

Akut Koroner Sendromların Otomatik ST/T Sınıflandırıcısı İle Erken Tanısı

Early Diagnosis Of Acute Coronary Syndromes With Automatic ST/T Classifier

Merve Begüm Terzi¹, Orhan Arıkan¹, Adnan Abacı², Mustafa Candemir², Mehmet Dedoğlu¹

1. Elektrik ve Elektronik Mühendisliği Bölümü

Bilkent Üniversitesi

{mbterzi, oarikan, dedeoglu}@ee.bilkent.edu.tr

2. Tıp Fakültesi, Kardiyoloji Anabilim Dalı

Gazi Üniversitesi

{abaci}@gazi.edu.tr

{mstfcdmr}@hotmail.com

Özetçe

Akut koroner sendrom hastalarında, miyokard infarktüsü başlangıcından önce geçici göğüs ağrıları ile birlikte EKG'de ST segment ve T dalgasında değişiklikler meydana gelmektedir. Akut koroner sendrom teşhisini erken yapmak amacıyla, EKG sinyalinin ST/T kısmındaki değişiklikleri saptayan yeni bir teknik geliştirilmiştir. Geliştirilen tekniğin gerçek EKG sinyalleri üzerinde uygulanması sonucu önerilen tekniğin güvenilir tespitler yaptığı gösterilmiştir. Bu nedenle, geliştirilen teknik ile akut koroner sendromlara erken tanı konularak, kalp yetmezliği ve ölüm oranlarında belirgin azalma sağlanması beklenmektedir.

Anahtar Kelimeler: Elektrokardiogram (EKG) sinyal sınıflandırma, öznelik tespiti, destek vektör makinesi (DVM), kernel metodu, akut koroner sendrom, akut miyokard infarktüsü.

Abstract

In patients with acute coronary syndrome, temporary chest pains together with changes in ECG ST segment and T wave occur shortly before the start of myocardial infarction. In order to diagnose acute coronary syndromes early, a new technique which detects changes in ECG ST/T sections is developed. As a result of implementing the developed technique to real ECG recordings, it is shown that the proposed technique provides reliable detections. Therefore, the developed technique is expected to provide early diagnosis of acute coronary syndromes which will lead to a significant decrease in heart failure and mortality rates.

Keywords: Electrocardiogram (ECG) signal classification, feature detection, support vector machine (SVM), kernel method, acute coronary syndrome, acute myocardial infarction.

1. Giriş

Akut koroner sendrom, akut miyokard iskemisi ile seyreden durumlar için kullanılır ve ST yükselmeli miyokard infarktüsü, ST yükselmez miyokard infarktüsü ve kararsız angina pectoris klinik tablolarını kapsar [1]. Akut miyokard infarktüsülü hastalarda, semptom başlangıcından hastaneye başvurmaya kadar geçen süre ortalama 2.5-3 saati bulmaktadır. Miyokard nekrozunun ve ölümcül aritmilerin büyük bölümü koroner damarın tıkanmasından sonraki birkaç saat içinde meydana gelir. Akut koroner sendromlara erken ve doğru tanı konması halinde tedaviye erken başlanabilir ve ölüm ve kalp yetmezliğinde belirgin azalma sağlanabilir.

Akut koroner sendromlarda, göğüs ağrısı ile birlikte EKG'de ST segment ve T dalgasında değişiklikler meydana gelir. Göğüs ağrısı sırasında meydana gelen ST/T değişiklikleri otomatik olarak tespit edilebilir ve hastaya erken uyarı verilerek zamanında tıbbi yardım istemesi sağlanabilir. Böylece miyokard infarktüsü tanısının erken konması, tedaviye erken başlanması ve hastaların uygun hastanelere yönlendirilmesi sağlanabilir.

Literatürde EKG sinyallerinin otomatik sınıflandırılması için çeşitli teknikler önerilmiştir. Bu tekniklerden yakın zamanda kullanılanlar; hibrid bulanık yapay sinir ağı sınıflandırıcısı, sinir bulanık sınıflayıcı, lineer diskriminant sınıflandırıcı, kural bazlı kaba küme karar sistemi ve yüksek dereceli spektrum analiz tekniğidir [2, 3, 4, 5].

Destek vektör makineleri diğer sınıflandırma teknikleriyle kıyaslandığında, DVM sınıflandırıcısının, maksimum marjın prensibine (MMP) dayalı yaklaşımı sayesinde daha yüksek genelleme kabiliyetine sahip olduğu görülmüştür [6]. Ayrıca, geleneksel sınıflandırma tekniklerine göre DVM'nin boyut sayısına karşı hassasiyetinin daha az olduğu gösterilmiştir. Bunun sebebi, DVM'nin maksimum marjın prensibi sayesinde, sınıflandırma görevini gerçekleştirmek için sınıfların istatistiksel dağılımının çok boyutlu öznelik uzayında tahmin edilmesine gerek kalmamasıdır. Bu nedenlerden ötürü, EKG sınıflandırma sistemi tasarlanırken,

DVM kullanılarak diğer sınıflandırma tekniklerine kıyasla daha gübüz ve verimli sınıflandırıcılar üretmek mümkündür.

2. Amaç ve Yöntem

Çalışmamızın amacı, koroner arter hastalarında veya koroner arter hastalığı riski yüksek olan kişilerde, göğüs ağrısı meydana geldiğinde, bu ağrının akut koroner sendroma bağlı olup olmadığını otomatik olarak analiz edecek, böylece hastalara erken tanı konmasına ve tedavi uygulanmasına olanak sağlayacak bir sistem geliştirmektir.


Bu amaçla, koroner arter hastalarında meydana gelen kritik göğüs ağrılarının erken tespiti için, EKG sinyalinin ST/T kısmında meydana gelen değişiklikleri otomatik olarak analiz eden sinyal analiz teknikleri geliştirilmiştir.

2.1. Veri Setinin Oluşturulması

Geliştirilen sinyal analiz tekniklerinin uygulanması için piyasada bulunan çok kanallı bir EKG cihazı kullanılarak, Gazi Üniversitesi Tıp Fakültesi Kardiyoloji Anabilim Dalı üyeleri ve uzmanlarınca tanılanmış 50 hastanın EKG kayıtlarının yer aldığı bir veri tabanı oluşturulmuştur.

2.2. Öznitelik Tespiti


EKG kaydı esnasında, hastanın hareket etmesi durumunda oluşan, düşük frekanslı ve EKG sinyali ile ilgili bilgi içermeyen sinyal bileşeninin ve 50 Hz'lik şebeke geriliminin EKG sinyalinden çıkarılması amacıyla bant geçiren süzgeç kullanılmıştır. Sinyalin başlangıcındaki ve sonundaki ani değişikliklerden kaynaklanan Gibbs etkisini azaltmak amacıyla, EKG sinyali başlangıç ve bitişi yumuşatılmış bir zaman penceresiyle çarpıldıktan sonra süzgeçlenmiştir. Süzgeçlenen EKG sinyallerinde QRS kompleks tespiti yapılmıştır. QRS kompleksinin tespiti için, genliği P ve T dalgalarından yüksek ve QRS kompleksinden düşük olan bir eşik değeri belirlenmiştir. EKG sinyal genliğinin belirlenen eşik değeri seviyesinden yüksek olduğu sinyal değerleri kıyaslanarak, QRS komplekslerinin zaman düzlemindeki tespiti gerçekleştirilmiştir [7].



Şekil 1: Süzgeçlenen EKG Sinyalinde QRS Tespiti

QRS tepe noktası tespit edilen EKG sinyalleri, bölütlenecek periyotlarına ayrıştırılmıştır. EKG sinyalindeki izoelektrik

seviyesinin bulunması, ST parçasındaki çökmeyi ya da yükselmeyi belirlemek için önem taşıdığından, tüm periyotlar için izoelektrik seviye bulunarak, EKG sinyalinden çıkarılmıştır.



Şekil 2: İzoelektrik Seviyenin Çıkarılması İle Elde Edilen Bir Periyotluk EKG Sinyali


EKG sinyalinin ön işleme aşamalarının tamamlanmasıyla akut koroner sendrom teşhisi için önem taşıyan özniteliklerin (ST segment seviyesi, ST segment eğimi ve T dalga alanı) tespiti tüm derivasyonlar için gerçekleştirilmiştir.

3. Geliştirilen Akut Koroner Sendrom Tespit Tekniği

EKG sinyallerini yüksek sınıflandırma performansları elde ederek sınıflandırmak amacıyla destek vektör makineleri ve çekirdek fonksiyonları kullanılmıştır. Birleşik özniteliklerin iki boyutlu sınıflandırması, lineer ve radyal tabanlı çekirdek fonksiyonuna sahip destek vektör makineleri kullanılarak gerçekleştirilmiştir [8].

Doğrusal olarak ayrılabilen verilerin sınıflandırılmasında, lineer çekirdek fonksiyonuna sahip destek vektör makineleri kullanılırken, doğrusal olarak ayrılamayan verilerin sınıflandırılmasında radyal tabanlı çekirdek fonksiyonuna sahip destek vektör makineleri kullanılmıştır.


Lineer ve radyal tabanlı çekirdek fonksiyonuna sahip destek vektör makinelerinin en iyi parametrelere sahip olan modelleri 5-katlı çapraz geçerlilik yöntemi kullanılarak bulunmuştur.



Şekil 3: Birleşik Özniteliklerin Lineer Çekirdek Fonksiyonuna ve Optimum Çekirdek Parametrelerine Sahip DVM ile Eğitilmesi

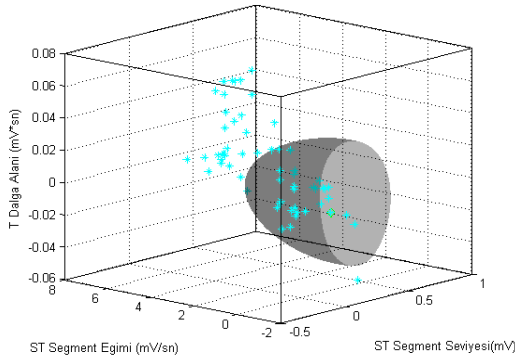
Şekil 3’de birleşik öznitelikler ST segment seviyesi ve ST segment eğimi için veri setinin lineer çekirdek fonksiyonuna ve optimum çekirdek parametrelerine sahip DVM ile eğitilmesi gösterilmektedir.

Şekil 4’de ise birleşik öznitelikler ST segment seviyesi ve ST segment eğimi için veri setinin radyal tabanlı çekirdek fonksiyonuna ve optimum çekirdek parametrelerine sahip DVM ile eğitilmesi gösterilmektedir. Her iki şekilde de ‘B’ ve ‘A’ etiketleri iki farklı EKG veri çeşidini, ‘SV’ etiketi ise destek vektörlerini göstermektedir.



Şekil 4: Birleşik Özniteliklerin Radyal Tabanlı Çekirdek Fonksiyonuna ve Optimum Çekirdek Parametrelerine Sahip DVM ile Eğitilmesi

Buna ek olarak, birleşik özniteliklerin üç boyutlu sınıflandırması, radyal tabanlı çekirdek fonksiyonuna sahip destek vektör makineleri kullanılarak gerçekleştirilmiştir. Şekil 5’de birleşik öznitelikler ST segment seviyesi, ST segment eğimi ve T dalga alanı için veri setinin radyal tabanlı çekirdek fonksiyonuna ve optimum çekirdek parametrelerine sahip DVM ile eğitilmesi gösterilmektedir.



Şekil 5: Birleşik Özniteliklerin Radyal Tabanlı Çekirdek Fonksiyonuna ve Optimum Çekirdek Parametrelerine Sahip DVM ile Eğitilmesi

İstatistiksel sınıflandırma başarımları ölçütleri olan isabet oranı (duyarlılık), yanlış alarm oranı, özgüllük (seçicilik), doğruluk, kesinlik (pozitif tahmin değeri), negatif tahmin değeri sonuçları tasarlanan tüm sınıflandırıcılar için hesaplanmış, en yüksek başarımları veren sınıflandırıcılar seçilmiştir. Tablo 1’de geliştirilen sınıflandırma tekniğinin performans

analizini gerçekleştirmek için kullanılan hata matrisi görülmektedir.

Tablo 1: Sınıflandırma Modeli Hata Matrisi

		Tahmin Edilen Sınıf	
		Negatif	Pozitif
Gerçek Sınıf	Negatif	Doğru Negatif	Yanlış Pozitif
	Pozitif	Yanlış Negatif	Doğru Pozitif

- Doğru Negatif (DN): Bir örneğin negatif olduğunu gösteren doğru tahmin sayısı.
- Yanlış Pozitif (YP): Bir örneğin pozitif olduğunu gösteren yanlış tahmin sayısı.
- Yanlış Negatif (YN): Bir örneğin negatif olduğunu gösteren yanlış tahmin sayısı.
- Doğru Pozitif (DP): Bir örneğin pozitif olduğunu gösteren doğru tahmin sayısı.

Hata matrisi kullanılarak elde edilen sınıflandırma başarımları ölçütlerinin tanımları aşağıda verilmiştir.

Duyarlılık (İsabet Oranı): Testin, gerçek hastalar için hastaları ayırma yeteneğidir.

$$\text{Duyarlılık} = \frac{DP}{DP + YN}$$

Özgüllük (Seçicilik): Testin, gerçek sağlıklı kişiler için sağlıklı kişileri ayırma yeteneğidir.

$$\text{Özgüllük} = \frac{DN}{DN + YP}$$

Yanlış Alarm Oranı: Testin, gerçek sağlıklı kişiler için hatalı olarak hasta dediği olgulardır.

$$\text{Yanlış Alarm} = \frac{YP}{YP + DN}$$

Kesinlik (Pozitif Tahmin Değeri) : Testin sonucuna göre belirlenen pozitifler içerisindeki doğru pozitiflerin oranıdır.

$$\text{Kesinlik} = \frac{DP}{DP + YP}$$

Negatif Tahmin Değeri (NTD): Testin sonucuna göre belirlenen negatifler içerisindeki doğru negatiflerin oranıdır.

$$\text{NTD} = \frac{DN}{DN + YN}$$

Doğruluk: Testin, hasta ve sağlıklı olarak toplam doğru tanı oranıdır.

$$\text{Doğruluk} = \frac{DP + DN}{DP + YP + YN + DN}$$

Tablo 2: İki Öznitelik ve Radyal Tabanlı Çekirdek Fonksiyonunun Optimum Parametreleri İçin DVM Sınıflandırıcısının Performans Ölçüt Sonuçları (%)

Performans Ölçütleri	Hastalar			
	H1	H2	H3	H4
Duyarlılık	100.00	95.48	94.30	91.88
Yanlış Alarm Oranı	0	2.47	0	3.51
Özgüllük	93.25	98.31	100.0	89.74
Doğruluk	97.86	99.12	96.93	96.57
Pozitif Tahmin Değeri	100.00	92.34	100.0	100.0
Negatif Tahmin	94.18	100.00	94.29	90.84

Tablo 3: Üç Öznitelik ve Radyal Tabanlı Çekirdek Fonksiyonunun Optimum Parametreleri İçin DVM Sınıflandırıcısının Performans Ölçütü Sonuçları (%)

Performans Ölçütleri	Hastalar			
	H1	H2	H3	H4
Duyarlılık	100.0	98.16	97.66	95.73
Yanlış Alarm Oranı	0	0.14	0	0.68
Özgüllük	96.48	100.00	100.00	93.54
Doğruluk	100.0	100.00	98.94	98.76
Pozitif Tahmin Değeri	100.0	97.82	100.00	100.0
Negatif Tahmin Değeri	96.75	100.00	97.65	93.72

Tablo 2 ve 3’de dört farklı vaka için elde edilen iki ve üç boyutlu sınıflandırma başarımları sonuçları gösterilmektedir. Bileşik öznitelikler kullanılarak gerçekleştirilen iki ve üç boyutlu sınıflandırma için hesaplanan başarımları sonuçları karşılaştırıldığında, üç öznitelik kullanarak gerçekleştirilen sınıflandırma başarımlarının, iki öznitelik kullanarak gerçekleştirilen sınıflandırma başarımlarından daha yüksek olduğu gözlemlenmiştir.

4. EKG Segment Sayısı ile Yanlış Alarm ve İsbet Olasılıkları Arasındaki İlişkinin Olasılıksal Analizi


EKG segment sayındaki artışın yanlış alarm olasılığı (P_{FA}) üzerindeki etkisini analiz etmek amacıyla, her bir EKG veri segmentinin bağımsız ve özdeşçe dağılmış olduğu varsayımı ile, başka bir deyişle ardışık EKG segmentlerinde sınıflayıcının performansının aynı kaldığını ve segmentler arasındaki kararların istatistiksel olarak birbirlerinden bağımsız olduğunu varsayarak, ardışık olarak artan segmentlerin yanlış alarm olasılıkları aşağıdaki formülü kullanarak teorik olarak hesaplanmıştır. (N_s : segment sayısı, P_{FA} : yanlış alarm olasılığı)

$$P_{FA_{total}} = \sum_{k=N_s/2}^{N_s} \binom{N_s}{k} (P_{FA})^k (1 - P_{FA})^{k-1} \quad (1)$$

Ayrıca, ardışık olarak artan aynı segmentler için DVM kullanılarak elde edilen yanlış alarm olasılıkları bulunmuştur. Yapılan analizler sonucunda, EKG segment sayısı arttıkça yanlış alarm olasılığının azaldığı gözlemlenmiştir.


Bununla birlikte, teorik olarak hesaplanan yanlış alarm olasılıkları ile, DVM kullanılması durumunda gözlemlenen yanlış alarm olasılıkları karşılaştırıldığında, gözlemlenen yanlış alarm olasılıklarının teorik olarak hesaplanan yanlış alarm olasılık değerlerine çok yakın olduğu görülmüştür.

Benzer şekilde, EKG segment sayısı artışının isbet olasılığı üzerindeki etkisini analiz etmek amacıyla, ardışık olarak artan segmentler için DVM kullanılarak elde edilen isbet olasılıkları incelenmiştir. Analiz sonucunda, EKG segment sayısındaki artışın, verilerin ayrımcılık özelliğini artırması sonucu, isbet olasılığı değerlerinde artışa yol açtığı görülmüştür.



Şekil 6: EKG Segment Sayısı ve Yanlış Alarm Olasılığı Arasındaki İlişkinin Grafiksel Gösterimi

Tablo 4’de ardışık olarak artan EKG segment sayıları için DVM kullanılarak elde edilen yanlış alarm ve isbet olasılık (P_D) değerlerindeki değişim gösterilmektedir. Sonuçlar incelendiğinde, ardışık segmentlerden DVM ile elde edilen sınıflandırma sonuçlarının çoğunluk karar füzyon yöntemi kullanılarak tümleştirilmesi sonucu, destek vektör makinelerinin sınıflandırma performanslarının arttırıldığı görülmektedir.



Şekil 7: EKG Segment Sayısı ve İsbet Olasılığı Arasındaki İlişkinin Grafiksel Gösterimi

Tablo 4: Ardışık Olarak Artan Segment Sayısı için Yanlış Alarm ve İsbet Olasılık Değerleri

Segment Sayısı	1	3	5	7	9	11	13	15	17	19
P_{FA}	1	0.557	0.246	0.077	0.032	0.005	0.001	0	0	0
P_D	0.921	0.948	0.967	0.980	0.989	0.996	0.999	1	1	1

Teşekkür

Bu çalışma (113E174) TÜBİTAK tarafından Bilimsel ve Teknolojik Araştırma Projelerini Destekleme Programı (1001) kapsamında desteklenmektedir.

Kaynaklar

- [1] S. Hongzong, W. Tao, Y. Xiaojun, L. Huanxiang, H. Zhide, L. Mancang, ve F. BoTao, "Support vector machines classification for discriminating coronary heart disease patients from non-coronary heart disease," *West Indian Medical Journal*, vol. 56, pp. 451-457, 10 2007.
- [2] S. Osowski ve T. H. Linh, "ECG beat recognition using fuzzy hybrid neural network," *IEEE Trans. Biomed. Eng.*, vol. 48, no. 11, pp. 1265-1271, Nov. 2001.
- [3] L. Khadra, A. S. Al-Fahoum ve S. Binajaj, "A quantitative analysis approach for cardiac arrhythmia classification using higher order spectral techniques," *IEEE Trans. Biomed. Eng.*, vol. 52, no. 11, pp. 1840-1845, Nov. 2005.
- [4] S. Mitra, M. Mitra ve B. B. Chaudhuri, "A rough set-based inference engine for ECG classification," *IEEE Trans. Instrum. Meas.*, vol. 55, no. 6, pp. 2198-2206, Dec. 2006.
- [5] F. De Chazal, M. O'Dwyer ve R. B. Reilly, "Automatic classification of ECG heartbeats using ECG morphology and heartbeat interval features," *IEEE Trans. Biomed. Eng.*, vol. 51, no. 7, pp. 1196-1206, Jul. 2004.
- [6] V. Vapnik, *Statistical Learning Theory*. New York: Wiley, 1998.
- [7] G. D. Clifford, F. Azuaje ve P. McSharry, *Advanced Methods And Tools for ECG Data Analysis*. Norwood, MA, USA: Artech House, Inc., 2006.
- [8] S. Amari ve S. Vu, "Improving support vector machine classifiers by modifying kernel functions," *Neural Networks*, vol. 12, no. 6, pp. 783-789, 1999.