

## Evrişimsel sinir ağı ve QRS imgeleri kullanarak EKG tabanlı biyometrik tanıma yöntemi

### ECG based biometric identification method using QRS images and convolutional neural network

Hakan GÜRKAN<sup>1\*</sup> , Ayça HANILCI<sup>2</sup> 

<sup>1,2</sup>Elektrik-Elektronik Mühendisliği Bölümü, Mühendislik ve Doğa Bilimleri Fakültesi, Bursa Teknik Üniversitesi, Bursa, Türkiye.  
hakan.gurkan@btu.edu.tr, ayca.hanilci@btu.edu.tr

Geliş Tarihi/Received: 03.05.2019  
Kabul Tarihi/Accepted: 20.08.2019

Düzeltilme Tarihi/Revision: 19.08.2019

doi: 10.5505/pajes.2019.32966  
Araştırma Makalesi/Research Article

#### Öz

Medikal uygulamalarda yaygın olarak kullanılan elektrokardiyogram (EKG) işaretleri, aldatma saldırılarına karşı güçlü kulan yaşam işareti olma özelliği sayesinde, biyometrik uygulamalar için bir biyometrik büyüklük olarak kullanılmaya başlanmıştır. Bilgisayar sistemlerinin hesaplama güçlerinin artmasına bağlı olarak kişi tanıma ve sınıflandırma doğruluğunu arttırmak amacıyla son yıllarda EKG biyometrik tanıma için birkaç evrişimsel sinir ağı (ESA) tabanlı yöntem sunulmuştur. Bu çalışmada, QRS (QRS dalgası) imgeleri ve 2 boyutlu ESA yapısı kullanılarak EKG işaretleri tabanlı bir biyometrik tanıma yöntemi önerilmiştir. Önerilen yöntemde, ilk olarak EKG işaretleri gürültü temizleme ve QRS belirleme algoritmalarından geçirilerek QRS bölümlerine ayrılmıştır. Elde edilen bu bölümler R noktalarına göre hizalandıktan sonra 256x256 büyüklüğünde QRS imgesi olarak adlandırılan 2 boyutlu EKG işaretlerine dönüştürülmüştür. Son olarak elde edilen bu QRS imgelerinin giriş olarak uygulandığı 2 boyutlu bir ESA modeli geliştirilerek biyometrik tanıma gerçekleştirilmiştir. Önerilen yöntemin başarımı diğer ESA tabanlı EKG biyometrik tanıma yöntemleri ile karşılaştırılabilir olarak incelenmiştir. Önerilen yöntem 46 kişiden oluşan bir EKG veri kümesi üzerinde %98.08 doğruluk oranı ve %99.275 kişi tanıma oranı sağlamıştır.

**Anahtar kelimeler:** Elektrokardiyogram (EKG), Biyometrik, Evrişimsel sinir ağı (ESA), QRS imgeleri.

#### Abstract

Electrocardiogram (ECG) signals, which are commonly used in medical applications, have been started to use as a biometric modality for biometric applications thanks to its liveness indicator that makes it stronger against spoofing attacks. Due to improving computational power of computer systems, several convolutional neural network (CNN) based methods have been recently proposed for ECG biometric identification in order to increase identification performance and classification accuracy. In this work, we proposed an ECG based biometric identification method using QRS (QRS wave) images and two-dimensional CNN. In the proposed method, ECG signals were segmented by applying noise removing and QRS detection algorithms. After these segments were aligned according to their R-points, they were transformed to two-dimensional ECG signals called QRS images of size 256x256. Finally, biometric identification task was achieved by developing a CNN based ECG biometric identification method which uses the QRS images as an input. The identification performance of the proposed method was compared to other CNN based ECG biometric identification methods proposed in the literature. The experimental results show that the proposed method provides an accuracy of 98.08% and an identification rate of 99.275% for a public ECG database of 46 persons.

**Keywords:** Electrocardiogram (ECG), Biometrics, Convolutional neural network (CNN), QRS images.

## 1 Giriş

Elektrokardiyogram (EKG) işaretleri kalbin elektriksel aktivitesini gösteren ve deri üzerinden ölçülebilen, biyolojik bir işarettir [1]-[3]. Kalp hastalıklarının teşhis edilmesi amacıyla yaygın olarak kullanılan EKG işaretlerinin analizi geçtiğimiz otuz yıl içerisinde aktif bir araştırma alanı olmuştur [2].


Biyometrik tanıma, bir bireyin fizyolojik ve/veya davranışsal karakteristiklerine dayalı olarak tanımlanmasıdır [1]. Fizyolojik özellikler genellikle sabit kalan ve zamanla kolayca değişmeyen özelliklerdir. Buna karşın davranışsal karakteristiklere dayalı özellikler zamanla ve ortama bağlı olarak farklılık gösterebilirler. Geçtiğimiz 30 yıl içerisinde yüz, parmak izi, el geometrisi, iris ve retina gibi fizyolojik özelliklere veya yürüme biçimi, imza ve konuşma gibi davranışsal özelliklere dayalı biyometrik tanıma sistemleri geliştirilmiştir [2],[3].

Son yıllarda ise klinik teşhis için çok önemli bir araç olan EKG işaretinin yeni bir biyometrik büyüklük olarak kullanılabileceğine dair çalışmalar yayınlanmıştır. Özellikle yaş, cinsiyet, kalbin pozisyonu, büyüklüğü ve anatomisi gibi çeşitli kişisel etkenlere bağlı olarak, EKG işaretleri ayırt edici özellikler taşımaktadır. Bu nedenle, EKG işaretlerinin biyometrik büyüklük olarak biyometrik tanıma sistemlerinde kullanılması söz konusu olmuştur [2],[4]. EKG tabanlı biyometrik tanıma sistemlerinin diğer sistemlere göre güvenlik açısından en önemli üstünlüğü, bu işaretlerin canlı bir vücuttan elde edilmesi gerekliliğidir. [3]. Bununla birlikte evrensel bir işaret olan EKG işareti hem taklit edilmesi neredeyse imkânsız hem de o kişinin o anda orada somut olarak bulunduğunu gösteren bir yaşam işaretidir. Buna ek olarak, bir kişiye ait EKG işaretini taklit edebilecek veya yapay olarak üretebilecek bir teknoloji henüz geliştirilmemiştir. Bu nedenlerden dolayı EKG tabanlı biyometrik tanıma sistemleri, bilgisayar ve ağ erişim kontrollerinde, bankamatik sistemlerinde ve sınır kontrol

\*Yazışılan yazar/Corresponding author

sistemleri gibi devlet uygulamalarında geniş kullanım alanı bulma potansiyeline sahiptir [2].

Normal bir EKG işaretinin bir periyodu Şekil 1'de görüldüğü gibi P dalgası ile başlar, QRS dalgası ile devam eder, T ve U dalgaları ile tamamlanır. EKG işaretini oluşturan bu temel dalga bileşenleri kalbi meydana getiren kulakçıkların ve karıncıkların depolarizasyonu ve repolarizasyonu sonucu meydana gelir. Şekil 1'de görülen P dalgası kulakçık repolarizasyonu sonucu oluşurken QRS dalgası karıncık depolarizasyonu sonucunda oluşur. T ve U dalgaları ise karıncık repolarizasyonu sonucunda meydana gelirler. EKG işaretlerinin bölütlenmesi genellikle R noktasının belirlenmesi ile gerçekleştirilir. R noktasının belirlenmesi sonucunda QRS dalgasını içeren ve QRS bölütü olarak adlandırılan EKG bölütleri elde edilebilir [5].



Şekil 1. EKG işareti ve önemli bileşenleri.

Figure 1. An ECG signal and its important components.

Bu çalışmada, QRS imgeleri ve 2 boyutlu evrişimsel sinir ağı yapısına dayanan bir EKG biyometrik tanıma yöntemi önerilmiştir. Önerilen yöntemde, ilk olarak EKG işaretleri gürültü temizleme ve QRS belirleme algoritmalarından geçirilerek QRS bölütlerine ayrılmıştır. Daha sonra bu bölütler R noktalarına göre hizalanarak 1 boyutlu EKG işaretleri 2 boyutlu EKG işaretlerine dönüştürülmüştür. Son olarak elde edilen bu 256x256 büyüklüğündeki 2 boyutlu EKG görüntülerini giriş olarak kabul eden 2 boyutlu evrişimsel sinir ağı (2B-ESA) modeli geliştirilerek biyometrik tanıma gerçekleştirilmiştir. Önerilen yöntemin başarımı teknik yazımda yayınlanmış az sayıda evrişimsel sinir ağı (ESA, convolutional neural network-CNN) tabanlı EKG biyometrik tanıma yöntemleri ile karşılaştırmalı olarak incelenmiştir.

## 2 İlgili çalışmalar

Son yirmi yıl içerisinde, çeşitli EKG tabanlı biyometrik tanıma sistemleri ve uygulamaları geliştirilmiştir. Bu alanda yapılan ilk çalışma 2001 yılında Biel ve diğ. tarafından [5] yapılmıştır. Bu çalışmada ticari bir cihaz kullanılarak 12 kanallı EKG işaretinin bir kanalı için 30 adet zaman ve genlik belirten öznelikler çıkartılmıştır. Bu öznelikler çok değişkenli analiz yöntemi kullanılarak sınıflandırılmış ve 20 kişilik bir denek grubunda yüzde yüzlük bir biyometrik tanıma başarımı elde edilmiştir [5]. Daha sonra yine 2001 yılında Irvine ve diğ. tarafından kalp ritmi değişiminin biyometrik bir büyüklük olarak kullanılabilceği gösterilmiştir [6].

2002 yılında Shen ve diğ. [7] tarafından 1 kanallı EKG işaretinden kişi tanıma için iki aşamalı bir yöntem önerilmiştir. Önerilen yöntem ilk aşamada, iki QRS aralığını karşılaştırmak için şablon eşleşme metodunu kullanarak özilinti katsayılarını hesaplamıştır. İkinci aşamada şablon eşleşme yöntemi sonucunda bulunan olası adaylar içerisinde yapay sinir ağı tabanlı bir karar verme (Decision-Based Neural Network-DBNN) algoritması kullanılarak tanıma işlemi

gerçekleştirilmiştir. Bu çalışmada yedi tane zaman ve genlik belirten öznelik kullanılmıştır. 20 kişi üzerinde yapılan deneyler sonucunda şablon eşleşme yöntemi %95, DBNN yöntemi %80, iki yöntem birlikte kullanıldığında da %100 tanıma oranı (identification rate-IDR) gerçekleştirilmiştir [7].

2003 yılında Israel ve diğ. tarafından EKG ve yüz işaretlerini tümleşik biçimde kullanan bir biyometrik tanıma sistemi sunulmuştur. Sunulan sistem otomatik tanıma sağlamasına rağmen tanıma oranları düşüktür [8].

2005 yılında Israel ve diğ. tarafından [9], EKG işaretlerinin her bir kalp döngüsünden 12 öznelik çıkarılmıştır. Sınıflandırıcı olarak doğrusal ayırıcı analizinin (Linear Discriminant Analysis-LDA) kullanıldığı bu yöntem, 29 kişiden alınan bir veri tabanı üzerinde %81 kalp döngüsü tanıma ve %100 insan tanıma başarımı göstermiştir [9]. Aynı yıl Shen [10], ilk aşamada şablon eşleşme yöntemi ile ortalama karesel hata yöntemi ikinci aşamada da DBNN yöntemi ile mesafe sınıflandırma yöntemi karşılaştırmalı olarak incelemiştir. Bu çalışmada 17 adet zaman ve genlik öznelikleri çıkartılmıştır. 168 sağlıklı kişinin EKG işaretinden oluşturulan veri tabanı üzerinde en iyi tanıma oranı şablon eşleşme ve mesafe sınıflandırma kullanılarak %95.3 olarak sunulmuştur [10].

2006 yılında tekrar Shen, [10] No.lu çalışmada elde edilen EKG öznelik setini 17'den 11'e indirgeyerek aynı EKG veri tabanı için %95 oranında tanıma başarımı sağlamıştır [11].

2007 yılında Wübbeler ve diğ. [4] Einthoven kanallarını kullanarak iki boyutlu bir kalp vektörü tanımlamışlardır. Bu öznelikler kullanılarak %98.1 oranında EKG tanıma başarımı gerçekleştirilmiştir [4].

2008 yılında Wang ve diğ. tarafından [2], EKG tabanlı bir biyometrik tanıma yöntemi geliştirilmiştir. Geliştirilen yöntem EKG bölütlerine ilişkin özilinti dizilerine (autocorrelation sequence-AC) ayırık kosinüs dönüşümü (Discrete cosine transform-DCT) uygulanarak elde edilen AC/DCT özneliklerinin sınıflandırılmasına dayanır. Bu yöntem iki farklı veri tabanı üzerinde test edilmiş ve her bir veri tabanı için sırasıyla %94.47 ve %97.8 oranında kişi tanıma başarımı göstermiştir [2]. Yine 2008 yılında Chuang-Chien ve diğ. tarafından [12] dalgaçık dönüşüm (wavelet transform) tabanlı bir EKG biyometrik tanıma yöntemi sunulmuştur. Bu yöntemde, EKG işaretleri için dalgaçık dönüşümü katsayılarından oluşan yeni bir öznelik seti oluşturulmuştur. Sunulan yöntem normal EKG işaretlerinde %100 tanıma başarımı sağlarken, kalp ritmi bozukluğu olan EKG işaretlerinde %81 tanıma başarımı sağlamıştır [12]. Aynı yıl, Irvine ve diğ. [13], eigenPulse adını verdikleri EKG tabanlı bir biyometrik tanıma yöntemi sunmuşlardır. Sunulan yöntem temel bileşenler analizine (Principles Component Analysis) dayanmaktadır.

2009 yılında Fang ve Chan [3], 1 kanallı veya 3 kanallı EKG işaretinin faz uzayında yeniden oluşturulmasına dayanan eğitimci EKG tabanlı bir biyometrik tanıma yöntemi geliştirmişlerdir. Bu çalışmada 1 kanallı EKG işaretleri için %93 ve 3 kanallı EKG işaretleri için de %99 başarımlar sağlanmıştır. Fatemian ve Hatzinakos tarafından [14], 2009 yılında, kişiye özgü olan temsilci QRS bölütü çıkartılmış ve buna dayanan yeni bir EKG tabanlı biyometrik tanıma sistemi önerilmiştir. Sınıflandırma ve tanıma işlemi ilinti katsayısı kullanılarak gerçekleştirilmiştir. Önerilen sistem ile %99.61 tanıma oranı başarılmıştır [14].

2010 yılında Li ve Narayanan tarafından [15], hem zamansal hem de güç spektrum bilgisi kullanılarak yeni bir EKG tabanlı biyometrik tanıma algoritması geliştirilmiştir. Zamansal özellikleri gösteren Hermite polinom katsayıları destek vektör makineleri (DVM, support vector machine-SVM) yöntemi kullanılarak; frekans bilgisini modellemek için kullanılan güç spektrum özellikleri (cepstral features) de GMM (Gaussian mixture model) ile sınıflandırılmıştır. Her iki öznelik seti kullanılarak %98.26 tanıma oranı elde edilmiştir [15]. Aynı yıl, Sufi ve diğ. tarafından [16], polinomsal uzaklık ölçütüne dayanan bir biyometrik tanıma sistemi sunulmuştur. Sunulan yöntemin diğer yöntemlere kıyasla daha hızlı olduğu belirtilmiştir. Yine 2010 yılında, Loong ve diğ. tarafından [17], LPC (Linear predictive coding) tabanlı bir EKG biyometrik tanıma sistemi önerilmiştir. Bu yöntemde EKG işaretinin LPC spektrumunun ilk 40 katsayısı öznelik seti olarak kullanılmış ve %99 doğru tanıma oranına sahip olduğu belirtilmiştir. Aynı yıl Ting ve diğ. tarafından [18], Kalman filtrelerine dayanan bir EKG tabanlı biyometrik tanıma yöntemi sunulmuştur. Önüç kişinin EKG işaretinden oluşan bir veri kümesi üzerinde test edilen bu yöntemin tanıma oranı %87.5 olarak belirtilmiştir [18].

2011 yılında Sufi ve Khalil tarafından [19], sıkıştırılmış EKG işaretlerinden veri madenciliği teknikleri kullanılarak EKG öznelik seti çıkarılmasına ilişkin bir yöntem sunulmuştur. Yine 2011 yılında Safie ve diğ. tarafından darbe aktif oranı (Pulse Active Ratio-PAR) olarak bilinen yeni bir öznelik çıkartma tekniği önerilmiştir [20].

2013 yılında Gurkan ve diğ. tarafından [21], EKG işaretlerine ilişkin AC/DCT öznelikleri, cepstrum öznelikleri, ve QRS bölütleri kullanılarak oluşturulan öznelik setlerine dayalı bir biyometrik tanıma algoritması geliştirilmiştir. Geliştirilen biyometrik tanıma algoritması 30 kişi üzerinden alınmış EKG verisi üzerinde test edilmiştir. Önerilen algoritmanın biyometrik tanıma oranı %97.31 olarak belirtilmiştir.

2017 yılında Chamatidis ve diğ. tarafından [22], Kosinüs, Fourier ve Dalgacık dönüşümlerinden elde edilen 20 şer adet katsayı birleştirilerek 60 tane katsayıdan oluşan yeni bir öznelik seti sunulmuştur. Sınıflandırma için 60 nöron içeren bir giriş katmanından ve sırasıyla 100, 200, 100 nöron içeren 3 gizli katmandan oluşan bir derin sinir ağı oluşturulmuştur. Önerilen yöntem ile %79.8 doğruluk (accuracy) oranı sağlamıştır [22].

Bu çalışmalara ek olarak parmak uçlarından ve/veya avuç içinden ölçülmesine ilişkin jel kullanmadan Ag/AgCl elektrotlar ile bazı ölçüm düzenekleri önerilmiş ve bu biçimde alınan EKG işaretleri üzerinde çeşitli biyometrik tanıma algoritmaları geliştirilmiştir.

2008 yılında Chan ve diğ. tarafından [23] EKG tabanlı biyometrik tanıma için dalgacık dönüşümüne dayanan yeni bir hata ölçütü tanımlanmıştır. Geriye doğru farkların çarpımına (multiplication of backward differences algorithm) dayanan bir QRS belirleme algoritması ile QRS bölütleri belirlenmiş ve elde edilen QRS bölütlerinin ortalama değeri kullanılarak kişiye ait bir temsilci QRS bölütü oluşturulmuştur. Sınıflandırma süreci dalgacık dönüşümüne dayanan yeni bir hata ölçütü kullanılarak gerçekleştirilmiştir. Bu yöntem ile %89 oranında kişi tanıma başarımına ulaşılmıştır [23].

2011 yılında Shen ve diğ. tarafından [24], kişiye ilişkin çıkartılan kalp döngüsü dalgasına ait 17 adet zaman ve genlik öznelikleri kullanılmış ve tanıma oranı %95.3 olarak belirtilmiştir [24]. Aynı yıl, Chen ve diğ. tarafından [25], EKG

işaretlerinin kaotik özneliklerinin çıkartılmasına dayanan bir biyometrik tanıma yöntemi geliştirmişlerdir. Elde edilen öznelikler geriye yayılım algoritmasına dayalı yapay sinir ağları (back propagation neural network) kullanılarak sınıflandırılmış ve %90 oranında kişi tanıma başarımı sağlanmıştır [25]. Lourenço ve diğ. tarafından [26] parmaklar arasından ölçülen EKG işaretlerine dayalı bir biyometrik tanıma sistemi önerilmiştir. Önerilen yöntemin başarımı 16 kişilik bir grup üzerinde parmaktan toplanan EKG işaretleri ile test edilmiştir. Önerilen yöntemin tanıma oranı %94.3 olarak belirtilmiştir [26].

2015 yılında Singh ve diğ. tarafından [27] parmak ucu EKG tabanlı bir biyometrik tanıma sistemi önerilmiştir. Ancak kullanılan sistem ve veri kümesi hakkında detaylı bir bilgi verilmemiştir [27].

2017 yılında Wieclaw ve diğ. tarafından [28] üç parmaktan alınan EKG işaretleri üzerinde kişi tanıma için çok katmanlı algılayıcı (multilayer perceptron) içeren bir derin sinir ağı önerilmiştir. Önerilen derin sinir ağı 270 nöronlu giriş katmanı, 70, 50, 30 nöronlu 3 gizli katman ve 19 nöronlu bir çıkış katmanından oluşmaktadır. Önerilen yöntem 18 kişiden elde edilen 147 EKG işareti üzerinde test edilmiş ve %88.97 doğruluk oranı elde edilmiştir.

2018 yılında Guven ve diğ. tarafından [29] hem parmak ucu EKG veri toplama sistemi hem de bu sistem kullanılarak elde edilen parmak ucu EKG işaretleri üzerinden bir biyometrik tanıma sistemi geliştirilmiştir. Geliştirilen sistem 60 kişilik bir test kümesi üzerinde test edilmiş ve %98.33 (60'da 59) oranında kişi tanıma başarımı sağlamıştır [29].

Bilgisayar çalışma hızlarının artması ve grafik işlemci birimlerinin (GPU) gelişmesi sonrasında derin öğrenme tabanlı yöntemler öznelik çıkarımı (feature extraction), sınıflandırma (classification), biyometrik tanıma ve doğrulama, konuşma tanıma, konuşmacı tanıma, doğal dil işleme, biyomedikal görüntü işleme ve sınıflandırma gibi alanlarda yaygın olarak kullanılmaya başlanmıştır [30]. Özellikle son yıllarda EKG tabanlı biyometrik tanıma için derin öğrenme yöntemlerinden biri olan ESA modelleri geliştirilmeye başlanmıştır [31]-[39].

2016 yılında Lei ve diğ. tarafından [32] öznelik çıkarımı için bir boyutlu ESA (1B-ESA) modeli ve sınıflandırma için doğrusal olmayan DVM yöntemi içeren bir model önerilmiştir. Önerilen model her birinin çıkışında ortalama ortaklama (average pooling) katmanı olan 3 adet evrimsel katman (convolutional layer) ve tam bağlantılı katmandan (fully connected layer) oluşmaktadır. ESA modelinin girişi 136x1 boyunda rastgele bölütlenmiş EKG bölütleridir. Modelin çıkışında elde edilen 1x160 boyutunda öznelik vektörleri doğrusal olmayan DVM modeli ile sınıflandırılmıştır. Önerilen yöntem, 100 kişiden oluşan bir veri tabanı için %99.33 oranında doğruluk oranı gerçeklemiştir [32].

2017 yılında Zhang ve diğ. tarafından [33] öznelik çıkarımı ve sınıflandırma için bir boyutlu paralel ESA modeli önerilmiştir. Bu model her birinin çıkışında maksimum ortaklama (maximum pooling) katmanı olan 4 adet evrimsel katman ve tam bağlantılı katmandan oluşan N tane 1B-ESA modelinin paralel bağlanması biçiminde oluşturulmuştur. EKG işaretleri 2 sn.'lik bölütlere ayrıldıktan sonra dalgacık dönüşümü ve özilinti işleminden geçirilerek modelin girişine uygulanmıştır. Önerilen model 18 ile 47 arasında kişi içeren farklı EKG veri kümeleri üzerinde test edilmiş ve ortalama %93.5 kişi tanıma oranı gerçeklemiştir [33].



Aynı yıl Eduardo ve diğ. tarafından [34] öznelik çıkarımı için derin otokodlayıcı (deep autoencoder) ve sınıflandırma için K-En Yakın Komşu (K-Nearest Neighbourhood, K-NN) yöntemi kullanan bir model önerilmiştir. Önerilen modelin başarımı 790 kişiden oluşan bir veri tabanı üzerinde test edilmiş ve %0.91 oranında kişi tanıma hatası verdiği belirlenmiştir [34]. Salloum ve diğ. [35] tarafından öznelik çıkarımı ve sınıflandırma için tekrarlayan sinir ağı (TSA, recurrent neural network-RNN) modeli önerilmiştir. Önerilen model 47 ve 90 kişi içeren iki EKG veri kümesi için %100 doğruluk oranı sağlamıştır [35]. Zhang ve diğ. tarafından [36] her birinin çıkışında maksimum ortaklama katmanı olan 3 adet evrişimsel katman ve tam bağlantılı katmandan oluşan bir iki boyutlu ESA (2B-ESA) modeli önerilmiştir. Bu çalışmada bir boyutlu EKG işaretleri rastgele olarak bölütlenmiş ve daha sonra 200x200 boyutlu EKG yörünge (ECG trajectory) görüntülerine dönüştürülmüştür. Elde edilen iki boyutlu EKG işaretleri önerilen 2B-ESA modelinin girişine uygulanmıştır. Önerilen ESA modelinin başarımı 10 kişiden oluşan bir EKG veri kümesi üzerinde test edilmiş ve %98.4 kişi tanıma oranı elde edilmiştir [36].

2018 yılında Luz ve diğ. tarafından [37] bir boyutlu ve iki boyutlu ESA yapılarının birlikte kullanıldığı bir model önerilmiştir. Önerilen modelde 1B-ESA yapısına giriş olarak R noktalarına göre hizalanmış QRS bölütleri uygulanmıştır. Aynı anda bu QRS bölütlerinin spektrogramları da 2B-ESA yapısının girişine uygulanmıştır. Her iki ESA yapısının çıkışında elde edilen sonuçlar skor seviyesinde birleştirilmiştir. Önerilen model %14 eşit hata oranı (equal error rate) sağlamıştır [37]. 2018 yılında Labati ve diğ. [38] tarafından ESA mimarisine dayanan EKG biyometrik tanıma yöntemi önerilmiştir. Önerilen yöntemde ilk olarak EKG işaretinden QRS bölütleri elde edilmiş ve bu bölütler arasındaki ilinti katsayısına göre seçilen QRS bölütleri arka arkaya eklenerek bir boyutlu öznelik vektörü tanımlanmıştır. Daha sonra bu vektörü giriş olarak kabul eden ve altı tane evrişimsel katmandan oluşan bir 1B-ESA modeli geliştirilmiştir. Önerilen model 52 kişiden oluşan bir veri kümesi üzerinde test edilmiş ve %100 oranında kişi tanıma oranı gerçekleştirmiştir [38]. Aynı yıl Abdeldayem ve diğ. [39] tarafından EKG işaretlerinin spektra-temporal imgelerinden öznelik çıkarmak ve sınıflandırmak için 2B-ESA modeli önerilmiştir. İlk olarak EKG işaretlerine kısa süreli Fourier dönüşümü (short time Fourier transform-STFT) ve sürekli zaman dalgacık dönüşümü (continuous wavelet transform-CWT) uygulayarak spektra-temporal imgeler oluşturulmuştur. Daha sonra maksimum ortaklama katmanı ve doğrultulmuş doğrusal birim (ReLU) aktivasyon fonksiyonu içeren 2 adet evrişimsel katman ve tam bağlantılı katmandan oluşan bir ESA modeli ile öznelik çıkarımı ve sınıflandırma işlemini yapmışlardır [39].


2019 yılında Hammad ve diğ. [40] tarafından EKG ve parmak izi işaretlerini birlikte değerlendiren bir biyometrik tanıma modeli önerilmiştir. Bu çalışmada [40], EKG işaretlerinden öznelik çıkarımı için ReLU aktivasyon fonksiyonu ve maksimum ortaklama katmanı içeren 4 adet evrişimsel katman ile 3 adet tam bağlantılı katmandan oluşan bir 1B-ESA modeli önerilmiştir. Parmak izi işaretlerinden öznelik çıkarımı için de VGG-net kullanılmıştır. Sınıflandırma işlemi ise çok sınıflı destek vektör makinesi ile gerçekleştirilmiştir. Önerilen model EKG işaretleri üzerinden %96.56 oranında doğruluk oranı gerçekleştirmiştir. Hem EKG hem de parmak izi işaretleri birlikte kullanıldığında ise önerilen modelin doğruluk oranı %99.99 olarak belirtilmiştir [40].

### 3 Önerilen biyometrik tanıma yöntemi

Önerilen 2B-ESA tabanlı EKG biyometrik tanıma yöntemi önileme süreci, veri çoğaltma süreci, ESA tabanlı öznelik çıkarma ve sınıflandırma süreci olmak üzere üç ana kısımdan oluşmaktadır.


#### 3.1 Önileme süreci

Önileme süreci, biyometrik tanıma algoritmalarının en önemli kısımlarından birini oluşturmaktadır. Çünkü öznelik çıkarma ve sınıflandırma işlemleri için kullanılacak işaretleri hazırlamakta önemli bir rol oynar. Önileme süreci, temel olarak üç kısımdan oluşur: Gürültü temizleme, QRS bölütleme ve QRS bölütlerinin 2 boyutlu imge olarak temsil edilmesi. EKG işaretleri şebeke gürültüsü, taban hattı kayması (baseline wander), yüksek frekans gürültüsü gibi biyometrik tanıma başarımını olumsuz yönde etkileyebilecek çeşitli gürültü bileşenlerini içerebilir. Bu nedenle önileme sürecinin ilk adımında EKG işaretleri 1Hz-40Hz geçirme bandına sahip bir 4. dereceden Butterworth bant geçiren süzgeç yapısından geçirilerek bu gürültü bileşenlerinden temizlenmiştir. İkinci adımda EKG işaretlerine ilişkin R noktaları teknik yazımda çok iyi bilinen Pan-Tompkins QRS belirleme algoritması [41] kullanılarak belirlenmiş ve daha sonra bu R noktası hizalanarak 256 örnek içeren QRS bölütleri elde edilmiştir. Daha sonra her bir EKG bölütü 0-1 değerleri arasına normalize edilmiştir. Üçüncü ve son adımda ise elde edilen eşit uzunluklu ve R noktasına göre hizalanmış EKG bölütleri kullanılarak 1 boyutlu EKG işaretleri 2 boyutlu EKG işaretlerine dönüştürülmüştür. Bu önileme sürecinin işleyişi Şekil 2-5'te gösterilmiştir.




Şekil 2. EKG işareti.

Figure 2. An ECG signal.




Şekil 3. QRS belirleme.

Figure 3. QRS detection.



Şekil 4. QRS bölütleme.

Figure 4. QRS segmentation.



Şekil 5. 256x256x1 boyutlu QRS imgesi.

Figure 5. A QRS image of size 256x256x1.

### 3.2 Öznitelik çıkarımı ve sınıflandırma için kullanılan 2B-ESA mimarisi

Derin sinir ağları (Deep neural networks) bilgisayarlı görme, konuşma tanıma ve robotik içeren için birçok yapay zeka uygulamasında yaygın olarak kullanılmaktadır. Derin sinir ağlarının yaygın bir şekli ise çoklu evrişimsel katmanlardan oluşan evrişimsel sinir ağlarıdır. (convolutional neural networks-CNN). Bu ağlarda her bir katman, öznitelik haritası (feature map) adı verilen giriş verisinin daha üst seviye temsilini oluşturur. Modern evrişimsel sinir ağları çok derin bir katman hiyerarşisi kullanarak üstün performans elde edebilmektedir [42]. Bu çalışmada öznitelik çıkarım ve sınıflandırma yöntemi olarak Şekil 6'da gösterilen 2B-ESA mimarisi kullanılmıştır. Bu mimariye ait parametre detayları ise Tablo 1'de sunulmuştur.


Önerilen yöntemde, 4 adet evrişimsel katman (convolutional layer), 3 adet tam bağlantılı katman (fully connected layer) ve 1 adet çıkış katmanı (output layer) kullanılmıştır. Her bir evrişimsel katman çıkışında birer adet maksimum ortaklama (maximum pooling) ve seyreltme (dropout) katmanları tanımlanırken, 3 adet tam bağlantılı katman çıkışında ise birer adet seyreltme katmanı tanımlanmıştır.

Evrişimsel katmanların her birinde aktivasyon fonksiyonu olarak doğrultulmuş doğrusal birim (Rectified Linear Unit-ReLU), tam bağlantılı katmanların her birinde ise Sigmoid fonksiyonları kullanılmıştır. Kullanılan ESA mimarisinde parametre sayısının azaltılması ve ezberleme sorunun önüne geçmek için maksimum ortaklama katmanları kullanılmıştır. Evrişimsel katmanlarda süzgeç boyutu olarak en sık kullanılan 3x3 boyutundaki süzgeçler kullanılırken, maksimum ortaklama katmanlarında ise 2x2 boyutunda süzgeçler kullanılmıştır. ESA mimarisinde kullanılan seyreltme katmanlarında nöronların %20'si sıfır kabul edilerek modelin eğitim verisini ezberlemesinin önüne geçilmesi sağlanmıştır [43].

Tablo 1: Önerilen 2B-ESA mimarisinin parametreleri.

Table 1. Parameters of the proposed 2D-CNN architecture.

Katman	Süzgeç Boyutu	Katman Çıkışı Boyutu	Parametre Sayısı
Evrişimsel (ReLU)	3x3	(256x256, 32)	320
Maks. Ortaklama	2x2	(128x128, 32)	0
Seyreltme (0.2)	-	(128x128, 32)	0
Evrişimsel (ReLU)	3x3	(128x128, 64)	18496
Maks. Ortaklama	2x2	(64x64, 64)	0
Seyreltme (0.2)	-	(64x64, 64)	0
Evrişimsel (ReLU)	3x3	(64x64, 128)	73856
Maks. Ortaklama	2x2	(32x32, 128)	0
Seyreltme (0.2)	-	(32x32, 128)	0
Evrişimsel (ReLU)	3x3	(32x32, 256)	295168
Maks. Ortaklama	2x2	(16x16, 256)	0
Seyreltme (0.2)	-	(16x16, 256)	0
Düzleştirme	-	(65536)	0
Tam Bağlantılı (Sigmoid)	-	(256)	16777472
Seyreltme (0.2)	-	(256)	0
Tam Bağlantılı (Sigmoid)	-	(256)	65792
Seyreltme(0.2)	-	(256)	0
Tam Bağlantılı (Sigmoid)	-	(256)	65792
Seyreltme (0.2)	-	(256)	0
Çıkış (Softmax)	-	(46)	11822
Toplam Parametre Sayısı			17308718



E: Evrişimsel (ReLU), MO: Maksimum ortaklama, S: Seyreltme, TB: Tam bağlantılı.

Şekil 6. Önerilen EKG biyometrik tanıma yönteminde kullanılan 2B-ESA mimarisi.

Figure 6. 2D-CNN architecture used in the proposed ECG biometric identification method.

## 4 Deneysel sonuçlar

### 4.1 EKG veri kümesi

Bu çalışmada önerilen yöntemin başarımını değerlendirmek için MIT-BIH Arrhythmia veri kümesi kullanılmıştır. Bu veri kümesi her biri 30 dk. uzunluğunda olan 47 farklı kişiden kaydedilmiş 48 tane EKG işareti içermektedir. Ayrıca, her bir EKG işareti 360 Hz frekansında örneklenmiş ve her bir örnek 11-bit ile kodlanmıştır. Bu veri kümesi yaşları 32 ile 89 arasında değişen 25 erkek, yaşları 23 ile 89 arasında değişen 22 kadından oluşmaktadır. Bu veri kümesinde 201 ve 202 No.lu kayıtlar aynı kişiden alınmıştır [44]-[46]. Bu çalışmada, 47 kişilik veri kümesi içerisinde 108 No.lu kayıt yetersiz veri nedeniyle kullanılamamıştır. Bu nedenle önerilen yöntemin başarımını değerlendirmek için 46 farklı kişiden alınmış kayıtlar kullanılarak eğitim modeli geliştirilmiş ve önerilen yöntemin başarımını test edilmiştir.

### 4.2 Başarım sonuçları

Önerilen yöntemin eğitim ve test aşamaları, 2.80 Ghz Intel Core i5 işlemci, 32 GB RAM ve GPU NVIDIA GTX1060 içeren bir iş istasyonu üzerinde Python Keras [47],[48] ve Tensorflow [49] Kütüphaneleri kullanılarak gerçekleştirilmiştir. Önerilen yöntemin kişi tanıma başarımını değerlendirmek için tasarlanan deneyde ilk olarak 46 kişiye ilişkin 1045 adet 256x256x1 boyutlu QRS imgesi elde edilmiştir. Daha sonra veri çoğaltma işlemi ile 4180 adet 256x256x1 boyutlu QRS imgeleri oluşturulmuştur. Her bir kişiye ait çoğaltılmış QRS imgelerinin %80'i 2B-ESA yapısını eğitmek için, geri kalan %20'si ise modeli test etmek için kullanılmıştır. Özet olarak toplamda 46 kişi için 3345 adet eğitim verisi, 835 adet test verisi kullanarak önerilen yöntemin kişi tanıma başarımını incelenmiştir. Eğitim ve test veri kümelerinin oluşturulmasında yanlılık etkisini (biasing effect) azaltmak için 3 katlamalı çapraz doğrulama (3-fold cross validation) yöntemi kullanılmıştır. Her bir kat için eğitim ve test kümelerinin model doğruluk ve model kayıp eğrileri 100 eğitim adımı için Şekil 7-9 ve Şekil 10-12'de sırasıyla sunulmuştur. Her bir kat için sınıflandırma başarımını değerlendirmek için test veri kümesi üzerinde doğruluk, duyarlılık, kesinlik ve F ölçütü değerleri hesaplanmış ve Tablo 2'de sunulmuştur. Ayrıca 3 katlamalı çapraz doğrulama yöntemi sonunda elde edilen ortalama değerler de Tablo 2'de verilmiştir. Tablo 2'de görüldüğü gibi önerilen yöntem test veri kümesi üzerinde ortalama olarak %98.08 oranında oldukça yüksek bir doğruluk oranı başarmaktadır.

Tablo 2: Önerilen yöntemin test veri kümesine göre sınıflandırma başarımı.

Table 2. Classification performance of the proposed method according to the test set.

Kat	Doğruluk (Accuracy)	Duyarlılık (Recall)	Kesinlik (Precision)	F-Ölçütü (F-score)
Kat 1	%97.36	%97.29	%98.17	%97.98
Kat 2	%99.88	%99.86	%99.91	%99.89
Kat 3	%97.00	%97.39	%97.54	%97.46
Ortalama	%98.08	%98.34	%98.54	%98.44

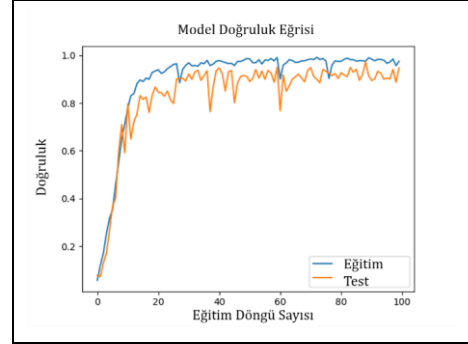
Ayrıca önerilen yöntemin kişi tanıma oranları Tablo 3'te sunulmuştur. Kişi tanıma oranlarının elde edilmesinde oylama yöntemi (voting rule) kullanılmıştır. Bir kişi için test verilerinin %50'sinden fazlası doğru olarak tespit ediliyorsa o kişinin doğru olarak belirlendiği kabul edilmiştir. Buna göre, Tablo 3 incelendiğinde önerilen yöntemin kat-1 için 46 kişide 45 kişiyi, kat-2 ve kat-3 için ise 46 kişide 46 kişiyi doğru olarak tanıdığı

görülmektedir. Önerilen yöntem ortalama olarak %99.275 kişi tanıma oranı başarmıştır.

Tablo 3. Önerilen yöntemin kişi tanıma oranı.


Table 3. Identification rate of the proposed method.

Kat	Kişi tanıma oranı-KTO (Identification Rate-IDR)
Kat-1	%97.826 (46 kişide 45)
Kat-2	%100 (46 kişide 46)
Kat-3	%100 (46 kişide 46)
Ortalama	%99.275



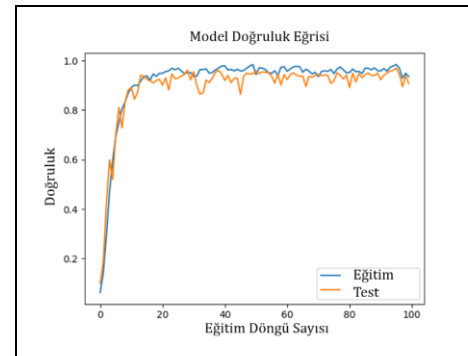
Şekil 7. Önerilen 2B-ESA mimarisi için 1. kat model doğruluk eğrisi.

Figure 7. Model accuracy curve of the proposed 2D-CNN architecture according to the fold-1.




Şekil 8. Önerilen 2B-ESA mimarisi için 2. kat model doğruluk eğrisi.

Figure 8. Model accuracy curve of the proposed 2D-CNN architecture according to the fold-2.




Şekil 9. Önerilen 2B-ESA mimarisi için 3. kat model doğruluk eğrisi.

Figure 9. Model accuracy curve of the proposed 2D-CNN architecture according to the fold-3.



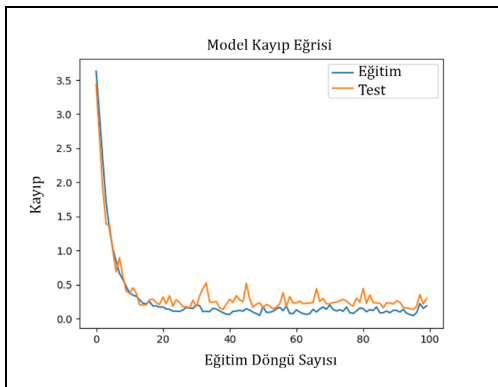
Şekil 10. Önerilen 2B-ESA mimarisi için 1. kat model kayıp eğrisi.

Figure 10. Model loss curve of the proposed 2D-CNN architecture according to the fold-1.



Şekil 11. Önerilen 2B-ESA mimarisi için 2. kat model kayıp eğrisi.

Figure 11. Model loss curve of the proposed 2D-CNN architecture according to the fold-2.

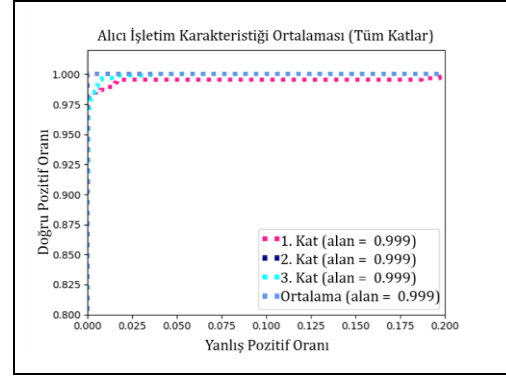


Şekil 12. Önerilen 2B-ESA mimarisi için 3.kat model kayıp eğrisi.

Figure 12. Model loss curve of the proposed 2D-CNN architecture according to the fold-3.

Bu deneyler sonucunda, önerilen yöntemin MIT-BIH Arrhythmia EKG veri kümesi [44]-[46] için oldukça yüksek doğruluk ve kişi tanıma başarımı sağladığı görülmektedir. Ayrıca önerilen yöntemin doğru olarak tespit ettiği QRS

imgelerinin %98.54'ünün doğru olduğu (Kesinlik), doğru olan QRS imgelerinin ise %98.34'ünün doğru tespit edildiği (Duyarlılık) Tablo 2'den açıkça görülmektedir. Bu anlamda, önerilen yöntemin sınıflandırma başarımının gerek duyarlılık ve kesinlik gerekse bunların harmonik ortalaması olan F-ölçütü bakımından değerlendirildiğinde yüksek olduğu gözlenmektedir. Ayrıca önerilen yöntemle ilişkin alıcı işletim karakteristiği (Receiver Operating Characteristic-ROC) eğrisi de Şekil 13'te görülmektedir.



Şekil 13. Önerilen yöntemle ilişkin ROC eğrisi.

Figure 13. ROC curve of the proposed method.

Önerilen yöntemin başarımı, teknik yazımda tespit edebildiğimiz ve az sayıda olan ESA tabanlı diğer EKG biyometrik tanıma yöntemlerinin başarımları ile doğruluk ve kişi tanıma oranlarına göre Tablo 4'te karşılaştırmalı olarak incelenmiştir. Özellikle aynı EKG veri tabanını kullanan [33] No.lu yöntem ile kıyaslandığında önerilen yöntemin yaklaşık %8 daha yüksek kişi tanıma oranı sağladığı görülmektedir.

Tablo 4'te belirtilen diğer yöntemlerde [32],[36]-[40] ise farklı EKG veri kümeleri kullanılmıştır. Tablo 4'te görüldüğü gibi [36],[39],[40] No.lu çalışmalarda sunulan yöntemlere göre doğruluk ve kişi tanıma oranları bakımından önerilen yöntemin başarımı daha yüksektir. Bununla birlikte, [32] ve [38] No.lu çalışmalarda sunulan yöntemlere göre önerilen yöntem yaklaşık %1-2 oranında daha az doğruluk oranı sağlamaktadır. Ancak burada belirtmek gerekir ki örnekleme frekansı, genlik değerleri, çözünürlüğü, EKG işareti sayısı, kişi sayısı bu çalışmada kullanılan MIT-BIH Arrhythmia EKG veri kümesine [44]-[46] göre oldukça farklıdır. Bu farklılıklar tam bir karşılaştırma yapmayı zorlaştırır da bu tabloda verilen sonuçlara bakarak önerilen yöntemin başarımı ile diğer yöntemlerin başarımları arasında anlamlı bir karşılaştırma sağlanmaktadır.

Önerilen yöntem, donanım ve hesaplama süreleri açısından ESA tabanlı diğer EKG biyometrik tanıma yöntemlerinden [38] ve [40] ile karşılaştırılmış ve sonuçlar Tablo 5'te sunulmuştur. Tablo 5'te görüldüğü gibi önerilen yöntemin eğitim süresi 46 kişi, 3345 adet eğitim verisi ve 100 eğitim döngüsü için yaklaşık 0.8 sa. test süresinin tüm test veri kümesi için 2.068 s, test başına ise 2.47 ms sürdüğü görülmektedir. Eğitim ve test süreleri karşılaştırıldığında önerilen yöntemin, diğer iki yöntemle göre daha kısa sürelerle sahip olduğu görülmektedir. Bununla birlikte test süresinin oldukça düşük olması önerilen yöntemin gerçek zamanlı uygulamalar için uygun olduğunu göstermektedir.



Tablo 4. Önerilen yöntemin başarımının ESA tabanlı diğer yöntemler ile karşılaştırılması [31].

Table 4. Comparing the performance of the proposed method with other ESA-based methods.

Yazar	Yöntem	Giriş İşareti Boyutu	Veri Kümesi	Kişi Sayısı	Başarım
Lei ve diğ. [32]	1B-ESA ve SVM	1x136	PTB	100	Doğruluk: %99.33
Zhang vd [33]	Paralel 1B-ESA	8 tane 1x720	MIT	47	Kişi Tanıma Oranı: %91.1
Zhang ve diğ. [36]	2B-ESA	200x200	Özel	10	Kişi Tanıma Oranı: %98.4
Luz ve diğ. [37]	1B-ESA 2B-ESA	1x800 128x128	CYBHi UofTDB	128 1012	Eşit Hata Oranı: 12.78% Eşit Hata Oranı: 14.27%
Labati ve diğ. [38]	1B-ESA	1x200	PTB	52	Doğruluk: %100
Abdeldayem ve diğ. [39]	2B-ESA	128x128	PTB	290	Kişi Tanıma Oranı: %97.5
Hammad ve diğ. [40]	1B-ESA	-	PTB	200	Doğruluk: %96.56
Önerilen Method	2B-ESA	256x256	MIT	46	Doğruluk: %98.08 Kişi Tanıma Oranı: %99.275

Tablo 5: Önerilen yöntemin ESA tabanlı diğer yöntemlerin donanım ve hesaplama süreleri ile karşılaştırılması.

Table 5. Comparing the performance of the proposed method with other ESA-based methods in terms of hardware and computational time.

Yazar	Yöntem	Donanım	Yazılım	Eğitim Süresi	Test Süresi
Labati ve diğ. [38]	1B-ESA	3.5 GHz Intel (R) Core (TM) i7-7800X CPU, 32 GB RAM, GPU NVIDIA TITAN X (Pascal)	Matlab 2017b ve MatConvNet toolbox	9 sa. 22 dk.	0.65 s
Hammad ve diğ. [40]	1B-ESA	2.7-GHz CPU, 32 GB RAM, GPU	Matlab 2017a	3-5 sa.	0.0958 s
Önerilen Method	2B-ESA	2.80 GHz Intel Core i5, 32 GB RAM, GPU NVIDIA GTX1060	Python Keras ve Tensorflow Kütüphaneleri	0.8 sa.	2.068 s 2.47 ms/test

## 5 Sonuçlar

EKG işaretleri medikal uygulamalarda özellikle kalp hastalıklarının teşhis ve tedavisinde yaygın olarak kullanılmaktadır. Bunun yanında, EKG işareti canlılık göstergesi olma özelliğinden dolayı yeni bir biyometrik büyüklük olarak biyometrik tanıma uygulamalarında da son yıllarda artan bir biçimde kullanılmaya başlanmıştır.

Bu çalışmada, EKG işaretleri tabanlı bir biyometrik tanıma yöntemi önerilmiştir. Önerilen yöntem 256x256 büyüklüğündeki QRS imgelerini giriş olarak kabul eden 2 boyutlu evrişimsel sinir ağı yapısına dayanmaktadır. Önerilen yöntem 46 kişiden oluşan bir EKG veri kümesi üzerinde ortalama olarak %98.08 doğruluk oranı ve %99.275 kişi tanıma oranı sağlamıştır. 3 katlamalı çapraz doğrulama (3-fold cross validation) yöntemi kullanılarak gerçekleştirilen deneylerde her bir kat için sırasıyla 46 kişide 45, 46 kişide 46 ve 46 kişide 46 kişiyi doğru olarak tanıma başarımı göstermiştir.

Önerilen yöntemde kullanılan ESA mimarisinde parametre sayısının çok olması bir dezavantaj gibi görünse de günümüzde bilgisayarların işlem kapasitelerinin oldukça yüksek olması bu dezavantajın ihmal edilmesine olanak sağlamaktadır. Tablo 5'te verilen eğitim ve test süreleri incelendiğinde özellikle test sürelerinin oldukça düşük olduğu ve bu durumu desteklediği gözlenmektedir. Buna karşın kullanılan parametre sayısının çok olması önerilen yöntemin başarımının artması yönünde bir avantaj sağlamaktadır.

Önerilen yöntemin başarımı teknik yazımda sunulmuş olan diğer ESA tabanlı EKG biyometrik tanıma yöntemleri ile karşılaştırmalı olarak incelenmiştir. Önerilen yöntemin başarımının doğruluk ve kişi tanıma oranlarına göre aynı veri kümesini kullanan yönteme göre çok daha iyi olduğu, farklı veri kümeleri kullanan yöntemlere göre de karşılaştırılabilir sonuçlar sağladığı gözlenmiştir.

## 6 Kaynaklar

- [1] Jain AK, Ross A, Prabhakar S. "An introduction to biometric recognition". *IEEE Transactions on Circuits and Systems for Video Technology*, 14(1), 4-20, 2004.
- [2] Wang Y, Agraftioti F, Hatzinakos D, Plataniotis KN. "Analysis of human electrocardiogram for biometric recognition". *EURASIP Journal on Advances in Signal Processing*, 2008, 1-11, 2008.
- [3] Fang C, Chan HL. "Human identification by quantifying similarity and dissimilarity in electrocardiogram phase space". *Pattern Recognition*, 42(9), 1824-1831, 2009.
- [4] Wübbeler G, Stavridi M, Kreiseler D, Bousseljot RD, Elster C. "Verification of humans using electrocardiogram". *Pattern Recognition Letters*, 28(10), 1172-1175, 2007.
- [5] Biel L, Pettersson O, Philipson L, Wide P. "ECG analysis: A new approach in human identification". *IEEE Transactions on Instrumentation and Measurement*, 50(3), 808-812, 2001.



- [6] Irvine JM, Wiederhold BK, Gavshon LW, et al. "Heart rate variability: A new biometric for human identification". *The International Conference on Artificial Intelligence*, Las Vegas, Nevada, USA, 25-28 June 2001.
- [7] Shen TW, Tompkins WJ, Hu YH. "One-lead ECG for identity verification". *The 2<sup>nd</sup> Joint Engineering in Medicine and Biology, 24<sup>th</sup> Annual Conference and the Annual Fall Meeting of the Biomedical Engineering Society*, Houston, Texas, USA, 23-26 October 2002.
- [8] Israel SA, Scruggs WT, Worek WJ, Irvine JM. "Fusing face and ECG for personal identification". *The 32<sup>nd</sup> Applied Imagery Pattern Recognition Workshop*, Washington, DC, USA, 15-17 October 2003.
- [9] Israel SA, Irvine JM, Cheng A, Wiederhold MD, Wiederhold BK. "ECG to identify individuals". *Pattern Recognition*, 38(1) 1, 133-142, 2005.
- [10] Shen TW. Biometric Identity Verification Based on Electrocardiogram (ECG). Ph.D. Thesis, University of Wisconsin, Madison, USA, 2005.
- [11] Shen TW. "Quartile discriminant measurement (QDM) method for ECG biometric feature selection". *International Symposium of Biomedical Engineering*, Taiwan, 14-16 December, 2006.
- [12] Chuang-Chien C, Chou-Min C, Chih-Yu H. "A novel personal identity verification approach using a discrete wavelet transform of the ECG signal". *International Conference on Multimedia and Ubiquitous Engineering*, Busan, Korea, 24-26 April, 2008.
- [13] Irvine JM, Israel SA, Scruggs WT, Worek WJ. "EigenPulse: robust human identification from cardiovascular function". *Pattern Recognition*, 41(11), 3427-3435, 2008.
- [14] Fatemian SZ, Hatzinakos D. "A new ECG feature extractor for biometric recognition". *The 16<sup>th</sup> International Conference on Digital Signal Processing*, Santorini, Greece, 5-7 July 2009.
- [15] Li M, Narayanan S. "Robust ECG biometrics by fusing temporal and cepstral information". *The 20<sup>th</sup> IAPR International Conference on Pattern Recognition*, İstanbul, Turkey, 23-26 August 2010.
- [16] Sufi F, Khalil I, Habib I. "Polynomial distance measurement for ECG based biometric authentication". *Security and Communication Networks*, 3(4), 303-319, 2010.
- [17] Loong JLC, Subari KS, Besar R, Abdullah MK. "A new approach to ECG biometric systems: A comparative study between LPC and WPD systems". *World Academy of Science Engineering and Technology*, 68, 759-764, 2010.
- [18] Ting CM, Salleh SH. "ECG based personal identification using extended kalman filter". *10<sup>th</sup> International Conference on Information Sciences, Signal Processing and their Applications (ISSPA)*, Kuala Lumpur, Malaysia, 10-13 May 2010.
- [19] Sufi F, Khalil I. "Faster person identification using compressed ECG in time critical wireless telecardiology applications". *Journal of Network and Computer Applications*, 34(1), 282-293, 2011.
- [20] Safie SI, Soraghan JJ, Petropoulakis L. "Electrocardiogram (ECG) biometric authentication using pulse active ratio (PAR)". *IEEE Transactions on Information Forensics and Security*, 6(4), 1315-1322, 2011.
- [21] Gürkan H, Guz U, Yarman BS. "A novel biometric authentication approach using electrocardiogram signals". *The 35<sup>th</sup> Annual International IEEE EMBS Conference of the IEEE Engineering in Medicine and Biology Society*, Osaka, Japan, 3-7 July 2013.
- [22] Chamatidis I, Katsika A, Spathoulas G. "Using deep learning neural networks for ECG based authentication". *International Carnahan Conference on Security Technology*, Madrid, Spain, 23-26 October 2017.
- [23] Chan ADC, Hamdy MM, Badre A, Badee V. "Wavelet distance measure for person identification using electrocardiograms". *IEEE Transactions on Instrumentation and Measurement*, 57(2), 248-253, 2008.
- [24] Shen TW, Tompkins WJ, Hu YH. "Implementation of a one-lead ECG human identification system on a normal population". *Journal of Engineering and Computer Innovations*, 2(1), 12-21, 2011.
- [25] Chen CK, Lin CL, Chiu YM. "Individual identification based on chaotic electrocardiogram signals". *The 6<sup>th</sup> IEEE Conference on Industrial Electronics and Applications*, Beijing, China, 21-23 June 2011.
- [26] Lourenço A, Silva H, Fred A. "Unveiling the biometric potential of finger-based ECG signals". *Computational Intelligence and Neuroscience*, 2011, 1-8, 2011.
- [27] Singh K, Singhvi A, Pathangay V. "Dry contact fingertip ECG based authentication system using time, frequency domain features and support vector machine". *The 37<sup>th</sup> Annual International Conference of the IEEE Engineering in Medicine and Biology Society*, Milan, Italy, 25-29 August 2015.
- [28] Wieclaw L, Khoma Y, Falat P, Sabodashko D, Herasymenko V. "Biometric identification from raw ECG signals using deep learning techniques". *The 9<sup>th</sup> International Conference on Intelligent Data Acquisition and Advanced Computing Systems: Technology and Application*, Bucharest, Romania, 21-23 September 2017.
- [29] Guven G, Gürkan H, Guz U. "Biometric identification using fingertip electrocardiogram signals". *Signal, Image and Video Processing*, 12(5), 933-940, 2018.
- [30] Şeker A, Diri B, Balık HH. "Derin öğrenme yöntemleri ve uygulamaları hakkında bir inceleme". *Gazi Mühendislik Bilimleri Dergisi*, 3(3), 47-64, 2017.
- [31] Pinto CR, Cardoso JS, Lourenço A. "Evolution, current challenges and future possibilities in ECG biometrics". *IEEE Access*, 6, 34746-34776, 2018.
- [32] Lei X, Zhang Y, Lu Z. "Deep learning future representation for electrocardiogram identification". *IEEE International Conference on Digital Signal Processing*, Beijing, China, 16-18 October 2016.
- [33] Zhang Q, Zhou D, Zeng X. "HeartID: A multiresolution convolutional neural network for ECG-based biometric human identification in smart health applications". *IEEE Access*, 5, 11805-11816, 2017.
- [34] Eduardo A, Aidos H, Fred A. "ECG-based biometrics using a deep autoencoder for feature learning: An empirical study on transferability". *The 6<sup>th</sup> International Conference on Pattern Recognition Applications and Methods*, Porto, Portugal, 24-26 February 2017.
- [35] Salloum R, Kuo CCJ. "ECG-based biometrics using recurrent neural networks". *IEEE International Conference on Acoustics Speech and Signal Processing*, New Orleans, LA, USA, 5-9 March 2017.
- [36] Zhang Q, Zhou D, Zeng X. "PulsePrint: Single-arm-ECG biometric human identification using deep learning". *The 8<sup>th</sup> IEEE 8<sup>th</sup> Annual Ubiquitous Computing Electronics and Mobile Communication Conference*, New York, NY, USA, 19-21 October 2017.

- [37] Luz EJS, Moreira GJP, Oliveira LS, Schwartz WR, Menotti D. "Learning deep off-the-person heart biometrics representations". *IEEE Transactions on Information Forensics and Security*, 13(5), 1258-1270, 2018.
- [38] Labati RD, Muñoz E, Piuri V, Sassi R, Scotti F. "Deep-ECG: Convolutional neural networks for ECG biometric recognition". *Pattern Recognition Letters*, 126(1), 78-85, 2019.
- [39] Abdeldayem SS, Bourlai T. "ECG-based human authentication using high-level spectro-temporal signal features". *IEEE International Conference on Big Data*, Seattle, WA, USA, 10-13 December 2018.
- [40] Hammad M, Wang K. "Parallel score fusion of ECG and fingerprint for human authentication based on convolution neural network". *Computer & Security*, Elsevier, 81, 107-122, 2019.
- [41] Pan J, Tompkins WJ. "A real-time QRS detection algorithm". *IEEE Transactions on Biomedical Engineering*, 32(3), 230-236, 1985.
- [42] Sze V, Chen Y, Yang T, Emer JS. "Efficient processing of deep neural networks: A tutorial and survey". *Proceedings of the IEEE*, 105(12), 2295-2329, 2017.
- [43] Srivastava N, Hinton G, Krizhevsky A, Sutskever I, Salakhutdinov R. "Dropout: A simple way to prevent neural networks from overfitting". *Journal of Machine Learning Research*, 15, 1929-1958, 2014.
- [44] Moody GB, Mark RG. "The impact of the MIT-BIH arrhythmia database". *IEEE Engineering in Medicine and Biology Magazine*, 20(3), 45-50, 2001.
- [45] Goldberger AL, Amaral LAN, Glass L, Hausdorff JM, Ivanov PCh, Mark RG, Mietus JE, Moody GB, Peng CK, Stanley HE. "PhysioBank, PhysioToolkit, and PhysioNet: Components of a new research resource for complex physiologic signals". *Circulation*, 101(23), 215-220, 2000.
- [46] Physionet. "MIT-BIH Arrhythmia Database". <https://physionet.org/physiobank/database/mitdb/> (01.10.2018).
- [47] Chollet F. *Deep Learning with Python*. New York, USA, Manning Publication, 2018.
- [48] Chollet F, et al. "Keras". <https://keras.io> (01.09.2018).
- [49] Abadi M, Agarwal A, Barham P, Brevdo E, Chen Z, Citro C, Corrado GS, Davis A, Dean J, Devin M, Ghemawat S, Goodfellow I, et al. "TensorFlow: Large-scale machine learning on heterogeneous systems". <https://www.tensorflow.org/> (01.09.2018).