathbf{x} - b) \geq 1 - \xi_m, \quad \xi_m \geq 0 \quad (7)$$

Denklem 6 ve 7'deki en iyileme problemi ve  $\|w\|_2$  parametresinin en küçüklenmesi Lagrange çarpanları kullanılarak, Denklem 8'de gösterildiği gibi ifade edilebilir:

$$\arg \min_{w, \xi, b} \max_{\alpha, \beta} \left\{ \frac{1}{2} \|w\|_2^2 + C \sum_{m=1}^n \xi_m - \sum_{m=1}^n \beta_m \xi_m - \sum_{m=1}^n \alpha_m [y_m(\mathbf{w}^T \mathbf{x} - b) - 1 + \xi_m] \right\} \quad (8)$$

Denklem 8'de gösterilen en iyileme probleminin çözümü için çekirdek hilesi yöntemi uygulanarak, verilerin düşük boyutlu girdi uzayından yüksek boyutlu öznitelik uzayına dönüştürülmesi için çekirdek fonksiyonları kullanılarak doğrusal olmayan haritalama gerçekleştirilebilir [8]. Böylece, girdi uzayında doğrusal olarak ayrılamayan veriler, öznitelik uzayında payı en büyük olan ayırıcı ötelenmiş düzlem bulunarak, doğrusal olarak ayrılabilir. Doğrusal olmayan dönüşümleri gerçekleştiren çekirdek fonksiyonu matematiksel olarak Denklem 9'da ifade edilmiştir. Bu çalışmada kullanılan lineer ve RBF çekirdek fonksiyonları sırasıyla Denklem 10 ve 11'de gösterilmiştir.

$$K(x_i, x_j) = \phi(x_i)\phi(x_j) \quad (9)$$

$$K(x_i, x_j) = (x_i \cdot x_j + c) \quad (10)$$

$$K(x_i, x_j) = \exp(-\gamma \|x_i - x_j\|^2), \quad \gamma > 0 \quad (11)$$

#### IV. GELİŞTİRİLEN AKUT MİYOKARD İSKEMİSİ TESPİT TEKNİĞİ

Bu çalışmada, akut miyokard iskemisi tespiti için DVM'ye ve çekirdek fonksiyonlarına dayalı bir gözetimli öğrenme tekniği geliştirilmiştir. Geliştirilen teknikteki öznitelik çıkarımı yöntemi vasıtasıyla hastalardan PTCA işlemi öncesinde ve sırasında alınan bazal ve iskemik EKG'ler kullanılarak, miyokard iskemisi teşhisi için kritik olan öznitelikler elde edilmiştir. Doğrusal olarak ayrılabilen verilerin sınıflandırılmasında, lineer çekirdek fonksiyonuna sahip DVM'ler kullanılırken, doğrusal olarak ayrılamayan verilerin sınıflandırılmasında RBF çekirdek fonksiyonuna sahip DVM'ler kullanılmıştır.

DVM algoritmasının belirli bir veri seti üzerindeki başarımının seçilen çekirdek fonksiyonunun parametrelerine büyük ölçüde bağlı olduğu bilinmektedir. Bu nedenle, geliştirilen DVM sınıflandırıcısının gürbüz bir şekilde çalışması için çekirdek fonksiyonunun parametrelerinin kullanılan veri setine uygun olacak şekilde seçilmesi gerekir. Bu amaçla, çalışmamızda DVM modelinin ve çekirdek fonksiyonunun parametreleri belirlenirken ızgara arama (grid-search) yöntemi ve çapraz geçerlilik yöntemi kullanılarak, gürbüz ve güvenilir sınıflandırıcılar tasarlanmıştır.

Geliştirilen tekniğin ön işleme aşamasında veriler z-skor normalleştirilmesi kullanılarak normalize edilmiştir. Böylece, eğitim algoritmasının her sınıfa aynı önemi vermesi sağlanmıştır. Daha sonra veri seti rastgele bir şekilde eğitim (80%) ve test (20%) setlerine bölünmüştür. Eğitim seti, ızgara araması yöntemi ve tekrarlı  $k$ -katlı çapraz geçerlilik yöntemi kullanılarak, DVM modelinin ve çekirdek fonksiyonunun parametreleri her hasta için spesifik olarak en iyilenecek şekilde sınıflandırıcılar tasarlanmıştır. Eğitim seti çapraz geçerlilik metodunu uygulamak için rasgele bir şekilde  $k=5$  parçaya bölünmüştür. Bu bölümün sonucunda elde edilen yeni veri setleri eğitim altkümesinden ve doğrulama altkümesinden oluşmaktadır. Eğitim altkümesi ile ızgara araması yöntemi kullanılarak, DVM algoritmasının farklı parametreleri için çeşitli modeller geliştirilmiş ve geliştirilen bu modeller doğrulama altkümesine uygulanmıştır. Bu prosedür, tekrarlı çapraz geçerlilik metodunun uygulanması sırasında eğitim altkümesinin her seferinde rasgele bir şekilde  $k=5$  farklı parçaya bölünmesi ile  $N=5$  kez tekrar edilmiştir. Böylece, geliştirilen DVM modellerinin doğrulama altkümesine uygulanması sonucunda önerilen tekniğin eğitim seti üzerindeki başarımının yansız kestirimi elde edilmiştir.


İstatistiksel sınıflandırma başarım ölçütleri olan isabet oranı (duyarlılık), yanlış alarm oranı, özgüllük (seçicilik), doğruluk, kesinlik (pozitif tahmin değeri), negatif tahmin değeri ve hata oranı tasarlanan tüm sınıflandırıcılar için her çapraz geçerlilik katında hesaplanmıştır. Farklı çapraz geçerlilik katlarında elde edilen başarım değerlerinin ortalaması alınarak, her bir başarım ölçütü ve parametre kombinasyonu için tek bir başarım kestirimi elde edilmiştir. Hesaplanan tüm başarım ölçütleri için en yüksek başarımın elde edildiği en iyi parametre değerleri ve en iyi DVM modeli her hasta için hastaya özgü olacak şekilde belirlenmiştir. Son olarak, hasta bazında geliştirilen en iyi DVM modelinin test veri setine uygulanması sonucunda önerilen tekniğin daha önce görülmemiş bir veri seti üzerindeki başarımı elde edilmiştir.

## V. SONUÇLAR VE TARTIŞMA

Geliştirilen tekniğin STAFF III veritabanındaki EKG sin-vallerine uygulanması sonucu akut koroner iskemisinin teşhisi için kritik EKG öznitelikleri olan ST segment seviyesi, ST segment eğimi, T dalgası genliği ve T dalgası altında kalan alan tüm hastalar için elde edilmiştir. Şekil 2'de birleşik öznitelikler ST segment seviyesi ve ST segment eğimi için bir hastaya ait EKG veri setinin RBF çekirdeğine ve en iyi çekirdek parametrelerine sahip DVM ile eğitimi gösterilmektedir. Şekilde gösterilen 'B' etiketine ait veriler hastanın bazal EKG'sini, 'A' etiketine ait veriler hastanın iskemik EKG'sini, 'SV' etiketine ait veriler ise destek vektörlerini göstermektedir.

Tablo I'de lineer ve RBF çekirdek fonksiyonunun en iyi parametrelerine sahip DVM modelinin, ST segmentini temsil eden iki birleşik öznitelik için en kolay, en zor ve ortalama vakaların sınıflandırma başarımları gösterilmektedir. Tablo I'deki iki farklı çekirdek fonksiyonu kullanılarak elde edilen sınıflandırma başarımları karşılaştırıldığında, lineer çekirdek fonksiyonuna sahip DVM ile doğrusal olarak ayrılabilen verilerin sınıflandırılması gerçekleştirildiğinden, lineer çekirdek fonksiyonuna sahip DVM kullanılarak daha yüksek başarımlar elde edildiği görülmektedir. RBF çekirdek fonksiyonuna sahip DVM ile doğrusal olarak ayrılamayan verilerin bulunduğu sınıflandırma problemlerinin çözümü gerçekleştirildiğinden, RBF çekirdek fonksiyonuna sahip DVM kullanılarak daha düşük başarımlar elde edilmiştir.

Tablo II'de RBF çekirdek fonksiyonunun en iyi parametrelerine sahip DVM modelinin, sadece ST segmentini temsil eden iki birleşik öznitelik ve ST segmentini ve T dalgasını temsil eden dört birleşik öznitelik için en kolay, en zor ve ortalama vakaların sınıflandırma başarımları gösterilmektedir. Tablo II'deki iki ve dört birleşik öznitelik kullanılarak elde edilen sınıflandırma başarımları karşılaştırıldığında, dört birleşik öznitelik kullanılarak elde edilen başarımların, iki birleşik öznitelik kullanılarak elde edilen başarımlardan daha yüksek olduğu görülmektedir. Bu nedenle, geliştirilen teknik ile elde edilen sonuçlar ST segmentini temsil eden özniteliklere T dalgasını temsil eden özniteliklerin eklenmesinin akut miyokard iskemisi tespitinin başarımlarını arttırdığını göstermektedir.



Şekil 2: Birleşik öznitelikler ST segment seviyesi ve ST segment eğimi için veri setinin RBF çekirdeğine ve en iyi çekirdek parametrelerine sahip DVM ile eğitimi.

TABLO I: DVM Modelinin ve Lineer ve RBF Çekirdeklerinin En İyi Parametreleri ile İki Birleşik Öznitelik İçin En Kolay, En Zor ve Ortalama Vakaların Başarım Sonuçları (%)

BAŞARIM ÖLÇÜTLERİ	HASTALAR					
	Lineer <sub>K,2</sub>	Lineer <sub>Z,2</sub>	Lineer <sub>O,2</sub>	RBF <sub>K,2</sub>	RBF <sub>Z,2</sub>	RBF <sub>O,2</sub>
Doğruluk	100	96.43	97.10	100	64.29	78.22
İsabet Oranı	100	91.83	95.75	100	64.71	78.26
Yanlış Alarm Oranı	0	6.67	0	0	36.36	21.88
Pozitif Tahmin Değeri	100	92.86	100	100	73.33	88.52
Negatif Tahmin Değeri	100	93.29	95.67	100	53.85	62.50
Özgüllük	100	93.33	100	100	63.63	78.13
Hata Oranı	0	3.57	2.90	0	35.71	21.78

TABLO II: DVM Modelinin ve RBF Çekirdeğinin En İyi Parametreleri ile İki ve Dört Birleşik Öznitelik İçin En Kolay, En Zor ve Ortalama Vakaların Başarım Sonuçları (%)

BAŞARIM ÖLÇÜTLERİ	HASTALAR					
	RBF <sub>K,2</sub>	RBF <sub>Z,2</sub>	RBF <sub>O,2</sub>	RBF <sub>K,4</sub>	RBF <sub>Z,4</sub>	RBF <sub>O,4</sub>
Doğruluk	100	64.29	78.22	100	78.57	89.29
İsabet Oranı	100	64.71	78.26	100	83.33	94.12
Yanlış Alarm Oranı	0	36.36	21.88	0	25	18.18
Pozitif Tahmin Değeri	100	73.33	88.52	100	71.43	88.89
Negatif Tahmin Değeri	100	53.85	62.50	100	85.71	90
Özgüllük	100	63.63	78.12	100	75	81.82
Hata Oranı	0	35.71	21.78	0	21.43	10.71

## TEŞEKKÜR

Gazi Üniversitesi Tıp Fakültesi Kardiyoloji Anabilim Dalı öğretim üyesi Prof. Dr. Adnan Abacı'ya değerli katkıları için teşekkür ederiz.

## KAYNAKLAR

- [1] E. J. Benjamin et al., American Heart Association Statistics Committee and Stroke Statistics Subcommittee, "Heart Disease and Stroke Statistics-2017 Update: A Report From the American Heart Association", Circulation, 135(10) e146-e603, 2017.
- [2] M. B. Terzi, O. Arkan, A. Abacı, M. Candemir and M. Dedoğlu, "Early Diagnosis of Acute Coronary Syndromes with Automatic ST/T Classifier", 18th National Biomedical Engineering Meeting, Istanbul, pp. 1-4, 2014.
- [3] S. H. Jambukia et al., "Classification of ECG Signals using Machine Learning Techniques: A Survey", International Conference on Advances in Computer Engineering and Applications, 2015.
- [4] C. J. C. Burges, "A Tutorial on Support Vector Machines for Pattern Recognition", Data Mining and Knowledge Discovery, 2, 121167, 1998.
- [5] A. L. Goldberger et al., "PhysioBank, PhysioToolkit, and PhysioNet", Circulation, 101(23) e215, 2000.
- [6] J. Petersson et al., "Spatial, Individual, and Temporal Variation of the High-Frequency QRS Amplitudes in the 12 Standard Electrocardiographic Leads", American Heart Journal, Volume 139, Issue 2, Part 1, 2000.
- [7] V. N. Vapnik, "An Overview of Statistical Learning Theory", IEEE Transactions on Neural Networks 10(5): 988-999, 1999.
- [8] M. B. Terzi, O. Arkan, S. Karatay, F. Arkan and T. Gulyaeva, "Classification of Regional Ionospheric Disturbance Based on Machine Learning Techniques", 41st COSPAR Scientific Assembly, Istanbul, 2016.