



Compression of ECG data by support vector regression method

Ömer Karal*

Department of Electrical and Electronics Engineering, Ankara Yildirim Beyazit University, Ankara, 06010, Turkey

Highlights:

- Compression of ECG data with a new SVR-based technique
- Characteristics and benefits of SVR
- Comparing the performance of the SVR technique to commonly used transform-based techniques such as DWT, DCT, and FT for compressing ECG data

Keywords:

- Data compression,
- Electrocardiogram,
- Modeling,
- Support vector regression

Article Info:

Received: 04.10.2017
Accepted: 23.01.2018

DOI:

10.17341/gazimmfd.416527

Acknowledgement:

Correspondence:

Author: Ömer Karal
e-mail: karal@ybu.edu.tr
phone:
+90-312 906 22 54

Graphical/Tabular Abstract

This study presents a new lossy method for ECG data compression based on the Support Vector Regression (SVR) technique. The SVR, a transform based method, allows the ECG data to be compressed in an optimal manner, since the accuracy is based on a provable algorithm. In transform based methods, it is very important to determine the number, shape, and location of the nonlinear basis functions that provide the transformation. The proposed method automatically determines the number, shape and location of these nonlinear basis functions, both optimally and quickly, due to the SVR optimization algorithm. Computer simulation results demonstrate the validity and feasibility of the proposed technique.

Model parameters	η	RMSE	PRD	CR	Model	RMSE	PRD	CR
$\varepsilon=0,01$	0,99	0,007	5,55	4,00	SVR	0,021	17,30	6,38
$\varepsilon=0,02$	0,93	0,012	11,06	5,23	DWT	0,025	20,75	6,34
$\varepsilon=0,03$	0,87	0,021	17,3	6,38	DCT	0,024	19,83	6,38
$\varepsilon=0,04$	0,81	0,029	23,38	6,70	FT	0,032	26,21	6,38
$\varepsilon=0,05$	0,77	0,036	29,06	7,44				

Purpose:

Electrocardiogram (ECG) signals must be continuously recorded and monitored to effectively detect diseases caused by fast or slow heartbeat, that is, rhythm disorders. However, long monitoring periods generates large amount of data that are difficult to store and transmit. Moreover, these records may be subject to noise due to the environment. For this reason, an effective and reliable data compression technique is needed for ECG data compression without losing the clinical information content. In order to address the aforementioned problems, in this paper, SVR based compression algorithm is introduced.

Theory and Methods:

SVR provides a better generalization capability because it tries to minimize both the empirical risk minimization and the structural risk minimization principle. Therefore, SVR has been widely used in many scientific areas. The success of SVR in application is dependent on the ε -insensitive Laplace (Vapnik) loss function that ignores the errors lower than the user-defined ε value. Small noisy training samples falling into the ε -insensitive zone are not included in the solution representation. So, SVR yields a sparse (compressed) model in the obtained solution. The compressed signal is expressed as the weighted sum of basis functions. Different from the other transformation-based compression methods, the number, position, and shape of these functions are automatically determined by the SVR algorithm based on the solution of the quadratic optimization problem.

Results:

From the experimental results, the user defined ε parameter allows us to check the selection of the samples (support vectors) related to the direct compression. If the value of the ε parameter increases, the Compression Ratio (CR) also increases, and at the same time increases the Percent Root Mean Square Difference (PRD) and Root Mean Square Error (RMSE) values, which leads to distortions in the compressed signal. Also, when the value of ε increases, the SVR algorithm also increases in generalization ability (lowers η).

Conclusion:

Computer simulation results show that the performance of the proposed SVR-based compression algorithm is better than other transformation-based compression techniques such as the commonly used Fourier Transform (FT), Discrete Cosine Transform (DCT), and Discrete Wavelet Transform (DWT). As can be seen from the table, at the same compression ratio (SO = 6.38), the SVR technique reached minimum PRD = 17.30 and RMSE = 0.021. In addition, the proposed method has important features such as being independent of the sampling conditions, being a single minimum in the global sense, and not requiring additional algorithms (preprocessing of the ECG signal). As a result, SVR based compression algorithm is an attractive candidate for compressing ECG signals.



EKG verilerinin destek vektör regresyon yöntemiyle sıkıştırılması

Ömer Karal*^{ID}

Ankara Yıldırım Beyazıt Üniversitesi, Mühendislik ve Doğa Bilimleri Fakültesi, Elektrik-Elektronik Mühendisliği Bölümü, Ankara, 06010, Türkiye

Ö N E Ç I K A N L A R

- DVR tabanlı yeni bir teknikle EKG verilerinin sıkıştırılması
- DVR tekniğinin özellikleri ve faydaları
- DVR tekniğinin performansının, EKG verilerinin sıkıştırılmasında yaygın olarak kullanılan DTD, AKD ve FTD gibi dönüşüm tabanlı tekniklerle karşılaştırılması

Makale Bilgileri

Geliş: 04.10.2017

Kabul: 23.01.2018

DOI:

10.17341/gazimmfd.416527

Anahtar Kelimeler:

Veri sıkıştırma,
Elektrokardiyogram,
Modelleme,
Destek vektör regresyon

ÖZET

Kalbin hızlı ya da yavaş çalışması sonucu ortaya çıkan hastalıkların, yani ritim bozukluklarının etkin bir şekilde saptanabilmesi için Elektrokardiyogram (EKG) verileri sürekli olarak kaydedilmeli ve izlenmelidir. Ancak, uzun izleme dönemleri, depolanması ve iletimi zor olan büyük miktarda veri üretir. Dahası, bu kayıtlar çevre nedeniyle gürültüye maruz kalabilir. Bu nedenle, gürültülü ortamlarda bile etkili sonuçlar verebilen EKG veri sıkıştırma algoritmalarına ihtiyaç vardır. Bu çalışma, Destek Vektör Regresyon (DVR) tekniğine dayanan, EKG veri sıkıştırması için yeni, kayıplı bir yöntem sunmaktadır. Dönüşüm tabanlı yöntem olan DVR, doğruluğu kanıtlanabilir bir algoritmaya dayandığı için, EKG verilerinin optimal biçimde sıkıştırılabilmesine imkan verir. Dönüşüm tabanlı yöntemlerde, dönüşümü sağlayan ve doğrusal olmayan taban fonksiyonlarının sayısını, şeklini ve yerini belirlemek çok önemlidir. Önerilen yöntem, DVR'nin optimizasyon algoritması sayesinde söz konusu taban fonksiyonlarının sayısını, şeklini ve yerini hem en uygun hem de hızlı bir şekilde otomatik olarak belirler. Bilgisayar simülasyon sonuçları, önerilen tekniğin geçerliliğini ve uygulanabilirliğini göstermektedir.

Compression of ECG data by support vector regression method

H I G H L I G H T S

- Compression of ECG data with a new SVR-based technique
- Characteristics and benefits of SVR
- Comparing the performance of the SVR technique to commonly used transform-based techniques such as DWT, DCT, and FT for compressing ECG data

Article Info

Received: 04.10.2017

Accepted: 23.01.2018

DOI:

10.17341/gazimmfd.416527

Keywords:

Data compression,
Electrocardiogram,
Modeling,
Support vector regression

ABSTRACT

Electrocardiogram (ECG) signals must be continuously recorded and monitored to effectively detect diseases caused by fast or slow heartbeat, that is, rhythm disorders. However, long monitoring periods generates large amount of data that are difficult to store and transmit. Moreover, these records may be subject to noise due to the environment. For this reason, there is a need for an ECG data compression algorithms that can produce effective results even in noisy environments. This study presents a new lossy method for ECG data compression based on the Support Vector Regression (SVR) technique. The SVR, a transform based method, allows the ECG data to be compressed in an optimal manner, since the accuracy is based on a provable algorithm. In transform based methods, it is very important to determine the number, shape, and location of the nonlinear basis functions that provide the transformation. The proposed method automatically determines the number, shape and location of these nonlinear basis functions, both optimally and quickly, thanks to the SVR optimization algorithm. Computer simulation results demonstrate the validity and feasibility of the proposed technique.

1. GİRİŞ (INTRODUCTION)

Elektrokardiyogram (EKG), kalbin kulakçık ve karıncıklarının kasılma ve gevşeme evreleri sırasında ortaya çıkan elektriksel aktivitenin grafiksel gösterimidir. EKG pratik ve dokulara zarar vermeyen (noninvaziv) bir teknik olduğu için kalbin çalışma fonksiyonunun değerlendirilmesinde ilk başvuru olan önemli yöntemlerden biridir. Kalbin hızlı ya da yavaş çalışması sonucu ortaya çıkan hastalıklar, yani ritim ve iletim bozuklukları, EKG ile belirlenebilir. Söz konusu ritim ya da iletim bozukluğu kalpte çok hızlı veya çok yavaş atımlar veya anlık duraklamalar şeklinde olabilir. Çok kısa sürebilen ve zaman zaman gerçekleşen bu durumlar muayene sırasında çekilen EKG'den çoğu zaman saptanamaz. Çünkü muayene sırasında çekilen EKG, kalp atımlarının ve ritminin yaklaşık 10-15 saniyelik bir kısmını gösterir. Bu nedenle ara ara ortaya çıkan bu ritim bozukluklarının saptanması için, EKG sinyallerinin sürekli (24 saat veya daha uzun) kaydedilip elektronik ortamda hızlı bir şekilde hekime iletilmesi gerekir. Ancak bu durum, oldukça yüksek miktarda depolama (hafıza) birimini gerektirir. Dahası, elde edilen kayıtlar, kayıt ve iletim ortamından kaynaklanabilecek gürültülere maruz kalabilir. Bu problemler, EKG verilerinin etkin bir şekilde sıkıştırılmasıyla (önemli bilgileri korunarak) giderilebilir. EKG verilerinin sıkıştırılması, modellenmesi ve yeniden oluşturulması için literatürde birçok teknik önerilmiştir. Mevcut teknikler üç ana kategoriye ayrılabilir [1]: 1) doğrudan veri sıkıştırma teknikleri, 2) öznitelik (parametre) çıkarım tabanlı sıkıştırma teknikleri ve 3) dönüşüm (transform) tabanlı sıkıştırma teknikleri.

Daha yüksek sıkıştırma oranlarına sahip olmaları ve gürültüye karşı daha duyarsız olmalarından dolayı dönüşüm tabanlı yöntemler genellikle daha çok tercih edilirler. Dönüşüm tabanlı tekniklerde, sinyal, taban fonksiyonlarının ağırlıklı bir toplamı olarak temsil edilir. Ağırlık (katsayı) ve genişlik (varyans) gibi taban fonksiyonlarının parametreleri, özgün veriler yerine, kodlanır, saklanır ve iletilir. Bu nedenle, en iyi dönüşüm tekniği, verilen hata ölçütünün sınırları içinde giriş sinyalini yeniden elde etmek için minimum sayıda taban fonksiyonu gerektiren dönüşümdür. Dönüşüm tabanlı teknikler arasında Karhunen-Loeve Dönüşümü (KLD) [2] ortalama karesel hata ölçütüne göre en az sayıda taban fonksiyonu gerektirdiğinden en uygun dönüşümdür. Ancak, yüksek bir sıkıştırma oranı sağlamasına rağmen, KLD taban fonksiyonlarını hesaplamak için gereken hesaplama süresi çok uzundur. Bundan dolayı, en uygun olmayan ancak mümkün olduğunca en uyguna yakın sonuçlar veren dönüşüm tabanlı teknikler, daha çok kullanım alanı bulmuştur. Reddy ve Murthy [3], EKG verilerini sıkıştırmak için Fourier Tabanlı Dönüşüm (FTD) tekniğini kullanmıştır. Ancak, FTD tekniği zaman içindeki frekans bilgisinin yerini tam belirleme konusunda başarısızdır [4]. Benzid vd. [5], Ayrık Kosinüs Dönüşüm (AKD) tekniğini EKG verilerini sıkıştırmak için kullanmıştır. Shinde ve

Kanjalkar [6], EKG verilerinin sıkıştırılması için FTD, AKD ve Dalgacık Tabanlı Dönüşüm (DTD) tekniklerinin karşılaştırılmalı bir çalışmasını gerçekleştirmiştir. Bu çalışmada, DTD sıkıştırma algoritmasının FTD ve AKD sıkıştırma algoritmalarından daha iyi performans sağladığı gösterilmiştir. Son yıllarda, zaman frekans lokalizasyonu, enerji sıkıştırması, gürültüye karşı duyarsızlığı ve çapraz-alt bant benzerliği gibi özellikleri nedeniyle, DTD teknikleri, öznitelik çıkarımı [7], gürültü giderme [8], örüntü tanıma [9], veri sıkıştırma [10] gibi birçok alanda kullanılmıştır. Addison [11], DTD tekniğinin sürekli ve ayrık zamanda ayrıntılı analizini yapmış ve ayrık DTD'nin geleneksel sinyal filtreleme ve kodlama yöntemleri ile uyuşan ilgi çekici bir matematiğe sahip olduğunu vurgulamıştır. Ayrıca, yine aynı çalışmada, ayrık DTD'nin daha az sayıda dalgacık katsayısı üretmesinden dolayı sürekli DTD'den daha kısa bir hesaplama zamanına ihtiyaç duyduğu gösterilmiştir. Ancak, DTD tekniğinin performansı, ana dalgacık, dalgacık filtrelerinin uzunluğu, ayrışma seviyelerinin sayısı gibi ölçütlere bağlıdır. DTD performansını arttırmak için, son yıllarda, dalgacık katsayılarının daha az sayıda bit ile kodlanması üzerine çalışmalar yapılmıştır. Mevcut dalgacık katsayılarını kodlama teknikleri kendi aralarında (i) eşik tabanlı yöntemler [12, 13], (ii) gömülü kodlama tabanlı yöntemler [14, 15], (iii) vektör-nicemleme tabanlı yöntemler [16, 17] ve (iv) doğrusal tahmin tabanlı yöntemler [18, 19] olmak üzere dört kategoriye ayrılabilir.

DTD tekniklerinde blok boyutu ile sıkıştırma oranı arasında orantısız bir ilişki vardır. Blok boyutunun artırılması belirli bir bozulma için sıkıştırma oranını artırır; ancak uyarlanabilir (adaptif) dalgacık kodlama şemalarının hesaplanma zamanı ve hafıza (bellek) gereksinimleri de aynı oranda artacaktır. Bu nedenlerden dolayı, dalgacık dönüşümü ile EKG veri sıkıştırmasında blok boyutuna nasıl karar verileceği konusu hala temel bir sorundur. Yukarıda bahsi geçen yöntemlerin amaç fonksiyonları, içbükey (konkav) yapıda oldukları için, çok sayıda yerel minimum nokta içerir. Bundan dolayı, amaç fonksiyonunun herhangi bir yerel minimuma takılmaması (global olarak en iyi şekilde çözüme yaklaşmak) için farklı başlangıç koşulları altında defalarca çalıştırılması gerekir. Bu durum hesaplama zamanı açısından oldukça maliyetlidir. Bu yüzden, çoğu EKG sıkıştırma tekniklerinde, genellikle, hesaplama sürelerine değinmez. Bu çalışmanın amacı, yukarıda belirtilen kısıtlamaların üstesinden gelmek için, mevcut dönüşüm tabanlı sıkıştırma tekniklerinden farklı olarak, destek vektör regresyon (DVR) tabanlı yeni bir dönüşüm yöntemi ile EKG verilerinin verilen hata toleransına göre en uygun bir şekilde sıkıştırabileceğini göstermektir. Dönüşüm tabanlı ve kayıplı bir teknik olan DVR, doğruluğu kanıtlanabilir bir algoritmaya (ikinci dereceden bir bilinmeyenli denklemin çözümüne) dayandığı için, kullanıcı tanımlı parametrelerinin değerine bağlı olarak, hemen hemen her türlü veriyi en uygun bir biçimde sıkıştırılabilir. DVR, sadece deneysel ölçüm hatasını değil, aynı zamanda genelleme hatasının üst sınırını da azaltmayı amaçlar. DVR tasarımı, genellikle bir

hata fonksiyonu ile modeli temsil eden katsayıların en aza indirgenmesine dayanır [20]. Giriş uzayında tanımlanan DVR'nin amaç fonksiyonu, Lagrange çarpanları ve taban fonksiyonları cinsinden daha yüksek boyutlu uzaya taşınarak dışbükey (konveks) optimizasyon problemi bina edilir. Yüksek boyutlu uzayda, dönüşümü sağlayan taban fonksiyonlarının iç çarpımı bir çekirdek (kernel) üretir. Gauss fonksiyonu, DVR'de en çok tercih edilen çekirdek fonksiyonlarından birisidir. EKG gibi düzgün bir yapıya sahip olmayan sinyallerin modellenmesinde, taban fonksiyonlarının sayısını, şeklini ve yerini belirlemek çok önemlidir. Önerilen DVR yöntemi, söz konusu taban fonksiyonlarının sayısını, şeklini ve yerini, giriş örneklerine uygulanan dönüşüm sonrası elde edilen çekirdek tabanlı optimizasyon probleminde, ikinci dereceden (kuadratik) amaç fonksiyonunu en aza indirgeyerek, sadece en uygun değil aynı zamanda (özellikle ardışık minimal optimizasyon algoritması ile) hızlı bir şekilde otomatik olarak belirler. EKG verilerinde, destek vektör yaklaşımının kullanımına ilişkin yapılan literatür taramasında dikkat çeken husus, yapılan çalışmaların neredeyse tamamında, destek vektör yaklaşımının sınıflandırma amacıyla kullanılmış olmasıdır. Osowski vd. [21] tarafından yapılan çalışmada kalp atışlarının normal (sağlıklı) sinüs ritmine veya uygun aritmi sınıfına ait olup olmadığına karar verebilmek için destek vektör makinesi (DVM) kullanılmıştır. Szilágyi vd. [22] tarafından yapılan çalışmada, filtrelenmiş gürültüsüz EKG sinyalinin temel özellikleri DVM tarafından üretilen üstel parametrelerle belirlenmiştir. Acır [23] tarafından yapılan çalışmada, girdi boyutunun azaltılması için sarsım (pertürbasyon) yöntemi kullanılmış ve ardından DVM ile kalp atışlarının normal ritimde olup olmadığına doğruluğu gösterilmiştir. Mehta ve Lingayat [24] tarafından yapılan çalışmada, EKG sinyalinde QRS ve QRS olmayan bölgelerin tanımlanması için sınıflandırıcı olarak DVM kullanılmıştır. Zidelmal vd. [25] tarafından yapılan çalışmada da, kalp atışlarının sınıflandırılması için gömülü ret seçeneği alan DVM modeli kullanılmıştır. Destek vektör yaklaşımının regresyon modeli olan DVR tekniği ile EKG verilerinin sıkıştırılması üzerine yapılan literatür taramasında, bilimsel bir çalışmaya rastlanmamıştır. Ancak, yakın geçmişte, DVR tekniği, biyomedikal [26, 27], yenilenebilir enerji [28, 29] ve uzaktan algılama [30, 31] gibi pek çok mühendislik alanına uygulanmıştır. DVR'nin uygulamadaki başarısı, gözlemlenen veride gürültüye karşı gürbüzlük sağlayan kayıp (loss) fonksiyonundan kaynaklanmaktadır. DVR'nin yalın haldeki formülünde, epsilon (ϵ) duyarsız Laplace (Vapnik) kayıp fonksiyonu kullanılır. Vapnik kayıp fonksiyonu, önceden belirlenen, ϵ değerinden daha az olan hataları (gürültüleri) önemsemez. Kayıp fonksiyonunda ϵ duyarsız bölgeye giren küçük gürültülü eğitim örnekleri çözüm sunumunda yer almadığından, DVR tekniği destek vektör cinsinden seyrek (sıkıştırılmış) bir model üretir. ϵ parametresi seyreklik ile doğrudan ilişkili olabilecek destek vektörlerinin seçimini kontrol etmemizi sağlar. Çalışmanın geri kalan kısmı aşağıdaki gibi düzenlenmiştir. Bölüm 2'de destek vektör regresyon yöntemi genel hatları ile ayrıntılı bir şekilde tanıtılmıştır. Bölüm 3'de EKG verilerinin DVR ile sıkıştırılması sonucu elde edilen deneysel sonuçlar

gösterilmiştir. Bölüm 4'de DVR tekniğinin performansı literatürde yaygın olarak kullanılan DTD, AKD ve FTD gibi diğer dönüşüm tabanlı tekniklerle karşılaştırılması yapılmıştır. Son bölümde ise uygulamalardan elde edilen sonuçlara ilişkin değerlendirmeler yapılmıştır.


2. DESTEK VEKTÖR REGRESYON (SUPPORT VECTOR REGRESSION)

Evsensel ileri beslemeli ağların bir çeşidi olan Destek vektör ağları, verileri sınıflandırmak için, AT&T Bell laboratuvarlarında Vapnik ve Cortes [32] tarafından geliştirilmiştir ve literatürde genellikle destek vektör makineleri (DVM) olarak anılmaktadır. DVM tabanlı model, regresyon için DVR olarak adlandırılır [33]. DVR, sinir ağlarının geleneksel denetimli öğrenme yöntemleri ile karşılaştırıldığında, sadece deneysel ölçüm hatasını (empirical risk minimization) değil, aynı zamanda genelleme hatasının üst sınırını da azaltmayı amaçlayan yapısal riski minimuma indirme (structural risk minimization) ilkesini de kullanır. Bu ilke sayesinde, DVR, eğitim aşamasında öğrenilen giriş-çıkış ilişkisini kullanarak, daha önce öğrenilmemiş test verileri için iyi genelleme performansı sergilemektedir. Sürekli değerli bir fonksiyona yaklaşım problemi için $\mathbf{x}_s \in \mathbb{R}^n$ girdi vektörünü, $y_s \in \mathbb{R}$ çıktı (hedef) değerini belirtecek şekilde N sayıda örnekten oluşan bir veri seti $D = \{(\mathbf{x}_s, y_s) \mid s \in \{1, 2, \dots, N\}\}$ verilmiş olsun. Regresyon analizinin amacı istenen (hedef) çıktıları ($y_s \in \mathbb{R}$) doğru bir şekilde tahmin edebilmek için matematiksel bir fonksiyon belirlemektir. Regresyon problemi doğrusal ve doğrusal olmayan regresyon problemleri olarak sınıflandırılabilir. Doğrusal olmayan regresyon probleminin çözülmesi daha zor olduğundan, DVR esas olarak doğrusal olmayan regresyon sorununun çözümü için geliştirilmiştir. Doğrusal olmayan regresyon problemini çözmek için DVR, doğrusal olmayan bir fonksiyon yardımıyla $\phi(\cdot): \mathbb{R}^n \rightarrow \mathbb{R}^m$ giriş uzayındaki eğitim verilerini daha yüksek boyutlu uzaya $\{(\phi(\mathbf{x}_s), y_s) \mid s \in \{1, 2, \dots, N\}\}$ taşır ($m > n$) ve bu uzayda doğrusal regresyon uygular. Bu durumda, en iyi regresyonu bulmak için elde edilen doğrusal fonksiyonun matematiksel gösterimi aşağıdaki gibidir (Eş. 1).

$$f(\mathbf{x}, w) = \sum_{s=1}^N w_s \phi(\mathbf{x}_s) + b = w^T \phi(\mathbf{x}) + b \quad (1)$$

Burada, $w \in \mathbb{R}^m$ model parametre vektörünü ve $b \in \mathbb{R}$ düşey eksenindeki sapma terimini temsil eder. Böylece, yüksek boyutlu uzayda w ile $\phi(\mathbf{x})$ arasındaki iç çarpımla elde edilen doğrusal regresyon (Eş. 1), giriş uzayında doğrusal olmayan regresyona karşılık gelir (Şekil 1). DVR'nin yüksek boyutlu uzayda doğrusal regresyonu gerçekleştiren amaç fonksiyonu, genellikle, ϵ -duyarsız kayıp fonksiyonu ve modeli temsil eden parametrelerin en aza indirgenmesinden oluşur (Eş. 2).

$$\min_{w \in \mathbb{R}^m, b \in \mathbb{R}} J(w, b) = \frac{1}{2} \sum_{s=1}^N \|w\|^2 + C \sum_{s=1}^N L_{\epsilon}(y_s, f(\mathbf{x}_s)) \quad (2)$$



Şekil 1. Giriş uzayındaki eğitim örneklerinin doğrusal olmayan fonksiyon yardımıyla $\varphi(\cdot)$ yüksek boyutlu uzayda doğrusal gösterimi (Using the non-linear function $\varphi(\cdot)$ mapping training examples in the input space to a high dimension where they are linear)


Burada, ilk terim $\|w\|^2/2$ model parametrelerinin Öklid normunun karesini, ikinci terim $L_\varepsilon(y_s, f(x_s))$ deneysel hata (kayıp) fonksiyonunu ve son olarak $C \in \mathbb{R}^+$ ise pozitif sabit bir sayıyı ifade eder. C 'nin görevi deneysel hata ile modelin eğitim verisine aşırı uyumu arasında dengeyi sağlamaktır. Küçük C değerleri, optimizasyon probleminde, deneysel hatanın aksine model parametresi w 'nın normunu daha fazla küçültmeye (genelleme yeteneğine) daha çok önem verirken, yüksek C değerleri ise w 'nın normunun aksine deneysel eğitim hatasını daha fazla küçültmeye önem verir.

Kayıp fonksiyonu $L_\varepsilon(y_s, f(x_s))$ ile gürültü dağılım modelleri arasında iyi bilinen bir ilişki mevcuttur. Eğer gürültü dağılımı biliniyorsa optimal kayıp fonksiyonu maksimum olabilirlik anlamında elde edilebilir [34]. Literatürde, DVR'de kullanılan bazı konveks kayıp fonksiyonları Tablo 1'de verilmiştir. Klasik DVR, amaç fonksiyonunda (Eş. 2) genellikle Vapnik'in önerdiği epsilon (ε) - duyarlı Laplace kayıp fonksiyonunu kullanılır (Eş. 3).

$$L_\varepsilon(y_s, f(x_s)) = \begin{cases} 0 & |y_s - f(x_s)| < \varepsilon \text{ için} \\ |y_s - f(x_s)| - \varepsilon & \text{diğer durumlarda} \end{cases} \quad (3)$$

Vapnik kayıp fonksiyonu, önceden belirlenen, ε değerinden daha az olan hataları önemsemmez (Şekil 2). Kayıp fonksiyonunda ε duyarlı bölgeye giren küçük gürültülü eğitim örnekleri çözüm sunumunda yer almadığından, DVR tekniği destek vektör cinsinden seyrek (sıkıştırılmış) bir model üretir. Sonuç olarak, ε parametresi seyreklik ile doğrudan ilişkili olabilecek destek vektörlerinin seçimini kontrol etmemizi sağlar. Vapnik kayıp fonksiyonunda, epsilon duyarlı bölge dışında kalan pozitif ve negatif sapmalarla ayrı ayrı ilgilenmek için tanımlanan, $\{\xi_s$ ve $\xi'_s \mid s \in \{1, 2, \dots, N\}\}$ pozitif serbest değişkenler yardımıyla Eş. 2'deki DVR optimizasyon problemi aşağıdaki gibi tanımlanabilir.

$$\min_{w \in \mathbb{R}^m, b \in \mathbb{R}} J(w, b, \xi_s, \xi'_s) = \frac{1}{2} \sum_{s=1}^N \|w\|^2 + C \sum_{s=1}^N [\xi_s + \xi'_s] \quad (4)$$



Şekil 2. ε -duyarlı Laplace kayıp fonksiyonu (ε -insensitive Laplace loss function)

$$\text{Kısıtlar} \begin{cases} y_s - w^T \varphi(x) - b \leq \varepsilon + \xi_s \\ -y_s + w^T \varphi(x) + b \leq \varepsilon + \xi'_s \\ \xi_s, \xi'_s \geq 0, \quad s \in \{1, \dots, N\} \end{cases} \quad (5)$$

Eş. 4 ve Eş. 5 ile giriş uzayında tanımlanan kısıtlı ikinci dereceden optimizasyon problemi Lagrange çarpanları yöntemiyle [35] yüksek boyutlu uzaya taşınıp çözülebilir (Eş. 6).

$$\begin{aligned} \min_{\substack{w \in \mathbb{R}^m, b \in \mathbb{R} \\ \alpha_s, \alpha'_s, \gamma_s, \gamma'_s, \xi_s, \xi'_s \geq 0 \\ s \in \{1, \dots, N\}}} J(w, b, \alpha_s, \alpha'_s, \gamma_s, \gamma'_s, \xi_s, \xi'_s) = \\ \frac{1}{2} w^T w + C \sum_{s=1}^N [\xi_s + \xi'_s] \\ - \sum_{s=1}^N \alpha_s (\varepsilon + \xi_s - y_s + w^T \varphi(x) + b) \\ - \sum_{s=1}^N \alpha'_s (\varepsilon + \xi'_s + y_s - w^T \varphi(x) - b) - \sum_{s=1}^N [\gamma_s \xi_s + \gamma'_s \xi'_s] \end{aligned} \quad (6)$$

Burada, α_s, α'_s ve γ_s, γ'_s her bir örnek ile ilişkili pozitif Lagrange çarpanlarıdır. Eş.6'daki optimizasyon problemi, giriş değişkenleri (w, b, ζ_s, ζ'_s) cinsinden minimali, Lagrange çarpanları ($\alpha_s, \alpha'_s, \gamma_s, \gamma'_s$) cinsinden maksimali alınarak çözümlenmelidir. Bundan dolayı, Eş. 6'nın optimal çözümü eyer (saddle) noktaları bulunarak belirlenir. Bunun için, önce Eş. 6'nın giriş değişkenlerine (w, b, ζ_s, ζ'_s) ayrı ayrı kısmi türev uygulanır ve elde edilen sonuçlar sıfıra eşitlenir.

$$\frac{\partial J}{\partial b} = \sum_{s=1}^N (\alpha'_s - \alpha_s) = 0 \quad (7)$$

$$\nabla_w J = w - \sum_{s=1}^N (\alpha_s - \alpha'_s) \varphi(x_s) = 0 \quad (8)$$

$$\frac{\partial J}{\partial \zeta_s} = C - \alpha_s - \gamma_s = 0 \quad (9)$$

$$\frac{\partial J}{\partial \zeta'_s} = C - \alpha'_s - \gamma'_s = 0 \quad (10)$$

Tablo 1. DVR'de kullanılan bazı konveks kayıp fonksiyonları
(Some convex loss functions used in SVR)

Kayıp fonksiyonu	Matematiksel tanımı
Laplace	$L(\zeta_s) = \zeta_s $
ε duyarsız Laplace	$L(\zeta_s) = \begin{cases} 0, & \zeta_s < \varepsilon \text{ için} \\ \zeta_s - \varepsilon, & \text{diğer durumlarda} \end{cases}$
Karesel	$L(\zeta_s) = \frac{1}{2}(\zeta_s)^2$
ε duyarsız Karesel	$L(\zeta_s) = \begin{cases} \frac{1}{2\mu}(\zeta_s)^2, & \zeta_s > \varepsilon \text{ için} \\ 0, & \text{diğer durumlarda} \end{cases}$
Huber	$L(\zeta_s) = \begin{cases} \frac{1}{2\mu}(\zeta_s)^2, & \zeta_s > \varepsilon \text{ için} \\ \zeta_s - \frac{\mu}{2}, & \text{diğer durumlarda} \end{cases}$
ε duyarsız Huber	$L(\zeta_s) = \begin{cases} \frac{1}{2\mu}(\zeta_s)^2, & \zeta_s > \varepsilon \text{ için} \\ \zeta_s _\varepsilon - \frac{\mu}{2}, & \text{diğer durumlarda} \end{cases}$
<i>lncosh</i>	$L(\zeta_s) = \frac{1}{\lambda} \ln(\cosh(\lambda \zeta_s))$
ε duyarsız <i>lncosh</i>	$L(\zeta_s) = \begin{cases} 0, & \zeta_s < \varepsilon \text{ için} \\ \frac{1}{\lambda} \ln(\cosh(\lambda \zeta_s)), & \text{diğer durumlarda} \end{cases}$

Eş. 7'den Eş. 10'a kadar olan eşitlikler, Eş. 6'daki giriş uzayı değişkenleri (w, b, ζ_s, ζ'_s) yerine koyulup gerekli sadeleştirmeler yapılırsa (giriş değişkenleri ortadan kaldırılırsa), sadece Lagrange çarpanları ($\alpha_s, \alpha'_s, \gamma_s, \gamma'_s$)

cinsinden ikinci dereceden bir optimizasyon problemi (Eş. 11) elde edilir.

$$\max_{\alpha \in \mathbb{R}^N} J(\alpha_s, \alpha'_s) = -\frac{1}{2} \sum_{s=1}^N \sum_{s=1}^N (\alpha_s - \alpha'_s) \mathcal{K}(\alpha_s - \alpha'_s) - \varepsilon \sum_{s=1}^N (\alpha_s + \alpha'_s) + \sum_{s=1}^N \gamma_s (\alpha_s - \alpha'_s) \quad (11)$$

$$\text{Kısıtlar : } \sum_{s=0}^N (\alpha'_s - \alpha_s) = 0 \text{ ve } \alpha_s, \alpha'_s \in [0, C] \quad (12)$$

γ_s ve γ'_s Lagrange çarpanları Eş. 11 elde edilirken Eş. 9 ve Eş. 10 ile giderilmiştir. Burada, K kernel fonksiyonlarından elde edilen kernel matrisini ifade eder ve Mercer koşullarını sağlaması gerekir [32]. Kernel fonksiyonları ($[\mathcal{K}(x_s, x_r)]_{s,r}$), giriş uzayından doğrusal olmayan fonksiyonlar $\varphi(\cdot)$, yardımıyla yüksek boyutlu uzaya taşınan eğitim örneklerinin iç çarpımı $[\varphi^T(x_s) \cdot \varphi(x_r)]_{s,r}$ olarak tanımlanır (Eş. 13).

$$\mathbf{K} = [\mathcal{K}(x_s, x_r)]_{s,r} = [\varphi^T(x_s) \times \varphi(x_r)]_{s,r} = \begin{bmatrix} \mathcal{K}(x_1, x_1) & \mathcal{K}(x_1, x_2) & \cdots & \mathcal{K}(x_1, x_N) \\ \mathcal{K}(x_2, x_1) & \mathcal{K}(x_2, x_2) & \cdots & \mathcal{K}(x_2, x_N) \\ \vdots & \vdots & \ddots & \vdots \\ \mathcal{K}(x_N, x_1) & \mathcal{K}(x_N, x_2) & \cdots & \mathcal{K}(x_N, x_N) \end{bmatrix} \quad (13)$$

Eş. 11, Eş. 12 kısıtları altında çözümlerse, Eş. 8 (model parametresi w) destek vektörleri (Lagrange çarpanları) cinsinden optimal olarak (Eş. 11 ikinci dereceden bir bilinmeyenli bir problem olduğu için minimumu tektir) aşağıdaki gibi (Eş. 14) elde edilir.

$$w = \sum_{s=1}^N (\alpha_s - \alpha'_s) \varphi(x_s) \quad (14)$$

ve x test örneği için Eş. 1'deki karar verme fonksiyonu (destek vektör regresyonu) aşağıdaki gibi (Eş. 15) yazılabilir.

$$f(x) = \sum_{x_s \in DV} (\alpha_s - \alpha'_s) \mathcal{K}(x_s, x_r) + b \quad (15)$$

Burada, DV sıfırdan farklı eğitim örneklerini (destek vektörleri) göstermektedir. Diğer bir deyişle, DV optimizasyon sonucu elde edilen çözüm gösteriminde ε duyarsız alan dışında kalan örnekleri temsil etmektedir. Dikkat edilecek olursa, destek vektör regresyon yaklaşımında, regresyon probleminin karmaşıklığı giriş uzayının boyutundan bağımsızdır ve sadece destek vektör sayısına bağlıdır. Dahası, herhangi bir test örneği için, karar verme fonksiyonu ile değerlendirme yaparken, w 'nın açık bir şekilde hesaplanmasına da gerek yoktur. Eş. 15'den de görüleceği gibi, eğitim örneklerini doğrusal olmayan fonksiyonlar yardımıyla giriş uzayından yüksek boyutlu uzaya taşıma işlemini yapmadan, DVR için gerekli işlemler çekirdek fonksiyonu ($[\mathcal{K}(x_s, x_r)]_{s,r}$) ile doğrudan giriş

uzayında yapılabilir. Buna literatürde “kernel trick” denir [36] ve optimizasyon probleminin çözülebilmesi için gerekli hesaplama zamanını oldukça azaltır. Ancak burada dikkat edilmesi gereken husus, çekirdek olarak kullanılacak fonksiyonların mutlaka Mercer şartlarını sağlaması gerekir. Bu şartlar için aşağıdaki özelliklere bakılır:

- Her (x_s, x_r) çifti için $K(x_s, x_r) \geq 0$ olmalı (pozitif yarı kesinlik)
- Her (x_s, x_r) çifti için $K(x_s, x_r) = K(x_r, x_s)$ olmalı (simetri)
- $K(x_s, x_r)$ sürekli fonksiyon olmalı (süreklilik)

Literatürde DVR’de yaygın olarak kullanılan çekirdek fonksiyonlarından bazıları Tablo 2’de verilmiştir. $u \rightarrow \infty$ giderken çekirdek fonksiyonu $K(u) \rightarrow 0$ ’a gidiyorsa, bu tür çekirdek fonksiyonlarına azalan çekirdek fonksiyonları denir ve parametresinin $(u) \pm \infty$ aralığındaki değerleri için sınırlıdır. DVR uygulamalarının çoğunda, monoton olarak artmayan bir fonksiyon olması ve tek parametre (varyans) ile ayarlanabilen uzaklık ölçütüne sahip olmasından dolayı Gauss çekirdek tercih edilmektedir. Eş. 15’de diğer model parametresi b Karush-Kuhn-Tucker (KKT) koşullarından [37] faydalanarak hesaplanır. KKT şartlarına göre optimal çözümde Lagrange çarpanları ile kısıtlar arasındaki çarpımın sıfır olması gerekir (Eş. 16 ve Eş. 17).

$$\begin{aligned} \alpha_s (\varepsilon + \xi_s - y_s + w^T \varphi(x) + b) &= 0 \\ \alpha'_s (\varepsilon + \xi'_s + y_s - w^T \varphi(x) - b) &= 0 \end{aligned} \quad (16)$$

ve

$$\begin{aligned} (C - \alpha_s) \xi_s &= 0 \\ (C - \alpha'_s) \xi'_s &= 0 \end{aligned} \quad (17)$$

Tablo 2. DVR’de kullanılan bazı çekirdek fonksiyonları (Some kernel functions used in SVR)

Kernel türü	Matematiksel gösterimi
Polinom	$K(x_s, x) = [x^T x_s + c]^p, c \geq 0, p > 1$
Gauss	$K(x_s, x) = \exp(-\ x - x_s\ _2^2 / 2\sigma^2), \sigma > 0$
Sigmoid	$K(x_s, x) = \tanh[px^T x_s + c], p > 0, q < 0$
Fourier	$K(x_s, x) = \frac{1 - p^2}{2(1 - 2p \cos(x_s - x))} + p^2, p > 0$
B_n -spline	$K(x_s, x) = B_n[x - (x_s)^2], n = 2p + 1$ and $n \geq 1$

KKT koşulları, destek vektör yaklaşımında, aşağıda belirtilen oldukça faydalı sonuçları ortaya çıkarır:

- Sadece $\alpha_s = C$ ve $\alpha'_s = C$ ’ye karşılık gelen eğitim örnekleri karar verme fonksiyonunun ε duyarsız bölgesi dışında kalır.
- $\alpha_s \alpha'_s = 0$ ’dır. Yani, her iki yönde de sıfır olmayan serbest değişken (ξ_s, ξ'_s) gerektireceği için ikili Lagrange çarpanlarının $(\alpha_s$ ve $\alpha'_s)$ ikisinin de aynı anda sıfırdan farklı olduğu bir küme olamaz.

- $\alpha_s, \alpha'_s \in (0, C)$ için $\xi_s = 0$ ve $\xi'_s = 0$ ’dır. Bundan dolayı Eş. 17 ortadan kalkar.

Yukarıda sözü edilen sonuçlardan, model parametresi b aşağıdaki (Eş. 18) gibi hesaplanabilir.

$$\begin{aligned} b &= y_s - w^T \varphi(x) - \varepsilon \text{ for } \alpha_s \in (0, C) \\ b &= y_s - w^T \varphi(x) + \varepsilon \text{ for } \alpha'_s \in (0, C) \end{aligned} \quad (18)$$

Eş. 16’ya göre sadece $|f(x_s) - y_s| \geq \varepsilon$ ifadesini sağlayan Lagrange çarpanları $(\alpha_s$ ve $\alpha'_s)$ sıfırdan farklı olabilir. Diğer bir ifadeyle, KKT koşullarının yerine getirilmesi için ε duyarsız bölge içerisinde kalan eğitim örnekleri, $|f(x_s) - y_s| < \varepsilon$, için α_s ve α'_s sıfır olur ve bu durumda Eş. 16’daki ikinci terim, $(\varepsilon + \xi_s - y_s + w^T \varphi(x_s) + b) \neq 0$ sıfırdan farklı bir değeri ifade eder. Bundan dolayı, w ’nın eğitim örnekleri x_s ’ler açısından seyrek gösterimi (yani w ’yı tanımlamak için tüm eğitim örneklerine gereksinimin olmaması) ortaya çıkar. w ’yı tanımlamada kullanılan bu eğitim örneklerine (katsayılar) destek vektörleri denir. Böylece, DVR çözümünde elde edilen sinyal daha az örnek (destek vektör) ile temsil edilir ki bu da DVR’nin girişine uygulanan sinyalin sıkıştırılmış olduğu anlamına gelir. Dolayısıyla, ε parametresi seyreklik (sıkıştırma) ile doğrudan ilişkili olabilecek destek vektörlerinin seçimini kontrol etmemizi sağlar. DVR yöntemi ile verilerin sıkıştırılmış modelinin oluşturulması sürecine dair sözde kod aşağıdaki gibi verilebilir.

Başla

1. Sıkıştırılacak veriyi yükle
 2. Kullanıcı tanımlı parametrelerin $(\varepsilon, C, \sigma$ (Gauss çekirdek parametresi)) değerini ata //Farklı çekirdek fonksiyonları için iki parametre değeri atanması gerekebilir (Tablo 2)
 3. Çekirdek fonksiyonunu hesapla (Eş. 13)
 4. Kuadratik optimizasyon problemini optimal alfa ları $(\alpha_s$ ve $\alpha'_s)$ bulmak için çöz (Eş.11 ve Eş. 12)
 5. Epsilon dan büyük alfa değerlerini $(\alpha_s$ ve $\alpha'_s > \varepsilon)$ belirle (Eş. 16 ve Eş. 17) // (sıkıştırma işlemi epsilon dan büyük alfa larla gerçekleşmektedir)
 6. w değerini belirle (Eş. 14)
 7. Bias (b) terimini belirle (Eş. 18)
 8. Sıkıştırılmış veriyi göster (Eş. 15)
- Bitir

3. DESTEK VEKTÖR REGRESYON İLE EKG VERİLERİNİN SIKIŞTIRILMASI VE DENEYSSEL SONUÇLAR (COMPRESSION OF ECG DATA WITH SUPPORT VECTOR REGRESSION AND EXPERIMENTAL RESULTS)

Bu bölüm, EKG verisini sıkıştırmak için önerilen DVR yönteminin geçerliliğini ve uygulanabilirliğini göstermek için çeşitli deneysel sonuçları sunmaktadır. Deneyler, Intel Core I5 işlemci 3,10 GHz, 10 GB RAM ve 64 bit Windows 10 işletim sistemine sahip kişisel bir bilgisayarda kurulu Matlab 2016a ortamında gerçekleştirilmiştir.

Çekirdek fonksiyonu olarak literatürde yaygın olarak kullanılan Gauss fonksiyonu $K(x_s, x_r) = \exp(-\|x - x_s\|^2/2\sigma^2)$ seçilmiştir. DVR tekniğinin kullanıcı tanımlı optimal parametreleri (C^* , σ^*) sırasıyla, $\{0,1, 0,5, 1, 2, 5, 10, 20, 50\}$ ve $\{0,005, 0,006, 0,007, 0,008, 0,009, 0,010, 0,011, 0,012, 0,013, 0,014, 0,015\}$ kümelerinden $C=1$, ve $\sigma=0,012$ olacak şekilde 5 kat çapraz doğrulama tekniği ile belirlenmiştir. DVR yönteminin performansı, özgün sinyal ile yeniden oluşturulan sinyal arasındaki hata ölçütü, yani Yüzde Fark Oranı (YFO) Eş. 19, Ortalama Karesel Hatanın Kökü (OKHK) Eş. 20 ve Sıkıştırma Oranı (SO) Eş. 21 ile verilen ölçütlere göre değerlendirilmiştir.

$$OKHK = \sqrt{\frac{1}{N} \sum_{s=1}^N (y_s - f(x_s))^2} \quad (19)$$


$$OKHK = \sqrt{\frac{\sum_{s=1}^N (y_s - f(x_s))^2}{\sum_{s=1}^N (y_s)^2}} \times 100 \quad (20)$$

$$SO = \frac{\text{Özgün sinyal için gerekli parametre sayısı}}{\text{Sıkıştırılmış sinyal için gerekli parametre sayısı}} \quad (21)$$

Gerçekleştirilen deneylerde MIT-BIH veri tabanından alınan EKG kaydı kullanılmıştır. Bu kaydın örneklenmesi 360Hz frekansta ve her bir örneğin çözünürlüğü ise 12 bittir. Söz konusu kayıt 24 saatlik bir EKG verisi içermektedir. Görsellik amacıyla, veriden normal bir sinüs ritmi (1 periyotluk EKG sinyali) çıkartılmış ve sıkıştırma işlemi bu

sinyal üzerinde gerçekleştirilmiştir (Şekil 3 lacivert sinyal). Şekil 3'ten görüleceği üzere, 1 periyotluk EKG sinyali P, QRS ve T olarak adlandırılan 3dalga biçiminden oluşur. Dalgalar arasındaki mesafeler, dalgaların süresi, dalgaların yükseklikleri, dalgaların şekilleri ve dalgaların düzenli olarak birbirlerini takip ederken meydana gelebilecek ani değişiklikler, kalpte olabilecek yapı değişikliğini veya hastalığı gösterebilir. Önerilen yöntemin gürültüye karşı gürbüz (robust) olduğunu göstermek için, EKG verilerine ortalaması sıfır ($\mu=0$) ve dağılımı (varyansı) $\tau=0,01$ olan Gauss gürültüsü $(1/\sqrt{2\pi})\exp(-(x-\mu)^2/2\tau^2)$ eklenmiştir (Şekil 4 pembe noktalar).

Şekil 4 özgün EKG sinyali (pembe renk) ve DVR tekniği ile ($C=1$, $\sigma=0,012$, $\varepsilon=0,02$ değerleri için) elde edilen deneysel sonuçları (lacivert sinyal) göstermektedir. Şekil 4'den görüleceği gibi, ε duyarsız bölge içinde kalan eğitim örnekleri (219 adet siyah '+'lar) DV optimizasyon algoritması sonucu elde edilen çözüm gösteriminde yer almazlar. Sadece ε duyarsız bölge dışında kalan eğitim örnekleri (49 adet destek vektör, yeşil renkli halkaların içindeki siyah '+'lar) çözüm gösteriminde yer aldığından, DVR yöntemi ile elde edilen sinyal özgün sinyale göre daha seyrek (az sayıda eğitim örneği içermiş) olur. Dolayısıyla özgün EKG sinyali DVR tekniği ile verilen ε değerine göre en uygun şekilde sıkıştırılmış hale gelir. Farklı ε değerleri için, eğitimde kullanılan örnek sayısı (#EÖ) destek vektör sayısı (#DV) düzgünlük parametresi (w), SO, OKHK, YFO ve eğitim süresi (saniye) gibi ayrıntılı analiz sonuçları Tablo 3'te listelenmiştir. Tablo 3'ten görüleceği üzere, seyreklik parametresi ε değeri arttıkça DVR sonucu elde edilen SO değeri de artmaktadır. Ancak, DVR yöntemindeki seyreklik parametresi ε değerinin artışı ile elde edilen sıkıştırılmış EKG sinyalinin özgün sinyale göre daha da bozulduğu (YFO



Şekil 3. Özgün(lacivert) EKG Gauss gürültüsü eklenmiş (açık mor) EKG ve Özgün EKG sinyalini oluşturan P QRS ve T dalga biçimleri (yeşil dikdörtgenler) (Original EKG (dark blue), the Gaussian noise added ECG (dark blue) and the P QRS and T wave forms (green rectangles) that make up the original ECG signal)

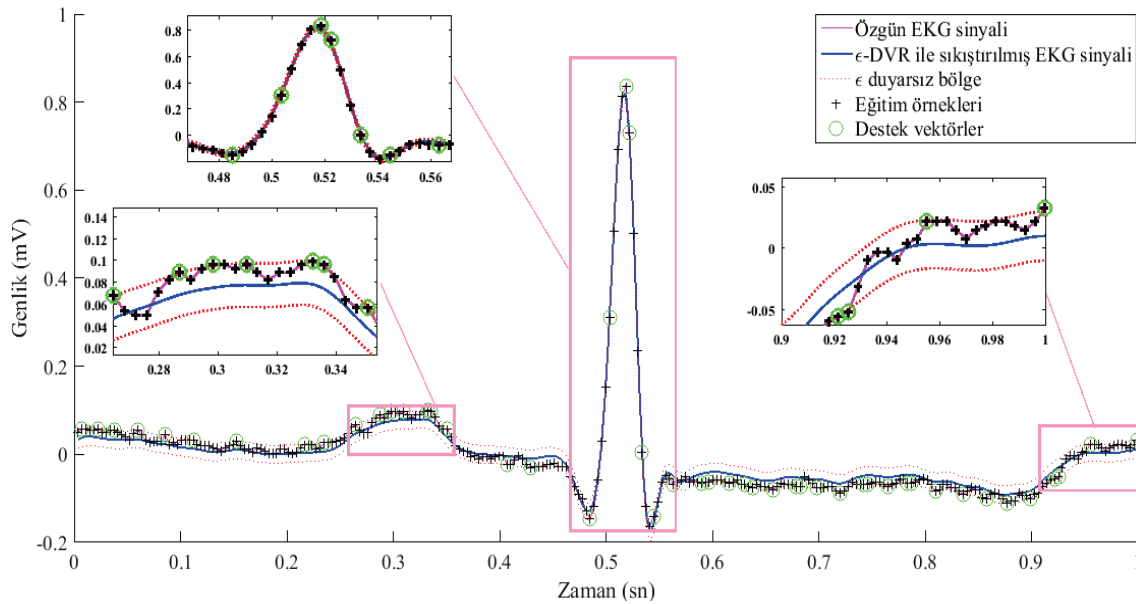
değerinin arttığı) görülmektedir. Bu durum doğal olarak OKHK değerini de artırmaktadır. Yine Tablo 3'den görüleceği üzere, model parametresi w 'nın değeri seyreklik parametresi ε değeri ile ters orantılıdır. Eğer ε değeri artarsa w 'nın değeri azalır ki bu, DVR yönteminin genelleme yeteneğinin artması anlamına gelir. Ancak, ε değerinin çok fazla artırılması, EKG verisini temsil edemeyecek bir model ortaya çıkarabilir. Bu yüzden, DVR yöntemi ile sıkıştırılan EKG verilerinin sıkıştırılması sonucu elde edilecek sinyalin kalitesini, hata tolerans parametresi (ε değeri) ile model parametresi w arasındaki ilişkiyi, konunun uzmanı birkaç hekimle birlikte tespit etmek gerekir.

4. SONUÇLAR VE TARTIŞMALAR (RESULTS AND DISCUSSION)

Bu bölümde, önerilen DVR tekniğinin performansı, literatürde yaygın olarak kullanılan DTD, AKD ve FTD gibi farklı dönüşüm tabanlı tekniklerle karşılaştırılmıştır.

Sıkıştırma oranı aynı olacak (6,38) şekilde, DVR, DTD, AKD ve FTD teknikleri aynı EKG verisini sıkıştırmak için uygulanmış ve elde edilen YFO ve OKHK değerleri Tablo 4'de listelenmiştir. Ayrıca, aynı EKG verisini aynı oranda sıkıştırmak için kullanılan her bir tekniğe ait grafiksel sonuçlar da Şekil 5, Şekil 6, ve Şekil 7'de ayrı ayrı gösterilmiştir.

Şekil 5 özgün EKG sinyalini (pembe renk) ve DTD tekniği (biorthogonal (çift dikgen) dalgacık modeli ve 3.seviye ayrıştırma) ile elde edilen sıkıştırılmış EKG sinyalini (lacivert sinyal) göstermektedir. Farklı dalgacık modelleri (Daubechies ve Symlets) de EKG sinyallerinin sıkıştırılması için denenmiştir. Ancak, yapılan araştırmalarda [38 - 40] ve gerçekleştirilen deneylerde en iyi sonuç biorthogonal 2,8 dalgacık modeli ile elde edilmiştir (Tablo 4'ün üçüncü satır). DTD tekniği iyi bir SO (6,34) ve OKHK (0,023) değeri sağlamasına rağmen, EKG sinyalinin QRS dalgasının R ve S noktalarında bir bozulmaya yol açtığı Tablo 4'ün




Şekil 4. DVR yöntemi ile sıkıştırılmış EKG sinyali (lacivert)
ECG signal compressed by SVR method (dark blue)

Tablo 3. DVR yöntemi ile sıkıştırılan EKG verilerine ilişkin deneysel sonuçlar
(Experimental results on ECG data compressed by SVR method)


Model Param.	#EÖ	#DV	w	Süre(sec.)	OKHK	YFO	SO
$\varepsilon=0,01$		67	0,99	1,8	0,007	5,55	4,00
$\varepsilon=0,02$	C=1 $\sigma=0,012$	49	0,93	1,8	0,012	11,06	5,25
$\varepsilon=0,03$		42	0,87	1,9	0,021	17,3	6,38
$\varepsilon=0,04$		40	0,81	1,9	0,029	23,38	6,70
$\varepsilon=0,05$		36	0,77	1,8	0,036	29,06	7,44

Tablo 4. Önerilen DVR algoritmasının sonuçlarının, DTD, AKD ve FTD sıkıştırma yöntemleriyle karşılaştırılması
(Comparison of the compression results of the proposed SVR algorithm with WBT DCT and FFT methods)

Model	Model Parametreleri	OKHK	YFO	SO
DVR	C=1, $\sigma=0,012$, $\varepsilon=0,03$	0,021	17,30	6,38
DTD	n=3, bior2,8, eşik değeri=0,3	0,025	20,75	6,34
AKD	Katsayıların %2'si sıfıra eşitlenirse	0,024	19,83	6,38
FTD	Katsayıların %3'ü sıfıra eşitlenirse	0,032	26,21	6,38




Şekil 5. DTD yöntemi ile sıkıştırılmış EKG sinyali (lacivert). ECG signal compressed by WBT method (dark blue).



Şekil 6. AKD yöntemi ile sıkıştırılmış EKG sinyali (lacivert). ECG signal compressed by DCT method (dark blue).

üçüncü satırındaki $YFO=20,62$ değerinden ve Şekil 5'den açıkça görülmektedir. Ayrıca, gerçekleştirilen deneylerde, DTD tekniğinin performansının seçilen dalgacık modeline ve ayırma seviyesine oldukça bağlı olduğu görülmüştür. Örneğin ayırma seviyesinin düşürülmesi sıkıştırılan sinyali daha iyi temsil etmesine karşın sıkıştırma oranını da düşürmektedir. Diğer taraftan ayırma seviyesi artırılacak olursa sıkıştırılan sinyalde bozulmalar ve salınımlar meydana gelmektedir. Ayırma seviyeleri artıkça sıkıştırma

oranı da artmakta ancak bu artış sinyali de bozmaktadır. Şekil 6 özgün EKG sinyalini (pembe renk) ve AKD tekniği (AKD katsayılarının enerjinin % 98'ini temsil edecek şekilde seçilerek) ile elde edilen sıkıştırılmış EKG sinyalini (lacivert sinyal) göstermektedir. AKD tekniği ile $SO = 6,38$ ve $OKHK = 0,024$ değerleri elde edilmesine rağmen, EKG sinyalinin şeklinde bir bozulmaya yol açtığı Tablo 4'ün dördüncü satırındaki $YFO=19,83$ değerinden ve Şekil 6'dan açıkça görülmektedir. Ayrıca, AKD tekniği ile sıkıştırılmış sinyal



Şekil 7. FTD yöntemi ile sıkıştırılmış EKG sinyali (lacivert). ECG signal compressed by DCT method (dark blue).

özgün EKG sinyali etrafında oldukça fazla salınım yaptığı ine Şekil 6'dan oldukça net görünmektedir. Bu salınım, enerjinin daha büyük oranlarda (>%98) korunmasını sağlayacak AKD katsayılarının belirlenmesiyle giderilebilir; ancak, bu durum sıkıştırma oranını düşürecektir. Şekil 7 özgün EKG sinyalini (pembe renk) ve FTD tekniği (enerjinin% 97'sini temsil edecek şekilde FTD katsayıların kullanılması) ile elde edilen sıkıştırılmış EKG sinyalini (lacivert sinyal) göstermektedir. 6,38 sıkıştırma oranını FTD tekniği ile elde edebilmek için diğer dönüşüm tabanlı tekniklere göre daha büyük hata (OKHK = 0,032) değeri ürettiği Tablo 4'ün son satırından açıkça görülmektedir. Ayrıca, Şekil 7'den görüleceği üzere, AKD tekniğinde olduğu gibi FTD tekniğinde de, sıkıştırılmış EKG sinyali özgün sinyal etrafında salınım yapmaktadır. Bu durum, Tablo 4'ün son satırındaki yüksek YFO=26,21 değerinden de anlaşılmaktadır. Son olarak, Tablo 4'ün ikinci satırından görüleceği üzere, EKG sinyalinin sıkıştırılmasında aynı sıkıştırma oranını (SO=6,38) elde edebilmek için, önerilen DVR yöntemi, en küçük OKHK=0,021 ve YFO=17,30 değerlerine sahiptir. Buradan, özgün EKG verisini en iyi şekilde temsil edebilmek (YFO değerini en küçük tutabilmek) için, önerilen DVR tekniğinin en az hata ile en yüksek sıkıştırma oranını elde edebildiği anlaşılmaktadır. Bundan dolayı, Tablo 4'deki diğer dönüşüm tabanlı tekniklerin analiz sonuçları göz önüne alındığında, EKG sinyalinin etkin bir şekilde sıkıştırılması ve analizinde, önerilen DVR tekniğinin uygulanabilir çekici bir teknik olduğu söylenebilir.

5. SONUÇLAR (CONCLUSIONS)

Bu çalışmada, EKG verilerini sıkıştırmak için, Destek vektör regresyon (DVR) tabanlı, yeni bir yöntem sunulmuştur.

Yöntemin temel yaklaşımı, EKG verilerini çekirdek (Gauss) fonksiyonu ile yüksek seviyeli özellik uzayına taşımak (dönüştürmek) ve bu uzayda doğrusal olarak modellemektir. DVR algoritmasının amaç fonksiyonu ikinci dereceden bir bilinmeyenli denklemin çözümüne dayandığı için, çekirdek fonksiyonlarının ağırlıkları, sayıları ve yerleri en uygun ve hızlı bir şekilde belirlenir. DVR yönteminin verileri sıkıştırma özelliği, gözlemlenen veride, gürültüye karşı gürbüzlük sağlayan ε -duyarsız kayıp fonksiyonundan kaynaklanmaktadır. Kayıp fonksiyonunda ε duyarsız bölgeye giren küçük gürültülü eğitim örnekleri çözüm sunumunda yer almadığından, DVR tekniği destek vektör cinsinden seyrek (sıkıştırılmış) bir model üretir. Çalışmada, çeşitli ε değerleri için, sıkıştırılmış EKG sinyaline ait sayısal analiz sonuçları detaylı bir şekilde gösterilmiştir. Analiz sonuçlarından, ε değeri arttıkça, SO değerinin arttığı görülmektedir. Ayrıca, önerilen DVR tekniğinin genel performansı, literatürde yaygın olarak kullanılan FTD, AKD ve DTD gibi farklı dönüşüm tabanlı sıkıştırma teknikleriyle karşılaştırılmıştır. Aynı sıkıştırma oranında (SO=6,38), en iyi gösterimi (YFO = 17,30) en az hata (OKHK=0,021) ile önerilen DVR tekniği başarmıştır. Bununla birlikte önerilen yöntem, herhangi bir ek algoritmaya (EKG sinyalini ön işleminden geçirmeye) ihtiyaç duymaması, işaretin örnekleme koşullarından bağımsız olması ve global anlamda tek bir minimuma sahip olması nedeniyle önemli bir üstünlüğe sahiptir.

KAYNAKLAR (REFERENCES)

1. Jalaliddine S.M., Hutchens C.G., Strattan R.D., Coberly W.A., ECG data compression techniques-a unified approach, IEEE Trans. Biomed. Eng., 37 (4), 329-343, 1990.

2. Olmos S., Millan M., Garcia J., Laguna P., ECG data compression with the Karhunen-Loeve transform, *Computers in Cardiology, Indianapolis, ABD*, 253-256, 8-11 Eylül, 1996.
3. Reddy B.S., Murthy I.S.N., ECG data compression using Fourier descriptors, *IEEE Trans. Biomed. Eng.*, (4), 428-434, 1986.
4. Singh B., Kaur A., Singh J., A review of ecg data compression techniques, *International journal of computer applications*, 116 (11), 2015.
5. Benzid R., Messaoudi A., Boussaad A., Constrained ECG compression algorithm using the block-based discrete cosine transform, *Digital Signal Process.*, 18 (1), 56-64, 2008.
6. Shinde A.A., Kanjalkar P., The comparison of different transform based methods for ECG data compression, *Uluslararası konferans, ICSCCN-IEEE, Thuckafay, Hindistan*, 332-335, 21-22 Haziran, 2011.
7. Aydın F., Aslan Z., Diagnosis of neuro degenerative diseases using machine learning methods and wavelet transform, *Journal of the Faculty of Engineering and Architecture of Gazi University*, 32 (3), 749-766, 2017.
8. Üstündağ M., Avcı E., Gökbulut M., Ata F., Denoising of weak radar signals using wavelet packet transform and genetic algorithm, *Journal of the Faculty of Engineering and Architecture of Gazi University*, 29(2), 375-383, 2014.
9. Uyar M., Yıldırım S., Gençoğlu M.T., A pattern recognition approach for classification of power quality disturbance types, *Journal of the Faculty of Engineering and Architecture of Gazi University*, 26 (1), 41-56, 2011
10. Manikandan M.S., Dandapat S., Wavelet-based electrocardiogram signal compression methods and their performances: a prospective review, *Biomed. Signal Process. Control*, 14, 73-107, 2014.
11. Addison P.S., Wavelet transforms and the ECG: a review, *Physiol. Meas.*, 26 (5), R155, 2005.
12. Abo-Zahhad M., Ahmed S.M., Sabor N., Al-Ajlouni A.F., Wavelet Threshold Based ECG Data Compression Technique Using Immune Optimization Algorithm, *IJSIP* 8 (2), 307-360, 2 Şubat, 2015.
13. Swarnkar A., Kumar R., Kumar A., Khanna P., Performance of different threshold function for ECG compression using Slantlet transform, *Uluslararası 4. Sinyal İşleme ve Bütünleşik Ağlar konferansı (SPIN)*, 375-379, 2-3 Şubat, 2017.
14. Ballesteros D.M., Moreno D.M., Gaona A.E., FPGA compression of ECG signals by using modified convolution scheme of the Discrete Wavelet Transform, *Ingeniare, Revista chilena de ingeniería*, 20 (1), 2012.
15. Al-Busaidi A.M., Khriji L., Touati F., Rasid M.F.A., Mnaouer A.B., Real-time DWT-based compression for wearable Electrocardiogram monitoring system, *Uluslararası 8. GCC konferans ve sergisi, (GCCC)*, 1-6, Muscat, Umman, 1-4 Şubat, 2015.
16. Huang B., Wang Y., Chen J., ECG compression using the context modeling arithmetic coding with dynamic learning vector-scalar quantization, *Biomed. Signal Process. Control* 8 (1), 59-65, 2013.
17. Hung K.C., Wu T.C., Lee H.W., Liu T.K., EP-based wavelet coefficient quantization for linear distortion ECG data compression, *Med. Eng. Phys.*, 36 (7), 809-821, 2014.
18. Ramakrishnan A.G., Saha S., ECG coding by wavelet-based linear prediction, *IEEE Trans. Biomed. Eng.*, 44 (12), 1253-1261, 1997.
19. Al-Shrouf A., Abo-Zahhad M., Ahmed S.M., A novel compression algorithm for electrocardiogram signals based on the linear prediction of the wavelet coefficients, *Digital Signal Process.*, 13 (4), 604-622, 2003.
20. Basak D., Pal, S., Patranabis D.C., Support vector regression, *Neural Inf. Process. Lett. Rev.*, 11 (10), 203-224, 2007.
21. Osowski S., Hoai L.T., Markiewicz T., Support vector machine-based expert system for reliable heartbeat recognition, *IEEE trans. Biomed. Eng.*, 51 (4), 582-589, 2004.
22. Szilágyi S.M., Szilágyi L., Benyó Z., Support Vector Machine-Based ECG Compression, In *Analysis and Design of Intelligent Systems using Soft Comput. Tec.*, 737-745, Springer Berlin Heidelberg, 2007.
23. Acir N., A support vector machine classifier algorithm based on a perturbation method and its application to ECG beat recognition systems, *Expert Syst. Appl.*, 31 (1), 150-158, 2006.
24. Mehta S.S., Lingayat N.S., Detection of QRS complexes in electrocardiogram using support vector machine. *J. Med. Eng. Technol.*, 32 (3), 206-215. 2008.
25. Zidelmal Z., Amirou A., Belouchrani A., Heartbeat classification using support vector machines (SVMs) with an embedded reject option, *Int. J. Pattern Recognit Artif Intell.*, 26 (01), 1250001, 2012.
26. Huber M.B., Lancianese S.L., Nagarajan M.B., Ikpot I.Z., Lerner A.L., Wismuller A., Prediction of biomechanical properties of trabecular bone in MR images with geometric features and support vector regression, *IEEE Trans. Biomed. Eng.*, 58 (6), 1820-1826, 2011.
27. Mahmoodian H., Ebrahimian L., Using support vector regression in gene selection and fuzzy rule generation for relapse time prediction of breast cancer, *Biocybern. and Biomed. Eng.*, 36 (3), 466-472, 2016.
28. Ramedani Z., Omid M., Keyhani A., Shamshirband S., Khoshnevisan B., Potential of radial basis function based support vector regression for global solar radiation prediction, *Renewable Sustainable Energy Rev.*, 39, 1005-1011, 2014.
29. Hu Q., Zhang S., Yu M., Xie Z., Short-term wind speed or power forecasting with heteroscedastic support vector regression, *IEEE Trans. Sustainable Energy*, 7 (1), 241-249, 2016.
30. Camps-Valls G., Bruzzone L., Rojo-Álvarez J.L., Melgani F., Robust support vector regression for biophysical variable estimation from remotely sensed images, *IEEE Geosci. Remote Sens. Lett.*, 3 (3), 339-343, 2006.
31. Okujeni A., Van Der Linden S., Tits L., Somers B., Hostert P., Support vector regression and synthetically mixed training data for quantifying urban land cover, *Remote Sens. Environ.*, 137, 184-197, 2013.

32. Cortes C. ve Vapnik V., Support-vector networks, *Mach. Learn.*, 20 (3), 273-297, 1995.
33. Smola A.J., Schölkopf B., A tutorial on support vector regression, *Stat. Comput.*, 14 (3), 199-222, 2004.
34. Karal O., Maximum likelihood optimal and robust support vector regression with Incosh loss function, *Neural Networks*, 94, 1-12, 2017.
35. Fletcher R., *Practical methods of optimization*. John Wiley & Sons, 2013.
36. Schölkopf B., Smola, A.J., *Learning with kernels: support vector machines, regularization, optimization, and beyond*, MIT press, Cambridge, MA, A.B.D., 2002.
37. Bertsekas D.P., *Nonlinear programming*, Belmont: Athena scientific., 1999.
38. Hilton M.L., Wavelet and wavelet packet compression of electrocardiograms, *IEEE Trans. Biomed. Eng.* 44 (5), 394–402, 1997.
39. Miaou S.G., Lin C.L., A quality-on-demand algorithm for wavelet-based compression of electrocardiogram signals, *IEEE Trans. Biomed. Eng.* 49 (3), 233–239, 2002.
40. Hwang W.J., Chine C.F., Li K.J., Scalable medical data compression and transmission using wavelet transform for telemedicine applications, *IEEE Trans. Inf. Technol. Biomed.* 7 (1), 54–63, 2003.

