

## KARDİOTOKOGRAM VERİSİNDEN FETAL İYİLİK HALİNİN BELİRLENMESİ İÇİN BİR KARAR DESTEK SİSTEMİ

*Ersen YILMAZ* \*

Alınma: 18.03.2016; düzeltme: 17.11.2016; kabul: 27.11.2016

**Öz:** Bu çalışmada kardiyotokogram verisinden fetal iyilik halinin belirlenmesi için bir karar destek sistemi önerilmiştir. Sistem En Küçük Kareler Destek Vektör Makineleri ve Temel Bileşen Analizi üzerinde temellendirilmiştir. Temel Bileşen Analizi yöntemi ile kardiyotokogram veri kümesinin boyutu indirgenmiştir. Özellik boyutu indirgenen veri kümesi üzerinde En Küçük Kareler Destek Vektör Makineleri kullanılarak sınıflandırma işlemi gerçekleştirilmiştir. Önerilen karar destek sisteminin başarımları UCI Makine Öğrenmesi Ambarlarından alınan kardiyotokogram veri kümesi üzerinde 10-katlı Çapraz Doğrulama tekniği kullanılarak incelenmiştir. Deneysel sonuçlar önerilen sistemin %98,74 sınıflandırma doğruluğuna, %98,86 duyarlılık oranına ve %98,73 özgüllük oranına sahip olduğunu göstermiştir.

**Anahtar Kelimeler:** Kardiyotokogram, Karar destek sistemi, Destek vektör makineleri, Temel bileşen analizi, Fetal iyilik hali

### A Decision Support System for Determination of Fetal Well-Being from Cardiotocogram Data

**Abstract:** In this study, we propose a decision support system for assessment of fetal well-being from cardiotocogram data. The system is based on Principal Component Analysis and Least Squares Support Vector Machines. Principal Component Analysis is used for feature reduction of the cardiotocogram data set. Classification of the data set with reduced features is made by using Least Squares Support Vector Machines. Performance analysis of the proposed system is examined on the cardiotocogram data set available on UCI Machine Learning Repository by using 10-fold Cross Validation procedure. Experimental results show that the proposed system has 98.74% classification accuracy, 98.86% sensitivity and 98.73% specificity rates.

**Keywords:** Cardiotocogram, Decision support system, Support vector machines, Principal component analysis, fetal well-being

## 1. GİRİŞ

Fetal kalp hareketliliği hamileliğin erken dönemlerinden itibaren başlar. Otonom sinir sisteminin gelişim aşamaları fetal kalp hızının (FKH) kontrolü ve değişiminde önemli bir role sahiptir. Ayrıca, fetalın oksijen seviyesi FKH'nın bazı bileşenlerini etkilemektedir (Fanelli ve diğ., 2013). Dolayısıyla, fetalın sağlık durumunun başka bir deyişle fetal iyilik halinin izlenmesinde FKH önemli bir parametre olarak kullanılmaktadır.

Kardiyotokografi gebelik döneminde ve doğum sırasında fetal sağlık durumunun izlenmesi amacıyla kullanılan bir yöntemdir. Kardiyotokogram (KTG), FKH ve uterin aktivite sinyallerinin kaydından oluşmaktadır (Georgoulas ve diğ., 2006). KTG takibi ile fetalın oksijen yetmezliği

\* Uludağ Üniversitesi, Mühendislik Fakültesi, Elektrik-Elektronik Mühendisliği Bölümü, 16059, Bursa  
İletişim Yazarı: Ersen Yılmaz (ersen@uludag.edu.tr)

yaşayıp yaşamadığının erken tespiti yapılabilir, böylece ilave testler gerçekleştirilebilir veya erken doğum kararı verilir (Alfirevic ve diğ., 2013).

KTG'nin doğru olarak analiz edilmesi daha sonra izlenecek adımlar açısından hayati öneme sahiptir. Bu nedenle, makine öğrenmesi yöntemleri kullanılarak KTG verisinden fetal iyilik halinin belirlenmesine yönelik çalışmalar son dönemde ilgi çekmeye başlamıştır. Bu çalışmaların önemli bir bölümünde aynı KTG verisi kullanılmıştır (Ocak ve Ertunç, 2013; Ocak, 2013; Huang ve Hsu, 2012; Sundar ve diğ., 2012; Sundar ve diğ., 2013; Karabulut ve İbrikçi, 2014; Jezewski ve diğ., 2014; Yılmaz ve Kılıkçier, 2013; Ravindran ve diğ., 2015).

Fetal iyilik halinin belirlenmesi problemi Ocak ve Ertunç (2013) ile Ocak (2013) çalışmalarında iki sınıflı sınıflandırma problemi olarak ele alınmıştır.

Ocak ve Ertunç (2013) problemin çözümü için bir Uyarlanabilir Sinirsel Bulanık Çıkarım Sistemi (USBÇS) önermişlerdir.

Ocak (2013) fetal iyilik halinin değerlendirilmesi için Destek Vektör Makineleri (DVM) ve Genetik Algoritma (GA) üzerinde temellendirilmiş bir karar destek sistemi önermiştir.

Aynı problem Huang ve Hsu (2012), Sundar ve diğ. (2012), Sundar ve diğ. (2013), Karabulut ve İbrikçi (2014), Jezewski ve diğ. (2014), Yılmaz ve Kılıkçier (2013) ile Ravindran ve diğ. (2015) çalışmalarında üç sınıflı sınıflandırma problemi olarak incelenmiştir.

Huang ve Hsu (2012) problemin çözümünde Ayırma Analizi, Karar Ağacı ve Yapay Sinir Ağı (YSA) yöntemlerini kullanmıştır.

Sundar ve diğ. (2012) KTG verisinin sınıflandırılması için bir YSA modeli önermiştir. Önerilen YSA modelinin başarımı Sundar ve diğ. (2013) çalışmasında K-Ortalamalı ve Bulanık C-Ortalamalı öbekleme algoritmalarının başarımı ile karşılaştırılmıştır.

Karabulut ve İbrikçi (2014) fetal durumunu tahmin etmek için Karar Ağacı temelli bir Uyarlanabilir Boosting yöntemi önermiştir.

Jezewski ve diğ. (2014) üç farklı özellik seçimi algoritmasının fetal durumunun belirlenme kalitesine olan etkisini araştırmıştır.

Yılmaz ve Kılıkçier (2013) Fetal durumunun belirlenmesi için En Küçük Kareler DVM (EKK-DVM) ve İkili Karar Ağaçları üzerinde temellendirilmiş bir karar destek sistemi önermiştir.

Ravindran ve diğ. (2015) İyileştirilmiş Uyarlanabilir Genetik Algoritmalar (İUGA) ve Aşırı Öğrenme Makinesi (AÖM) yöntemlerini bir arada kullanarak fetal iyilik halinin belirlenmesi için bir medikal karar destek sistemi önermişlerdir.

Bu çalışmada Ocak ve Ertunç (2013), Ocak (2013), Huang ve Hsu (2012), Sundar ve diğ. (2012), Sundar ve diğ. (2013), Karabulut ve İbrikçi (2014), Jezewski ve diğ. (2014), Yılmaz ve Kılıkçier (2013) ve Ravindran ve diğ. (2015) çalışmalarında kullanılan KTG veri kümesi kullanılmış ve fetal iyilik halinin belirlenmesi problemi Ocak ve Ertunç (2013) ve Ocak (2013) çalışmalarında olduğu gibi iki sınıflı sınıflandırma problemi olarak ele alınmıştır.

Problemin çözümü için Temel Bileşen Analizi (TBA) ve EKK-DVM üzerinde temellendirilmiş bir karar destek sistemi önerilmiştir. Ocak ve Ertunç (2013) ve Ocak (2013) çalışmalarında önerilen sistemlerin başarımlarını incelemeleri yapılırken KTG veri seti %50-%50 eğitim ve test kümesi biçiminde ayrıştırılmıştır. Bu çalışmada ise başarımlarını incelemesi daha kararlı sonuçların alınabileceği 10-katlı Çapraz Doğrulama (10kÇD) tekniği kullanılarak gerçekleştirilmiştir. TBA ile özellik vektörü boyutu indirgenmiş ve EKK-DVM ile ikili sınıflandırma probleminin çözümü gerçekleştirilmiştir. Başarımlarını sonuçları sınıflandırma doğruluğu, hata matrisi, duyarlılık ve özgüllük ölçütleri kullanılarak sunulmuştur.

## 2. İLGİLİ ÇALIŞMALAR

Literatürde bu çalışmada da kullanılan KTG veri kümesini kullanan çalışmalar, problemi ele alış biçimlerine göre iki grupta toplanabilirler. Birinci grupta yer alan çalışmalar, Huang ve Hsu (2012), Sundar ve diğ. (2012), Sundar ve diğ. (2013), Karabulut ve İbrikçi (2014), Jezewski ve

diğ. (2014), Yılmaz ve Kılıkçier (2013) ile Ravindran ve diğ. (2015), fetal iyilik halinin belirlenmesi problemini üç sınıflı sınıflandırma problemi olarak ele alırken ikinci grupta yer alan çalışmalar, Ocak ve Ertunç (2013) ile Ocak (2013), aynı problemi iki sınıflı olarak ele almışlardır.

Huang ve Hsu (2012) bir Çok Katmanlı Algılayıcı YSA (ÇKA-YSA) modeli ile %97,80 sınıflandırma doğruluğuna ulaşmışlardır. Başarım incelemesi veri kümesi %80 eğitim, %10 test ve %10 doğrulama kümesi olarak ayrıştırılarak yapılmıştır.

Sundar ve diğ. (2012) çalışmasında problemin çözümü için yine bir ÇKA-YSA modeli önerilmiştir. Modelin başarımı 10 deneme yapılarak test edilmiştir. Başarım sonuçları her bir deneme için kesinlik, hassasiyet ve F-Ölçütü ölçekleri cinsinden sunulmuştur. Aynı yazarlar önerdikleri ÇKA-YSA modeli ile K-Ortalomalı ve Bulanık C-Ortalomalı öbeleme algoritmalarının başarımını Sundar ve diğ. (2013) çalışmasında karşılaştırmışlardır. İlgili çalışmada, ÇKA-YSA'nın başarım sonuçlarının daha iyi olduğu ve öbeleme algoritmalarının Şüpheli ve Patolojik örneklerin sınıflandırmasında zayıf kaldıkları görülmektedir.

Karabulut ve İbrikçi (2014) fetal durumunun belirlenmesi probleminin çözümünde altı farklı modelin başarım karşılaştırmasını yapmışlardır. Ayrıca, Uyarlanabilir Boosting algoritmasının bu modellerin başarımını üzerindeki etkisini incelemişlerdir. En yüksek başarım oranı %95,01 sınıflandırma doğruluğu ile Uyarlanabilir Boosting algoritmasında C4.5 karar ağacı temel sınıflandırıcı olarak kullanıldığında elde edilmiştir. Başarım incelemesi yapılırken 10kÇD tekniği kullanılmıştır.

Jezewski ve diğ. (2014) üç özellik seçim / indirgeme yönteminin fetal durumunu belirleme kalitesi üzerindeki etkisini incelemişlerdir. Sınıflandırma yöntemi olarak Lagragian DVM kullanmışlardır. Başarım sonuçlarını etkinlik, duyarlılık, özgüllük ve kalite indisi ölçekleri cinsinden sunmuşlardır.

Yılmaz ve Kılıkçier (2013) iki adet EKK-DVM sınıflandırıcıyı İkili Karar Ağaç yapısı ile birlikte kullanarak problemin çözümünü gerçekleştirmişlerdir. EKK-DVM'lerin başarımını artırmak için çekirdek fonksiyonlarının parametre değerlerini Parçacık Sürüsü Optimizasyonu ile belirlemişlerdir. Başarım analizi yapılırken 10kÇD kullanılmış ve %91,62'lik sınıflandırma doğruluğuna ulaşmışlardır.

Ravindran ve diğ. (2015) AÖM ile İUGA yöntemlerini bir arada kullanarak fetal iyilik halinin belirlenmesi probleminin çözümünü yapmışlardır. İUGA ile özellik seçimi yaparak AÖM ile sınıflandırma işlemini gerçekleştirmişlerdir. Başarım incelemesi 10kÇD tekniğini kullanarak yapılmış ve %93,61 sınıflandırma doğruluğuna ulaşmışlardır.

Ocak ve Ertunç (2013) fetal iyilik halinin belirlenmesi problemini iki sınıflı sınıflandırma problemi olarak çözmüşlerdir. Çözüm için bir USBÇS önermişlerdir. Sistemin başarım incelemesini veri kümesini %50 eğitim ve %50 test kümesine ayırarak gerçekleştirmişlerdir. Önerilen USBÇS'nin test kümesi üzerinde %96,6 duyarlılık ve %97,2 özgüllük oranlarına sahip olduğu görülmektedir.

Ocak (2013) çalışmasında problem yine iki sınıflı olarak ele alınmış ve GA ile EKK yöntemleri üzerinde temellendirilmiş bir karar destek sistemi önerilmiştir. GA ile özellik seçimi yapılmış ve EKK ile sınıflandırma işlemi gerçekleştirilmiştir. Sistemin başarım incelemesi veri kümesi %50 eğitim ve %50 test kümesi biçiminde ayrıştırılarak yapılmıştır. Önerilen GA-EKK sisteminin test kümesi başarım sonuçlarından %100 duyarlılık ve %99,3 özgüllük oranlarına sahip olduğu görülmektedir.

Bu çalışmada fetal iyilik halinin belirlenmesi problemi iki sınıflı sınıflandırma problemi olarak ele alınmıştır. Literatürde problemi iki sınıflı olarak ele alan Ocak ve Ertunç (2013) ve Ocak (2013) çalışmalarında önerilen sistemlerin başarım incelemeleri yapılırken veri kümesi %50 eğitime ve %50 test kümesi biçiminde ayrıştırılmıştır. Bu çalışmada ise başarım incelemesi daha kararlı sonuçların alınabileceği 10kÇD tekniği kullanılarak yapılmış ve TBA ile EKK temelli bir karar destek sistemi ile çözümü gerçekleştirilmiştir.

### 3. TEMEL YAPI TAŞLARI

#### 3.1. Temel Bileşen Analizi

Temel Bileşen Analizi (TBA), boyut indirgeme amacıyla sıklıkla kullanılan doğrusal bir yöntemdir. Boyut indirgeme işlemi, verinin daha küçük boyutta olan ve temel altuzay olarak bilinen bir doğrusal altuzaya gömülmesi ile sağlanır (Van der Maaten ve diğ., 2009).

$(x_i, y_i)_{i=1}^N$ ,  $x_i \in \mathfrak{R}^p$  ve  $y_i \in \{1, 2, \dots, c\}$  biçiminde verilen  $N$  elemanlı bir veri kümesi için, ( $x_i$ ,  $p$  özelliğe sahip örnekleri ve  $y_i$  ise bu örneklere ilişkin sınıf bilgisini göstermek üzere), temel altuzaya ait eksenler (1) denkleminde verilen evrensel ortak-değişinti matrisi  $S$ 'den türetilir.

$$S = \frac{1}{N} \sum_{j=1}^c \sum_{i=1}^{N_j} (x_i^j - \mu)(x_i^j - \mu)^T \quad (1)$$

burada  $\mu$  tüm örneklerin evrensel ortalama değerini,  $x_i^j$   $j$ 'nci sınıftan olan  $i$ 'nci örneği,  $N_j$   $j$ 'nci sınıfa ait örnek sayısını ve  $c$  ise sınıf sayısını göstermektedir.

$m$  adet temel eksen,  $K_1, \dots, K_m$ ,  $S$ 'nin ilk  $m$  en değerli özvektörü bulunarak elde edilir:

$$SK_i = \lambda_i K_i, i = \{1, 2, \dots, m\}, m < p \quad (2)$$

burada  $\lambda_i$ ,  $S$ 'nin  $i$ 'inci en büyük özdeğeridir.

Veri kümesindeki herhangi bir  $x_i$  örneğinin temel bileşenleri (3) denklemi ile elde edilir:

$$\bar{x}_i = K^T x_i, i = \{1, 2, \dots, N\} \quad (3)$$

burada  $\bar{x}_i \in \mathfrak{R}^m$  ve  $K = [K_1, K_2, \dots, K_m]$  (Wang ve Paliwal, 2003).

#### 3.2. En Küçük Kareler Destek Vektör Makineleri

En Küçük Kareler Destek Vektör Makineleri (EKK-DVM) Suykens ve Vandewalle (1999) tarafından önerilmiştir. Geleneksel DVM (Boser ve diğ., 1992) üzerinde temellendirilmiş hesaplama yükü daha hafif bir yöntemdir.  $(x_i, y_i)_{i=1}^N$ ,  $x_i \in \mathfrak{R}^p$  ve  $y_i \in \pm 1$  biçiminde verilen  $N$  elemanlı bir veri kümesi için, ( $x_i$ ,  $p$  özelliğe sahip örnekleri ve  $y_i$  ise bu örneklere ilişkin sınıf bilgisini göstermek üzere), EKK-DVM aracılığıyla (4) denklemi ile verilen eniyileme probleminin çözümü gerçekleştirilir:

$$\text{En Küçükleme } J_{LS}(w, e) = \frac{1}{2} \|w\|^2 + \frac{1}{2} \gamma \sum_{i=1}^N e_i^2 \quad (4)$$

$$\text{Kısıtlama, } y_i (w^T \varphi(x_i) + b) = 1 - e_i, i = \{1, 2, \dots, N\}$$

burada  $w$  aşırı düzleme olan normal vektör,  $b$  yan veya dengeleyici bir sabit,  $\varphi(.)$  örnek noktalarını daha yüksek boyutlu bir uzaya haritalayan doğrusal olmayan bir fonksiyon,  $\gamma$  ve  $e_i$  ise sırasıyla ceza ve arttıran yapay değişkenler olarak tanımlanır (Boser ve diğ. 1992; Suykens ve Vandewalle, 1999; Krupa ve diğ. 2011; Yılmaz ve Kılıkçılar, 2013).

(4) denkleminin çözümü için aşağıda verilen Lagrangian fonksiyonu tanımlanır:

$$L_{LS}(w, b, e; \alpha) = J_{LS}(w, e) - \sum_{i=1}^N \alpha_i \{y_i [w^T \varphi(x_i) + b] - 1 + e_i\} \quad (5)$$

burada  $\alpha_i$ 'ler Lagrange çarpanlarıdır. Eniyileme aşağıdaki doğrusal denklem takımının çözümü ile gerçekleştirilir (Suykens ve Vandewalle, 1999):

$$\left[ \begin{array}{c|c} 0 & -Y^T \\ \hline Y & ZZ^T + \gamma^{-1}I \end{array} \right] \left[ \begin{array}{c} b \\ \alpha \end{array} \right] = \left[ \begin{array}{c} 0 \\ I \end{array} \right] \quad (6)$$

burada  $Z = [\varphi^T(x_1)y_1; \dots; \varphi^T(x_N)y_N]$ ,  $Y = [y_1; \dots; y_N]$ ,  $I = [I; \dots; I]$ ,  $\alpha = [\alpha_1; \dots; \alpha_N]$ .

EKK-DVM sınıflandırıcısı aşağıdaki gibi tanımlanır ve (6) ile verilen doğrusal denklem takımının çözümü ile elde edilir:

$$f(x) = \text{sign} \left( \sum_{i=1}^N y_i \alpha_i K(x, x_i) \right) + b \quad (7)$$

$K(x, x_i)$  çekirdek fonksiyonu olarak isimlendirilir ve iki vektörün yüksek boyutlu uzaydaki iç çarpımı biçiminde tanımlanır,  $\varphi(x)^T \varphi(x_i)$  (Boser ve diğ. 1992; Suykens ve Vandewalle, 1999; Krupa ve diğ., 2011; Yılmaz ve Kılıkçılar, 2013).

#### 4. ÖNERİLEN KARAR DESTEK SİSTEMİ

Bu çalışmada önerilen sistemin mimarisi Şekil 1'de verilmiştir. Sistem iki aşamalı bir yapıya sahiptir. Birinci aşamada KTG veri kümesinin özellik vektörü boyutu detayları 3.1 alt bölümünde verilen TBA yöntemi yardımıyla indirgenmektedir. İndirgenmiş özellik vektörüne sahip KTG verisi sınıflandırma işleminin gerçekleştirilmesi amacıyla EKK-DVM sınıflandırıcısına uygulanmaktadır. EKK-DVM'in çalışma prensipleri 3.2 alt bölümünde verilmiştir.

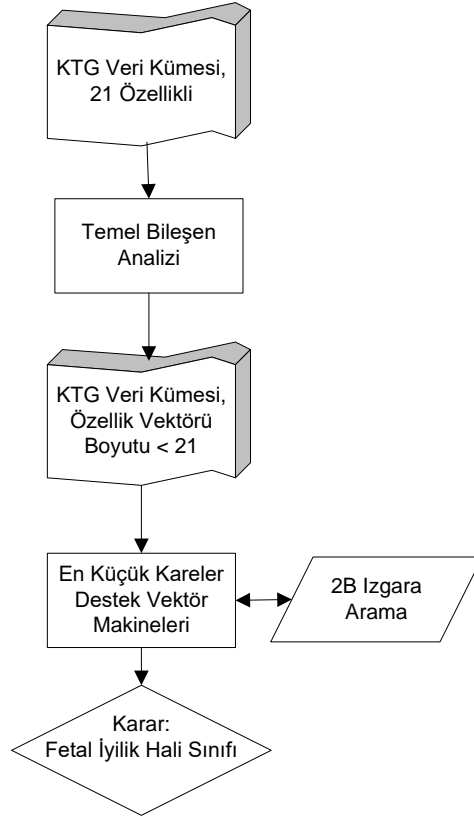
Önerilen sistemde EKK-DVM'in çekirdek fonksiyonu olarak (8) denklemi ile verilen radial temelli fonksiyon kullanılmaktadır.

$$K(x, x_i) = \exp\left(-\frac{1}{2\sigma^2}(x - x_i)^2\right) \quad (8)$$

burada  $\sigma^2$  çekirdek fonksiyonunun genişliğidir.

En yüksek başarımlı sonucunun elde edilmesi amacıyla EKK-DVM parametreleri  $\gamma$  ve  $\sigma^2$ 'nin değerleri eniyileme yoluyla belirlenmektedir. Eniyileme işleminde iki boyutlu (2B) ızgara arama yöntemi kullanılmaktadır. 2B ızgara arama yönteminde  $\gamma$  ve  $\sigma^2$ 'nin en iyi değerleri belirlenen tanım aralıklarında aynı anda aranmaktadır.

Bu çalışmada EKK-DVM parametrelerinin en iyi değerleri [0,001 1.000] aralığı aranarak belirlenmiştir.  $\gamma$  ve  $\sigma^2$ 'nin, 0,001'den başlayan ve ölçeklenmiş adım genişliği ile 1.000'e kadar ulaşan tüm değerleri için EKK-DVM başarımlı sonuçları elde edilmiştir. Bu başarımlı sonuçları arasında en yüksek EKK-DVM başarımlı veren  $\gamma$  ve  $\sigma^2$  değerleri en iyi değerler olarak seçilmiştir.



**Şekil 1:**  
Önerilen TBA-EKK-DVM mimarisi

## 5. DENEYLER

### 5.1. Kardiyotokogram Veri Kümesi

Bu çalışmada UCI Makine Öğrenmesi Ambarları'ndan alınan KTG veri kümesi kullanılmıştır (<http://archive.ics.uci.edu/ml/datasets/Cardiotocography>, Erişim Tarihi: 01.01.2016). Veri kümesinde 23 özellekle tanımlanmış 2126 örnek bulunmaktadır. Son iki özellik FKH örneği ve fetal durumu ile ilgili sınıf kodunu vermektedir. Her bir örnek FKH örneği ve fetal durumuna göre sınıflandırılabilir. Fetal durumu için Normal, Patolojik ve Şüpheli olmak üzere üç sınıf kodu bulunmaktadır. 2126 örneğin 1655 adeti Normal, 176 adeti Patolojik ve 295 adeti ise Şüpheli sınıfına aittir. KTG veri kümesine ait özelliklerin açıklamaları ve detayları (<https://archive.ics.uci.edu/ml/datasets/Cardiotocography>; Ayres-de-Campos ve diğ., 2000) kaynaklarında bulunabilir.

### 5.2. Başarım Analizi

Önerilen karar destek sisteminin başarımlarını incelemek için 10kÇD tekniği kullanılarak yapılmıştır. Başarım ölçütleri olarak sınıflandırma doğruluğu, hata matrisi, duyarlılık ve özgüllük kullanılmıştır. Çapraz doğrulama tekniği ve kullanılan ölçütler alt bölümlerde açıklanmıştır.

### 5.2.1. Çapraz Doğrulama

Çapraz Doğrulama (ÇD), makine öğrenmesi algoritmalarının başarımlarını incelemelerinde kullanılan istatistiksel bir yöntemdir. ÇD’de veri kümesi eğitim ve test kümesi olmak üzere ikiye ayrılır. Bu kümeler, her bir örneğin bir kez doğrulama şansına sahip olacağı biçimde, ardışık tekrarlamalar yoluyla birbirleriyle karşılaştırılır (Refaeilzadeh ve diğ., 2009; Kohavi ve Provost 1998, Yılmaz ve Kılıkçier, 2013). Detaylı bilgi (Refaeilzadeh ve diğ., 2009) ile (Kohavi ve Provost, 1998) çalışmalarında bulunabilir.

### 5.2.2. Sınıflandırma Doğruluğu

Sınıflandırma doğruluğu, bir sınıflandırıcının doğru olarak tahmin ettiği örnek sayısının veri kümesinde yer alan tüm örnek sayısına oranı olarak basit bir biçimde açıklanabilir (Kohavi ve Provost, 1998).

### 5.2.3. Hata Matrisi

Hata matrisi, bir veri kümesi için tahmin edilen ve gerçek sınıflandırmaları gösterir. İki sınıflı bir sınıflandırma problemi için hata matrisi Tablo 1’de verildiği gibi 2x2 boyutlu olarak oluşur (Kohavi ve Provost, 1998; Yılmaz, 2013).

**Tablo 1. Hata matrisi**

Tahmin Edilen	Gerçek	
	Pozitif	Negatif
Pozitif	<i>DP (Doğru Pozitif)</i>	<i>YP (Yanlış Pozitif)</i>
Negatif	<i>YN (Yanlış Negatif)</i>	<i>DN (Doğru Negatif)</i>

### 5.2.4. Duyarlılık ve Özgüllük

Duyarlılık doğru pozitif oranı, özgüllük ise doğru negatif oranı olarak tanımlanırlar ve (9) ile (10) denklemlerinde verildiği gibi ifade edilirler (Kohavi ve Provost 1998; Yılmaz, 2013).

$$Duyarlılık = \frac{DP}{DP + YN} \quad (9)$$

$$Özgüllük = \frac{DN}{YP + DN} \quad (10)$$

## 5.3. Deneysel Sonuçları

Fetal iyilik halinin belirlenmesi problemi iki sınıflı sınıflandırma problemi olarak ele alınmıştır. KTG veri kümesi 1.655 adet Normal ve 176 adet Patolojik örneğe sahiptir. Deneyler yapılırken 10kÇD tekniği kullanılmıştır. Veri kümesinde yer alan örneklerin 21 adet olan özellik vektörü boyutu TBA yöntemi kullanılarak indirgenmiştir. Deneyler yapılırken, indirgenmiş özellik vektörü boyutu olarak [5-15] aralığı kullanılmış ve EKK-DVM parametrelerinin ( $\gamma$  ve  $\sigma^2$ ) seçimi [0,001 1.000] arasında iki boyutlu ızgara arama yöntemiyle gerçekleştirilmiştir.

Yapılan deneyler sonucunda en yüksek başarı, indirgenmiş özellik boyutunun 10 ve EKK-DVM parametrelerinin  $\gamma=100$  ve  $\sigma^2 = 2$  olduğu durumda gerçekleşmiştir. Önerilen sistemin bu durum için 10kÇD başarımları sonuçları Tablo 2 ve Tablo 3’de sunulmuştur.

**Tablo 2. TBA-EKK-DVM’in her bir kat için sınıflandırma doğruluğu ve ortalama sınıflandırma doğruluğu (% Olarak)**

Kat-1	Kat-2	Kat-3	Kat-4	Kat-5	Kat-6	Kat-7	Kat-8	Kat-9	Kat-10
99,45	99,46	98,36	98,91	99,45	98,91	99,45	98,36	98,36	96,72
Ortalama Sınıflandırma Doğruluğu : 98,74									

**Tablo 3. TBA-EKK-DVM için hata matrisi**

Tahmin Edilen	Gerçek	
	Patolojik	Normal
Patolojik	174	21
Normal	2	1.634
Toplam	176	1.655

Hata matrisi kullanılarak duyarlılık ve özgüllük değerleri sırasıyla %98,86 ve %98,73 olarak elde edilmiştir.

#### 5.4. Tartışma

Bu çalışmada elde edilen sonuçlar ile aynı veri kümesi üzerinde daha önce yapılan çalışmaların sonuçları başarımları karşılaştırması yapmak amacıyla Tablo 4’de sunulmuştur.

**Tablo 4. Önerilen sistem ile daha önce yapılan çalışmaların karşılaştırılması**

Yöntem	Başarım İncelemesi	Duyarlılık	Özgüllük
USBÇS, Ocak ve Ertunç (2013)	%50 Eğitilme % 50 Test	% 96,6	% 97,2
GA-DVM (Özellik Vektörü Boyutu=13), Ocak 2013	%50 Eğitilme % 50 Test	% 100	% 99,3
TBA-EKK-DVM (Bu Çalışma, İndirgenmiş Özellik Vektörü Boyutu =10)	10kÇD	% 98,9	% 98,7

Tablo 4 incelendiğinde TBA-EKK-DVM’in duyarlılık ve özgüllük oranlarının USBÇS’in ilgili oranlarından %2,3 ve %1,5 daha iyi olduğu, GA-DVM’e ait duyarlılık ve özgüllük oranlarından ise %1,1 ve %0,6 daha kötü olduğu görülmektedir. Fakat şunu da not etmek gerekir ki; GA-DVM’in başarımları sonuçları 13 adet özellik vektörü kullanılarak elde edilmiştir. TBA-EKK-DVM’in başarımları sonuçları ise indirgenmiş özellik vektörü boyutunun 10 olduğu durum için elde edilmiştir. Ayrıca, GA-DVM’in başarımları incelemesi yapılırken veri kümesi eğitilme ve test kümesi olmak üzere ikiye ayrılırken, TBA-EKK-DVM’de ise 10kÇD tekniği kullanılmıştır.



## 6. SONUÇLAR VE GELECEK ÇALIŞMALAR

Bu çalışmada kardiyotokogram verisinden fetal iyilik halinin belirlenmesi için Temel Bileşen Analizi ve En Küçük Kareler Destek Vektör Makineleri yöntemleri üzerinde temellendirilmiş bir karar destek sistemi önerilmiştir. Sistemin başarımı 10 katlı Çapraz Doğrulama tekniği kullanılarak incelenmiştir. Yapılan deneyler ile önerilen sistemin %98,7 sınıflandırma doğruluğuna, %98,9 duyarlılık oranına ve %98,7 özgüllük oranına sahip olduğu gösterilmiştir. Ayrıca, daha önce yapılan çalışmalarda kullanılan sistemler ile karşılaştırıldığında önerilen sistemin önemli bir başarımla sonucuna eriştiği görülmektedir.

Yapılan deneyler ışığında; bu çalışmada önerilen Temel Bileşen Analizi ve En Küçük Kareler Destek Vektör Makineleri yöntemlerine dayanan sistemin kardiyotokogram verisinden fetal iyilik halinin tespitinde başarılı bir karar destek sistemi olarak kullanılabileceği sonucuna varılmıştır.

Gelecek çalışmalar kapsamında düşük özellik vektörü boyutu ile yüksek başarımlı oranların elde edilebileceği melez yöntemlerin çalışılması planlanmaktadır.

## TEŞEKKÜR

Yazar, UCI Makine Öğrenmesi Ambarlarına değerli bir açık veri tabanı olduğu için teşekkür eder. Lichman, M. (2013). UCI Machine Learning Repository [<http://archive.ics.uci.edu/ml>]. Irvine, CA: University of California, School of Information and Computer Science.

## REFERANSLAR

1. Alfirovic, Z., Devane, D. ve Gyte, G.M.L. (2013). Continuous cardiotocography (CTG) as a form of electronic fetal monitoring (EFM) for fetal assessment during labour, *Cochrane Database of Systematic Reviews*. doi: 10.1002/14651858.CD006066.pub2
2. Ayres-de-Campos, D., Bernardes, J., Garrido, A. ve diğ. (2000). SisPorto 2.0: a program for automated analysis of cardiotocograms. *Journal of Maternal-Fetal and Neonatal Medicine*, 9(5), 311–318. doi: 10.3109/14767050009053454
3. Boser, B.E., Guyon, I.M. ve Vapnik, V.N. (1992). A training algorithm for optimal margin classifiers, *5th Annual ACM Workshop on Computational Learning Theory*, Pittsburgh, PA, USA, 144–152. doi: 10.1145/130385.130401
4. Fanelli, A., Magenes, G., Campanile, M. ve Signorini, M.G. (2013). Quantitative assessment of fetal well-being through CTG recordings: A new parameter based on phase-rectified signal average. *IEEE Journal of Biomedical and Health Informatics*, 17(5), 959-966. doi: 10.1109/JBHI.2013.2268423
5. Georgoulas, G., Stylios, C.D. ve Groumpos, P.P. (2006). Predicting the risk of metabolic acidosis for newborns based on fetal heart rate signal classification using support vector machines, *IEEE Transactions on Biomedical Engineering*, 53(5), 875–884. doi: 10.1109/TBME.2006.872814
6. Huang, M. ve Hsu, Y. (2012). Fetal distress prediction using discriminant analysis, decision tree, and artificial neural network, *Journal of Biomedical Science and Engineering*. doi: 10.4236/jbise.2012.59065
7. Jezewski, M., Czabanski, R. ve Leski, J. (2014). The influence of cardiotocogram signal feature selection method on fetal state assessment efficacy, *Journal of Medical Informatics & Technologies*, 23, 51-58.

8. Karabulut, E.M. ve Ibrıkci, T. (2014). Analysis of cardiotocogram data for fetal distress determination by decision tree based adaptive boosting approach, *Journal of Computer and Communications*, 2(9), 32-37. doi: 10.4236/jcc.2014.29005
9. Kohavi, R. ve Provost, F. (1998). Glossary of terms, *Machine Learning*, 30(2-3), 271-274.
10. Krupa, N., MA, M.A., Zahedi, E., Ahmed, S. ve Hassan, F.M. (2011). Antepartum fetal heart rate feature extraction and classification using empirical mode decomposition and support vector machine, *BioMedical Engineering Online*. doi: 10.1186/1475-925X-10-6
11. Ocak, H. ve Ertunç, H.M. (2013). Prediction of fetal state from the cardiotocogram recordings using adaptive neuro-fuzzy inference systems, *Neural Computing and Applications*, 23(6), 1583-1589. doi: 10.1007/s00521-012-1110-3
12. Ocak, H. (2013). A medical decision support system based on support vector machines and the genetic algorithm for the evaluation of fetal well-being, *Journal of Medical Systems*, 37(9913), 1-9. doi: 10.1007/s10916-012-9913-4
13. Refaeilzadeh, P., Tang, L. ve Liu, H. (2009). Cross-validation. In Liu, L., Ozsu, M. T. (Eds.), *Encyclopedia of Data Base Systems*, 532–538. doi: 10.1007/978-0-387-39940-9\_565
14. Ravindran, S., Jambek, A.B., Muthusamy, H. ve Siew-Chin, N. (2015). A novel clinical decision support system using improved adaptive genetic algorithm for the assessment of fetal well-being, *Computational and Mathematical Methods in Medicine*. doi: 10.1155/2015/283532
15. Sundar, C., Chitradevi, M. ve Geetharamani, G. (2012). Classification of cardiotocogram data using neural network based machine learning technique, *International Journal of Computer Applications*. doi: 10.5120/7256-0279
16. Sundar, C., Chitradevi, M. ve Geetharamani, G. (2013). An overview of research challenges for classification of cardiotocogram data, *Journal of Computer Science*. doi: 10.3844/jcssp.2013.198.206
17. Suykens, J.A.K. ve Vandewalle, J. (1999). Least squares support vector machine classifiers, *Neural Processing Letters*, 9(3), 293–300. doi: 10.1023/A:1018628609742
18. Van der Maaten, L., Postma, E. ve Van den Herik, J. (2009). Dimensionality reduction: a comparative review, *Tilburg University, TiCC TR 2009-005*.
19. Wang, X. ve Paliwal K.K. (2003). Feature extraction and dimensionality reduction algorithms and their applications in vowel recognition, *Pattern Recognition*, 36(2003), 2429-2439. doi: 10.1016/S0031-3203(03)00044-X
20. Yılmaz, E. ve Kılıkçier, Ç. (2013). Determination of fetal state from cardiotocogram using LS-SVM with particle swarm optimization and binary decision tree, *Computational and Mathematical Methods in Medicine*. doi: 10.1155/2013/487179
21. Yılmaz, E. (2013). An expert system based on Fisher score and LSSVM for cardiac arrhythmia diagnosis, *Computational and Mathematical Methods in Medicine*. doi: 10.1155/2013/849674