



## Gerçek zamanlı gömülü sistemler için rastgele orman tabanlı şok tavsiye algoritması

### A random forest-based shock advice algorithm for real-time embedded systems

Oğuzhan Çakmakoglu<sup>1</sup>, Abdullah Talha Sözer<sup>2\*</sup>

<sup>1</sup>Havelsan, Ankara, Türkiye.

oguzhancakmakoglu@hotmail.com

<sup>2</sup>Elektrik-Elektronik Mühendisliği Bölümü, Mühendislik Fakültesi, Karabük Üniversitesi, Karabük, Türkiye

talhasozer@karabuk.edu.tr

Geliş Tarihi/Received: 21.11.2024

Düzeltilme Tarihi/Revision: 05.09.2025

doi: 10.65206/pajes.58338

Kabul Tarihi/Accepted: 13.10.2025

Araştırma Makalesi/Research Article

#### Öz

Ani kalp durması (SCA), kalbin kan dolaşımını sağlayamayacak kadar etkisiz hale gelmesi durumudur. SCA'ya sebep olan en yaygın ritim bozukluklarından ikisi ventriküler fibrilasyon ve ventriküler taşikardidir. Bu ritim bozukluklarının düzeltilmesi için kalbe elektrik şoku verilmesi hayati önem taşır. Otomatik Harici Defibrilatör (AED) cihazları, hastanın kalp ritmini analiz eder ve gerektiğinde otomatik olarak elektrik şoku uygular. AED cihazı, ritim bozukluklarının tespiti için elektrokardiyogram sinyallerini toplar, şok tavsiyesi algoritmaları (SAA) ile hastaya şok verilip verilmeyeceğine karar verir. Ancak AED'de yürütülecek bir SAA geliştirme süreci, gömülü sistemlerin sınırlı veri işleme kapasitesi gibi bazı zorluklar barındırmaktadır. Algoritma gömülü sistemde çalışacağı için kısıtlı veri işleme kabiliyeti olan bir ortamda kalp ritimlerini başarıyla ayırt edebilecek nitelikte olmalıdır. Mevcut çalışmalar incelendiğinde, eşik tabanlı ya da makine öğrenmesi (ML) temelli SAA'ların bulunduğu ve birçok ML tabanlı SAA'nın yüksek sınıflandırma başarısı sunduğu görülmektedir. Ancak, bu algoritmaların yalnızca küçük bir kısmı gerçek zamanlı gömülü sistemlerde test edilmiş ve AED cihazlarına uygunluğu değerlendirilmiştir. Bu çalışmada, halka açık bir veri seti kullanılarak, geleneksel bir ML yöntemi olan rastgele orman ile SAA geliştirilmiştir. Önerilen algoritma, şok uygulanabilir ritimlerde %92.9 duyarlılık ve şok uygulanmaması gereken ritimlerde %99.2 özgüllük değerleri sağlamıştır. Yüksek seviye programlama dili ile geliştirilen SAA, C diline entegre edilerek mikrodenetleyici tabanlı bir geliştirme kitinde test edilmiştir. 500 kB bellek ihtiyacı ve 75 mikro saniyelik tespit süresi ile algoritmanın AED cihazlarında kullanımı için uygun olduğu ve başarıyla entegre edilebileceği kanıtlanmıştır.

**Anahtar kelimeler:** AED, Şok Tavsiyesi Algoritması, Makine Öğrenmesi

#### Abstract

Sudden cardiac arrest (SCA) occurs when the heart becomes unable to pump blood effectively. One of the most common arrhythmias that cause SCA are ventricular fibrillation and ventricular tachycardia. Treating these arrhythmias through defibrillation—delivering an electric shock to the heart—is vital for patient survival. Automated External Defibrillators (AEDs) analyze the patient's heart rhythm and automatically deliver a shock when necessary. To do this, AEDs collect electrocardiogram (ECG) signals and use shock advisory algorithms (SAAs) to decide whether a shock is required. However, the development of SAAs suitable for AEDs involves challenges, such as the limited data processing capacity of embedded systems. The algorithm must be capable of reliably distinguishing heart rhythms in such constrained environments. A review of existing studies reveals both threshold-based and machine learning (ML)-based SAAs, with many ML-based algorithms demonstrating high classification performance. Yet, only a small fraction of these algorithms have been tested in real-time embedded systems, and their applicability to AED devices has been evaluated in limited contexts. In this study, a traditional ML-based SAA was developed using the random forest method and evaluated with a publicly available dataset. The proposed algorithm achieved 92.9% sensitivity for shockable rhythms and 99.2% specificity for non-shockable rhythms. Initially developed in a high-level programming language, the SAA was integrated into C and tested on a microcontroller-based development kit. With a memory requirement of 500 kB and a detection time of 75 microseconds, the algorithm was shown to be suitable for implementation in AED devices, demonstrating its potential for commercial use.

**Keywords:** AED, Shock Advice Algorithm, Machine Learning

## 1 Giriş

Ani kalp durması (SCA, Sudden Cardiac Arrest), kalbin kan dolaşımını sağlayamayacak kadar etkisiz hale gelmesi durumudur. Kalp yeterli kan pompalama işlevi sağlayamaz, bu nedenle dolaşım ve bilinç kaybı olur. Duruma acil müdahale edilmezse ölüm riski yüksektir. Dünya genelinde her yıl milyonlarca kişi ani kalp durması nedeniyle hayatını kaybetmektedir. Örneğin, Amerika Birleşik Devletleri'nde her yıl yaklaşık 350000 kişi ani kalp durması yaşamaktadır [1].

SCA'nın sebeplerinden biri de kalbin normal ritimden çıkarak ventriküller fibrilasyon (VF) ya da ventriküller taşikardi (VT)

gibi ritim bozuklukları yaşamasıdır. Bu durumda kalp etkili bir şekilde kan pompalayamaz ve bu durum genellikle birkaç dakika içinde kalbin durması ile sonuçlanır. Defibrilasyon müdahalesi ile bu ritim bozukluklarının düzeltilmesi hayati önem taşır. Defibrilasyon, kalpteki VT ve VF ritim bozukluklarını düzeltmek amacıyla kalbe elektrik şoku verilmesi işlemidir. Defibrilasyon işlemi sırasında kalbe verilen elektrik şoku, geçici olarak kalbin elektriksiz aktivitesini durdurur. Bu VT ve VF ritimlerini sona erdirir ve kalbe, normal ritmini yeniden başlatma şansı verir [2]. Defibrilasyon işlemi, manuel defibrilatörler veya Otomatik Harici Defibrilatör (AED) cihazları ile yapılır. Defibrilatörler profesyonel kullanıma yönelik manuel kontrol gerektiren cihazlar iken AED cihazları,

\*Yazışılan yazar/Corresponding author

hastane dışı acil durumlar için geliştirilmiş olup, eğitilmiş ya da eğitimsiz kişiler tarafından kullanılabilir. AED cihazları, otomatik olarak hastanın kalp ritmini analiz eder ve sadece gerektiğinde şok verir. Kullanıcıya sesli ve görsel talimatlar sunar, böylece tıbbi bilgiye sahip olmayan kişiler bile acil durumlarda bu cihazı kullanabilir. Bu durum, AED cihazının kamusal alanlarında yaygınlaştırılmasını, spor kompleksleri, alışveriş merkezleri, acil toplanma alanları gibi halka açık alanlarda ulaşılabilir durumda olmasını teşvik etmektedir. Yaygınlaşmanın okulları da kapsamı beklenmektedir [3].

Ritim bozukluklarının tespiti için elektrokardiyogram (EKG) sinyalleri toplanır. Birtakım ön işleme adımının ardından sinyallerden R-R aralığı süresi, güç spectral yoğunluğu gibi VT ve VF ritimlerini tanımlayan öz nitelikler elde edilir. Elde edilen öz nitelikler kullanılarak eşik veya makine öğrenmesi (ML) temelli yaklaşımlar ile hastaya şok verilip verilmeyeceğine karar verilir. Eşik temelli şok tavsiyesi algoritmalarında (SAA), incelenen EKG sinyalinde VT ve VF ritimlerinin varlığı, ona özgü bir eşikle karşılaştırılarak belirlenmektedir. VF filtresi, standart üstel algoritma, değiştirilmiş üstel algoritma, karmaşıklık ölçüsü algoritması, eşik geçiş aralıkları algoritması, oto-korelasyon algoritması ve spektral algoritma gibi eşik temelli SAA'lar geliştirilmiştir [4]. Eşik tabanlı SAA için en önemli avantaj, yalnızca bir veya birkaç parametre ve uygun eşiklerle sağlanan basitliktir. Ancak sundukları tespit başarısı sebebi ile eşik tabanlı SAA'nın gerçek zamanlı verilerle pratik AED için uygulandığında güvenilir olduğunu söylemek zordur [5]. ML temelli yöntemler geleneksel ML ve Deep learning (DL) temelli olmak üzere iki sınıfta incelenebilir. Geleneksel ML temelli SAA için temel ilke, çoğunlukla girişine verilen öz niteliklerin istatistiksel ilişkilerini analiz edip, bu bilgiyi kullanarak şok verilebilir ve verilemez ritimleri doğru sınıflara ayırmayı amaçlayan bir model oluşturmaktır. DL temelli SAA'lar ise şok tavsiyesi için çoğunlukla EKG sinyalinden otomatik olarak öz nitelik çıkarımı yapar ve EKG sinyali ile ritim sınıfları arasındaki ilişkiyi gösteren bir model türetir. ML temelli yaklaşımlar yüksek tespit başarısı sunmaktadır [5], [6].

Geliştirilen bir SCA'nın ticari bir üründe uygulanmasında bazı kısıtlar bulunmaktadır. Algoritma, şok uygulanabilir ve uygulanamaz ritimleri yüksek bir başarı seviyesinde ayırt edebilmelidir. Amerikan Kalp Derneği (AHA) tarafından şok gerektiren ritimler için %90'ın üzerinde bir duyarlılık, şok uygulanmaması gereken ritimler için %95'in üzerinde özgüllük ve normal sinüs ritimleri durumunda ise %99'un üzerinde bir özgüllük tavsiye edilmektedir [7]. Diğer önemli bir kısıt ise SAA'nın koşturulacağı gömülü sistemin veri işleme kabiliyeti, dolayısıyla maliyeti ile ilgilidir. SAA'nın hızlı bir şekilde incelenen kalp ritminin sınıfına karar vermesi gerektiğinden, algoritmaların işlem süresi büyük öneme sahiptir. Eşik temelli yöntemler genellikle az hesap yüküne ihtiyaç duyması sebebiyle daha hızlıdır ve ticari bir ürün için uygun görünmekle beraber tavsiye edilen başarı ölçütüne ulaşmak zor olabilir [5]. ML temelli yaklaşımlar ile yüksek tespit elde edilebilmesine rağmen bunlar daha fazla hesaplama gücü gerektirebilir. Bu durum ise daha güçlü bir işlemciye ihtiyacı doğurmakta, maliyet artırmaktadır. Bunun yanında enerji sarfiyatı da artmaktadır. Modelin boyutu sebebiyle bellek ihtiyacı da göz önüne alınmalıdır. Bu kısıtlar makine öğrenmesi temelli SAA'ların gerçek zamanlı uygulamasını güçleştirmektedir. AED cihazlarının yaygınlaşacağı da göz önüne alındığında yüksek tespit başarısıyla beraber ve düşük maliyetli gömülü sistemlere uygun SAA'lar önem kazanmaktadır.

Mevcut çalışmalar incelendiğinde şok uygulanabilir ve uygulanamaz ritimleri tespit edebilmek için çok sayıda makine öğrenmesi temelli SAA önerildiği görülmektedir. Çalışmalarda yüksek başarılar yakalanmış olmasına rağmen önerilen algoritmalarından çok azının gerçek zamanlı olarak gömülü sistemde test edildiği, uygunluğunun araştırıldığı göze çarpmaktadır. Fahimeh ve ark. şok uygulanabilir ve uygulanamaz kalp ritimlerini ayırt etmek için bir düşük maliyetli derin öğrenme algoritması geliştirmişlerdir. Halka açık veri setlerinde yüksek başarı seviyesi ulaşan algoritma Raspberry Pi mikrobilgisayar üzerinde de test edilmiş ve yöntemin AED cihazları için uygulanabilir olduğu gösterilmiştir [8]. Raspberry Pi mikrobilgisayarda test edilen diğer bir çalışmada ise araştırmacılar geleneksel makine öğrenmesi ile EKG sinyallerini sınıflandırmışlardır [9]. Andrés ve ark. ise geleneksel makine öğrenmesi temelli yöntemlerini hem FPGA'da hem 32-bit ARM Cortex M4 mikrodenetleyicide uygulamış ve yüksek başarı elde ettiklerini ifade etmişlerdir [10]. Düşük maliyetli bir çözümün AED cihazlarının yaygınlaşması için önemli bir kistas olduğu dikkate alındığında FPGA ve Raspberry Pi mikrobilgisayar kullanımının uygun bir çözüm olmadığı söylenebilir. AHA tarafından beklenen başarı seviyesine ulaşan mikrodenetleyicide koşturulan bilen bir SAA ticari uygulamalar için daha uygun bir çözümdür.

Bu çalışmada halka açık bir veri seti kullanılarak şok uygulanabilir ve uygulanamaz kalp ritimlerinin tespiti için bir geleneksel ML temelli SAA geliştirilmiştir. Rastgele orman (RF) yaklaşımı ile ritimleri ayırt eden yöntem düşük hesap maliyetine sahipken AHA doğruluk standartlarını da karşılamaktadır. Ayrıca yöntem bir mikrodenetleyicide test edilmiş ve AED cihazları için uygulanabilir olduğu gösterilmiştir. Çalışmanın ana katkıları aşağıdaki gibi özetlenebilir:

- ✓ Düşük hesaplama maliyeti olan, AED cihazlarının kısıtlı donanıma sahip mikrodenetleyicileri için uygun SAA geliştirilmiştir.
- ✓ Yüksek seviye programlama dili ile geliştirilen SAA'nın gömülü sistemlerde çalışması için C dilinde entegrasyonu yapılmıştır.
- ✓ AED cihazları için uygun mikrodenetleyici içeren bir geliştirme kiti üzerinde testler gerçekleştirilmiş ve yöntemin uygulanabilirliği gösterilmiştir.


Materyal metot bölümünde kalp ritimlerinin morfolojisi, veri seti, önerilen SAA ve değerlendirme ölçütleri sunulacaktır. Deneysel sonuçlar bölümünde bilgisayarda ve gömülü sistemde elde edilen sonuçlara yer verilecektir. Tartışma ve sonuç bölümünde sonuçlar değerlendirilecek, çalışmanın kısıtları sunulacak ve gelecek çalışma önerileri ile sonlandırılacaktır.

## 2 Materyal & Metot

### 2.1 Şoklanabilir ve şoklanamaz EKG sinyallerinin morfolojisi

Sağlıklı bir kalbe ait EKG sinyalinde P-QRS-T tepelerinin belirgin olduğu normal sinüs ritmi (NSR) gözlenirken, kalp rahatsızlığı durumunda aritmler ortaya çıkar. Aritmi, kalbin normal ritminden sapma durumunu ifade eder. Kalbin atış hızı, ritmi veya her ikisindeki düzensizlikler aritmi olarak adlandırılır. Bazı aritmi türlerinde şok uygulamak gerekirken; normal sinüs, atriyal fibrilasyon, asistol gibi bazı ritimlerde şoktan kaçınmak gerekmektedir. AHA tarafından şoklanabilir ve şoklanamaz kalp ritimleri tanımlanmıştır [11]. AED cihazları,

Lead-II üzerinden alınan EKG sinyalinden şok uygulanabilir ve uygulanamaz ritimleri tespit eder. Şekil 1'de bazı kalp ritimleri görülmektedir.



Şekil 1. Şok uygulanabilir (VT, VF) ve şok uygulanamaz (NSR) ritimler [12].

Figure 1. Shockable (VT, VF) and non-shockable (NSR) rhythms [12].

VT, genellikle 100-250 atım/dakika aralığında bir kalp hızı ile karakterize edilir ve ventriküllerin kasılma süresi 30 saniye veya daha uzun sürerse hayati tehlike oluşturabilir; VF ise düzensiz elektriksel aktivite ile 300 atım/dakika ve üzeri bir hızda görülür, bu da kanın etkili pompalamasını engeller.

## 2.2 Veri seti

SAA'nın geliştirilmesi için genellikle ventriküller bozuklukları olan hastaları sürekli olarak izleyen Holter cihazları aracılığı ile elde edilen açık kaynak EKG veri setleri ve kalp krizi geçiren hastalardan AED'ler tarafından kaydedilen sinyallerin bulunduğu OHCA veri setleri mevcuttur. Çalışmada, araştırmacılar tarafından sıklıkla tercih edilmesi, sinyal kalitesinin yüksek olması, uzmanlar tarafından detaylı bir şekilde etiketlenmiş olması sebebiyle açık kaynaklı MIT-BIH Arrhythmia veri seti kullanılmıştır. Veri seti 48 adet 30 dakika uzunluğunda sinyaller barındırmaktadır. Set uzmanlar tarafından etiketlenmiştir ve sette birçok farklı ritim mevcuttur [13], [14].

Çalışmada NSR ve VT sinyalleri önerilen SAA'nın geliştirilmesinde kullanılmıştır. Veri setinde 61 adet VT etiketli ritim varken VF etiketlerinin sayısı birkaç ile sınırlı kaldığı için çalışmada VF ritimleri göz ardı edilmiştir.

## 2.3 Önerilen SAA


Önerilen algoritma gerçek zamanlı gömülü sistemlerde yürütüleceği için akan sinyal işlemeye uygun olarak tasarlanmıştır. Bu bağlamda, sinyal sabit uzunluklu pencere ile değerlendirilmekte, ancak pencere zaman boyunca kaydırılarak sürekli olarak güncellenmektedir. Bu durumda algoritma VT ve NSR ritimlerinin zamanda kaymış olan biçimleri ile de karşılaşmaktadır.

Önerilen SAA, VT ve NSR ritimlerini tespit için sinyalin örnek değerlerinden faydalanmaktadır. Zamanda kaymış biçimlerin doğru tespit edilebilmesi için sınıflama adımı öncesinde

hizalama işlemi uygulanmıştır. Her pencerenin başlangıcından itibaren bir ön kesitte (örneğin ilk 1 saniyede) tespit edilen tepe noktası referans alınmış, sinyaller bu noktaya göre hizalanarak sınıflandırıcıya verilmiştir.

Ritimleri sınıflandırmak için geleneksel ML yöntemlerinden RF tercih edilmiştir. RF birden çok karar ağacından oluşan bir topluluk makine öğrenmesi yöntemidir. RF gürültüye ve aşırı uyumlara karşı dirençli olması ve gömülü sistemlerde görece kolay uygulanabilmesi sebebiyle tercih edilmiştir [15]. Model Python ortamında geliştirilmiştir.

RF modeli hizalanmış ritimler ile eğitilmiştir 30 dakikalık EKG sinyallerinde VT veya NSR etiketi görüldüğünde, ilgili andan itibaren 1 saniyelik kesitteki tepe noktası tespit edilmiştir. Tepenin 0.75 saniye öncesi ve 1.25 saniye sonrası alınarak 2 saniyelik hizalanmış ritim elde edilmiştir. Çalışmada 3, 4, 5 saniyelik ritimler tercih edilmesine [16] rağmen bu çalışmada veri tabanındaki birçok VT ritminin kısa olması sebebiyle 2 saniyelik pencereler kullanılmıştır. Pencereler, ritmin sonuna kadar 1 saniyelik adımlarla kaydırılarak aynı işlemler tekrarlanmıştır. Bu yöntemle VT ritmi içeren 186, NSR ritmi içeren 506 pencere elde edilmiştir.



Şekil 2. Pencere kaydırma ile hizalanmış sinyallerin elde edilmesi. Uzman tarafından belirlenen VT ritminin başlangıç anı, kesikli çizgi ile gösterilmiştir. Sinyaller tepe noktası çevresinde hizalanmıştır.

Figure 2. Obtaining signals aligned by window shifting. The onset of the VT rhythm determined by the expert is shown with a dashed line. The signals are aligned around the peak point.

RF modelinin eğitiminde sinyalin örnek değerleri kullanılmıştır. Eğitim ve test aşamasında modelin farklı veri bölümlerinde genel performansını değerlendirmek ve aşırı uyumu azaltmak için 5 katlı çapraz doğrulama kullanılmıştır. Ağaçlara bir düğüm sınırı konulmamakla beraber modeldeki ağaç sayısı değiştirilerek performansı incelenmiştir. Ağaç sayısının artması, modelin doğruluğunu artırabilir, ancak bu durum işlem yükünü de yükseltir. Bu nedenle, gömülü yazılımda kullanılabilirliği sağlamak amacıyla, işlem yükü ve doğruluk arasında bir denge kurmak için en uygun ağaç sayısı araştırılmıştır.

## 2.4 Değerlendirme ölçütleri

AED cihazlarının performansını değerlendirmek için en sık kullanılan ölçütler özgüllük ve duyarlılıktır. Duyarlılık, cihazın VT gibi şok gerektiren durumları doğru bir şekilde tanımlayıp bu anlarda şok önerme oranını ifade eder. Yüksek bir duyarlılık, şok gerektiren acil durumların gözden kaçma olasılığının düşük olduğunu gösterir. Özgüllük ise cihazın, şok gerekmeyen durumlarda şok önerisinde bulunmama oranıdır. Yüksek

özellik, AED'nin yalnızca gerçekten ihtiyaç duyulduğunda şok tavsiyesi verdiğini, böylece gereksiz şokları önleyerek hasta güvenliğini sağladığını gösterir [17]. Duyarlılık ve özellik denklemleri aşağıdaki gibidir.

$$\text{Duyarlılık} = \frac{TP}{TP + FN} \quad (1)$$

$$\text{Özellik} = \frac{TN}{TN + FP} \quad (2)$$

$$\text{Dengeli doğruluk} = \frac{\text{Duyarlılık} + \text{Özellik}}{2} \quad (3)$$


Burada TP şok gerektiren sinyal için şok tavsiyesini; TN şok gerektirmeyen sinyal için şok tavsiye edilmemesini; FP şok gerektirmeyen sinyal için şok tavsiyesini; FN şok gerektiren bir sinyal için şok tavsiye edilmemesini ifade eder.

Ayrıca yukarıda bahsedildiği gibi SAA'nın karar vermesi için gereken süre de uygulanabilirliği için önemli bir kısıt olduğu için önerilen SAA'nın gömülü sistemde koşturulma hızı da değerlendirilecektir.

## 2.5 Gömülü sistem

AED cihazında hassas seviyede analog sinyal okuma ve hızlı işlem gücü gereksinimleri göz önünde bulundurulduğunda seçilecek mikrodenetleyicinin işlemci frekansı, veri yolu genişliği, ADC çözünürlüğü önem kazanmaktadır. Seçimde AED'deki gömülü yazılımın ve SAA'nın bellek ihtiyacı da göz önüne alınmalıdır.

Yukarıdakilerle beraber fiyat, ulaşılabilirlik da göz önüne alınarak 180 MHz Arm Cortex M4, 32-bit veri yolu, 12-bit ADC çözünürlüğü ve 2 Mbyte flaş hafızaya sahip STM32F429ZI mikrodenetleyicisini barındıran Şekil 'te görülen NUCLEO-F429ZI [18] geliştirme modülünde önerilen SAA'nın performansı test edilmiştir.





Şekil 3. NUCLEO-F429ZI geliştirme modülü.

Figure 3. NUCLEO-F429ZI development board.

## 3 Deneyisel sonuçlar


Önerilen SAA, ritimleri sınıflandırmak için RF makine öğrenmesi metodu kullanmaktadır. Farklı ağaç sayıları ile elde edilen model başarısı Şekil 'te görülmektedir. Şekilde SSA'nın sınıflandırma başarısı, şok uygulanmaması gereken NSR ve şok uygulanabilir ritimler olan VT'leri tespit başarısı gösterilmiştir. Modelin 15 ve 50 ağaç ile dengeli doğruluğunun %96'yı geçtiği, 50 ağaç ile özelliğün %99'a ulaştığı gözlemlenmektedir.

Ağaç sayısının artması hesaplama maliyetini yükseltmekle birlikte, şekilde görüldüğü ağaç sayısı ile model başarısı arasında doğrusal bir ilişki gözlenmemiştir. AHA tarafından tavsiye edilen %90 seviyesindeki VT tespit başarısına kolaylıkla ulaşılmaktadır. Bununla beraber %99 seviyesindeki NSR tespit başarısına ise 50 ağaçda ulaşıldığı görülmektedir. 50 ve 60 arası ağaç ile modelin başarısı tekrar incelendiğinde



Şekil 4. Ağaç sayısı ile model başarısının değişimi. (a) Ağaç sayısı ile dengeli doğruluk arasındaki ilişki (b) Ağaç sayısı ile duyarlılık arasındaki ilişki (c) Ağaç sayısı ile özellik arasındaki ilişki.


Figure 4. Variation of model performance with number of trees. (a) Relationship between number of trees and balanced accuracy (b) Relationship between number of trees and sensitivity (c) Relationship between number of trees and specificity.



Şekil 3. Ağaç sayısı ile model özgüllüğünün değişimi.

Figure 5. Change in model specificity with the number of trees.


Şekil 4'da 57 ağaçlı model ile elde edilen hata matrisi sunulmuştur. Elde edilen %92.9 duyarlılık, %99.2 özgüllük ve %96.1 dengeli doğruluk ile AHA standartları karşılanmıştır.



Şekil 4. Önerilen SAA için hata matrisi.


Figure 6. Error matrix for the proposed SAA.

Önerilen SAA'nın gürültüye karşı dayanıklılığını görmek için sinyallere farklı sinyal gürültü oranı (SNR) seviyelerinde yapay gürültü eklenmiş ve performansı test edilmiştir. Bu sayede gerçek ortamlarda karşılaşılabilecek ölçüm hataları, kas artefaktları veya elektromanyetik parazit gibi bozucu etkilere karşı algoritmanın hassasiyet ve özgüllüğündeki değişim gözlemlenmiştir. Şekil 7'de gürültülü VT ritmi sunulmuştur.



Şekil 5. (a) VT ritmi içeren sinyal, (b) SNR=3 dB gürültülü hali.

Figure 7. (a) VT rhythm signal, (b) noisy version at SNR=3 dB.



Şekil 6. Farklı SNR seviyeleri için elde edilen performans.


Figure 8. Performance obtained for different SNR levels.

Şekil 8'den görüldüğü gibi önerilen algoritmanın NSR ritimlerini tespit etme başarısı gürültüden etkilenmez iken VT ritimlerinin doğru tespiti gürültü seviyesinin artması ile düşmektedir.

Gömülü sistemde performansının incelenebilmesi için önerilen SAA C dilinde yeniden derlenmiştir. 57 adet karar ağacına sahip olan model yaklaşık 532 KB yer kaplarken, 200 adet karar ağacına sahip olan model yaklaşık 1.9 MB yer kaplamıştır. 200 karar ağacı barındıran model daha fazla yer kaplamasına rağmen Şekil 7'te görüldüğü üzere model başarısı daha yüksek değildir. C diline uyarlanan modelin test edilmesi için veri setindeki sinyaller gömülü sisteme verilmiştir. 5 saniyelik sinyal yaklaşık 13 kB yer kaplamaktadır. Gömülü sistemde koşturulan SAA ile elde edilen sonuçlar ve karar verme süresi seri port aracılığı ile bilgisayarda gözlemlenmiştir. Gömülü sistemde elde edilen model doğruluğu, kişisel bilgisayardaki ile aynıdır. 57 ağaçlı modelde VT ritimleri için tespit süresi ortalama 60 mikro saniye iken NSR ritimleri için tespit süresi ortalama 75 mikro saniyedir. 200 ağaçlı modelde VT ritimleri için tespit süresi ortalama 210 mikro saniye iken NSR ritimleri için tespit süresi ortalama 256 mikro saniyedir. Şekil 7'de 200 ağaçlı model koşturulurken elde edilen tespit sonuçları ve süreleri gösterilmiştir.

#### 4 Tartışma ve sonuç

SCA yaşayan bireylerin hayatta kalma şansını artırmak için AED cihazlarının yaygınlaşması hayati önem taşımaktadır. AED cihazlarının spor kompleksleri, alışveriş merkezleri, okullar gibi halka açık alanlara yaygınlaşabilmesi için yüksek maliyete sahip olmaması gerekmektedir. Şok uygulanabilir ve uygulanamaz ritimleri ayırt etmek için geliştirilen ML temelli SSA'lar yüksek tespit başarısı sağlamaktadır. Ancak çalışmalar incelendiğinde önerilen yöntemlerin hesaplama maliyetini dikkate almadıkları görülmektedir. Literatürdeki birçok çözüm, yüksek hesaplama gücü gerektirdiği için gerçek zamanlı ve düşük maliyetli gömülü sistemlerde kullanıma uygun değildir. Ayrıca çözümlerin çok küçük bir kısmı gömülü sistemde test edilmiştir.



Şekil 7. Seri porttan alınan model sonuçları ve tespit süreleri.

Figure 9. Model results and detection times from the serial port.

Bu eksikliği gidermek amacıyla, düşük hesaplama maliyetine sahip geleneksel ML temelli SAA önerilmiştir. Yöntem gömülü sistemlere kolaylık ile uyarlanabilen bir sınıflandırıcı olan RF modelini kullanmaktadır. Model halka açık bir veri setinde geliştirilmiş ve AHA standartlarının üstünde tespit başarısı sunmuştur. Ardından model C dilinde derlenerek mikrodenetleyici platformunda test edilmiştir. Gömülü sistemde de ritimler başarı ile sınıflandırılmakla beraber tespit süresinin çok kısa olduğu ve bellek ihtiyacının küçük olduğu gösterilmiştir.

Deneysel sonuçlar incelendiğinde RF metodunda kullanılan ağaç sayısının artması tespit başarısını çok az artırmakta iken gömülü sistemde ihtiyaç duyulan belleği ve tespit süresini kayda değer olarak artırmaktadır. Önerilen SAA için en uygun ağaç sayısı tespiti ile küçük boyutlu, AHA standartlarında doğruluk sağlayan, çok hızlı tespit yapan yöntem elde edilmiştir. Bu sonuçlara göre önerilen yöntemin daha az maliyetli mikrodenetleyiciler için de uygun olduğu söylenebilir.

Literatürde gömülü sistemde test edilen ML temelli SAA sayılı olmakla beraber FPGA ve Raspberry Pi sistemleri düşük maliyetli çözümler için uygun değildir. Araştırmalarımızda mikrodenetleyicide test edilmiş yalnız iki ML temelli SAA'ya rastlanmıştır. Tablo 1'de önerilen yöntem ile mikrodenetleyicide test edilen diğer yöntem kıyaslanmaktadır.

Tablo 1. SAA'ların başarı kıyaslaması

Table 1. Performance comparison of SAAs

| Çalışma  | Veri seti | İşlemci              | ML modeli | Doğruluk (%) | Tespit süresi (ms) |
|----------|-----------|----------------------|-----------|--------------|--------------------|
| [10]     | [19],[20] | 32-bit Arm Cortex m4 | SVM       | %99          | 30                 |
| [10]     | [19],[20] | 32-bit Arm Cortex m4 | ANN       | %99          | 0.6                |
| Önerilen | [13]      | 32-bit Arm Cortex m4 | RF        | %94.7        | 0.065              |

Tablo incelendiğinde diğer yöntemlerin yüksek doğruluk sağladığı görülmektedir. Ancak farklı veri setleri kullanıldığı göz önüne alınmalıdır. Önerilen SAA çok kısa tespit süresi ile öne çıkmaktadır. EKG ölçümlerinde örnekleme periyodunun bu

rakamdan çok daha fazla olduğu düşünülürse önerilen yöntemin gerçek-zamanlı tespit yaptığı söylenebilir.

Çalışmanın başlıca kısıtı kullanılan veri seti ile ilgilidir. Çalışmada RF modeli NSR ve VT ritimleri ile eğitilmiştir. Şok uygulanan VF ve şok uygulanmaması gereken NSR harici ritimlerin de modelin eğitiminde kullanılması, gömülü sistemlere uygun ML temelli SAA geliştirilmesi için önemlidir. Farklı veri setlerinin bir arada kullanılması ile ritim çeşitliliği artırılabilir. Ayrıca hastaların kadın-erkek, genç-yaşlı gibi sınıflara ayrılması ve modelin bu doğrultuda eğitilmesi, tespit güvenilirliğini arttıracaktır. Diğer bir kısıtın da modelin gürültüye karşı dayanıklılığı olduğu söylenebilir. Deneysel sonuçlardan da görüldüğü gibi gürültü seviyesinin artması ile VT ritimlerinin sınıflandırma başarısı AHA standartlarının altına düşmüştür. Gürültünün VT ritimlerinin morfolojisine etkisinin daha fazla incelenmesi, ön işleme tekniklerinden faydalanılması gerekmektedir. Bu kısıtlar sebebiyle, modelin klinik koşullara genellenmesi sınırlı olduğu söylenebilir.

Sonuç olarak RF algoritması temelli SAA'lar, sağladıkları yüksek doğruluk ve hızlı cevap süresi sayesinde AED cihazlarının düşük maliyetli işlemcileri için uygun bir alternatiftir.

## 5 Discussion and conclusion

The widespread availability of AED devices is crucial for improving the survival rates of individuals experiencing SCA. To ensure the deployment of AEDs in public areas such as sports complexes, shopping malls, and schools, these devices must be cost-effective. ML-based SAAs developed to differentiate between shockable and non-shockable rhythms demonstrate high detection accuracy. However, a review of existing studies reveals that many proposed methods do not consider computational cost. Most solutions in the literature are unsuitable for real-time, low-cost embedded systems due to their high computational requirements. Furthermore, only a small fraction of these solutions has been tested on embedded systems.

To address this gap, a traditional ML-based SAA with low computational cost is proposed. The method employs an RF classifier, which is well-suited for adaptation to embedded systems. The model was developed using a publicly available dataset and achieved detection performance exceeding the standards of the AHA. The model was subsequently compiled in C and tested on a microcontroller platform. Experimental results demonstrated successful classification of rhythms in the embedded system, along with very short detection times and minimal memory requirements.

An analysis of the experimental results shows that increasing the number of trees in the RF model slightly improves detection performance but significantly increases memory requirements and detection time on the embedded system. By optimizing the number of trees, the proposed SAA achieves a small size, AHA-standard accuracy, and rapid detection times. These findings suggest that the proposed method is also suitable for less costly microcontrollers.

Table 1. Performance comparison of SAAs

| Study    | Dataset   | Processor            | ML model | Accuracy (%) | Detection time (ms) |
|----------|-----------|----------------------|----------|--------------|---------------------|
| [10]     | [19],[20] | 32-bit Arm Cortex m4 | SVM      | %99          | 30                  |
| [10]     | [19],[20] | 32-bit Arm Cortex m4 | ANN      | %99          | 0.6                 |
| Proposed | [13]      | 32-bit Arm Cortex m4 | RF       | %94.7        | 0.065               |

Although the number of ML-based SAAs tested on embedded systems in the literature is limited, FPGA and Raspberry Pi platforms are not ideal for low-cost solutions. In our research, only two ML-based SAAs were identified as having been tested on microcontrollers. Table 1 compares the proposed method with other microcontroller-tested methods.

The table indicates that other methods achieve high accuracy, although differences in datasets must be considered. The proposed SAA stands out with its extremely short detection time. Considering that the sampling period for ECG measurements is much longer than this detection time, the proposed method can be classified as a real-time solution.

The main limitation of this study concerns the dataset used. The RF model was trained with NSR and VT rhythms. Including VF rhythms (requiring shock) and non-NSR rhythms (not requiring shock) in the model's training process is essential for developing ML-based SAAs suitable for embedded systems. Using a combination of different datasets could increase rhythm diversity. Additionally, categorizing patients by factors such as gender and age and training the model accordingly would enhance detection reliability.

In conclusion, ML-based SAAs are promising alternatives for AED devices equipped with low-cost processors due to their high accuracy and rapid response times.

## 6 Yazar katkı beyanı

Gerçekleştirilen çalışmada Yazar 1 fikrin oluşması, literatür taraması, tasarımın yapılması ve deneylerin gerçekleştirilmesi başlıklarında; Yazar 2 deneylerin gerçekleştirilmesi, elde edilen sonuçların değerlendirilmesi, eleştirel inceleme, literatür taraması ve makale yazılması başlıklarında katkı sunmuşlardır.

## 7 Etik kurul onayı ve çıkar çatışması beyanı

Hazırlanan makalede etik kurul izni alınmasına gerek yoktur.

Hazırlanan makalede herhangi bir kişi/kurum ile çıkar çatışması bulunmamaktadır.

## 8 Kaynaklar

- [1] American Heart Association. "Heart Attack and Sudden Cardiac Arrest Differences". <https://www.heart.org/en/health-topics/heart-attack/about-heart-attacks/heart-attack-or-sudden-cardiac-arrest-how-are-they-different> (10.11.2024).
- [2] American Heart Association. "Arrhythmias". <https://watchlearnlive.heart.org/index.php?moduleSelect=arrhyt> (10.11.2024).
- [3] Congress.gov. "H. Rept. 118-520 - Cardiomyopathy Health Education, Awareness, And Research, And Aed Training In The Schools Act Of 2024". <https://www.congress.gov/congressional-report/118th-congress/house-report/520/1> (10.11.2024).

- [4] Acharya R, Fujita H, Oh S, Raghavendra U, Tan J, Adam M, Gertych A, Hagiwara Y. "Automated identification of shockable and non-shockable life-threatening ventricular arrhythmias using convolutional neural network". *Future Generation Computer Systems*, 79, 952-959, 2018.
- [5] Nguyen M, Nguyen T, Le H. "A review of progress and an advanced method for shock advice algorithms in automated external defibrillators". *BioMedical Engineering Online*, 21, 2022.
- [6] Gurkan H, Hanilci A. "ECG based biometric identification method using QRS images and convolutional neural network". *Pamukkale University Journal of Engineering Sciences*, 26, 2, 318-327, 2020.
- [7] Figuera C, Irusta U, Morgado E, Aramendi E, Ayala U, Wik L, Kramer-Johansen J, Eftestøl T, Alonso-Atienza F. "Machine learning techniques for the detection of shockable rhythms in automated external defibrillators". *PLoS One*, 11, 7, 2016.
- [8] Nasimi F, Yazdchi M. "LDIAED: A lightweight deep learning algorithm implementable on automated external defibrillators". *PLoS One*, 17, 2, 2022.
- [9] Khadar S, Tabatabaey-Mashadi N, Daliri G. "A simple realtime algorithm for automatic external defibrillator". *Biomedical Signal Processing and Control*, 51, 277-284, 2019.
- [10] Orozco-Duque A, Rúa S, Zuluaga S, Redondo A, Restrepo J, Bustamante J. "Support vector machine and artificial neural network implementation in embedded systems for real time arrhythmias detection". *BIO SIGNALS 2013- Proceedings of the International Conference on Bio-Inspired Systems and Signal Processing*, 310-313, 2013.
- [11] American Heart Association. "What is an Arrhythmia". <https://www.heart.org/en/health-topics/arrhythmia/about-arrhythmia> (10.11.2024).
- [12] Krasteva V, Ménétré S, Didon J, Jekova I. "Fully convolutional deep neural networks with optimized hyperparameters for detection of shockable and non-shockable rhythms". *Sensors (Switzerland)*, 20, 10, 2020.
- [13] Moody G, Mark R. "The impact of the MIT-BIH arrhythmia database". *IEEE Engineering in Medicine and Biology Magazine*, 20, 3, 45-50, 2001.
- [14] Moody G, Mark R. "MIT-BIH Arrhythmia Database". <https://physionet.org/content/mitdb/1.0.0/> (10.11.2024).
- [15] Tripathy R, Sharma L, Dandapat S. "Detection of Shockable Ventricular Arrhythmia using Variational Mode Decomposition". *Journal of Medical Systems*, 40, 4, 1-13, 2016.
- [16] Nam D, Kang D, Myoung H, Lee K. "Detection method for shockable rhythm based on a single feature". *Electronics Letters*, 52, 9, 686-688, 2016.
- [17] Nishiyama T, Nishiyama A, Negishi M, Kashimura S, Katsumata Y, Kimura T, Nishiyama N, Tanimoto Y, Aizawa Y, Mitamura H, Fukuda K, Takatsuki S. "Diagnostic accuracy of commercially available automated external defibrillators". *Journal of the American Heart Association*, 4, 12, 2015.
- [18] STMicroelectronics, "STM32 Nucleo-144 development board with STM32F429ZI MCU". <https://www.st.com/en/evaluation-tools/nucleo-f429zi.html> (10.11.2024).
- [19] Greenwald S. "The MIT-BIH Malignant Ventricular Arrhythmia Database". <https://archive.physionet.org/physiobank/database/vfd>

b/ (10.11.2024).

- [20] Moody G. "MIT-BIH Normal Sinus Rhythm Database".  
<https://physionet.org/content/nsrdb/1.0.0/>  
(10.11.2024).

Düzenlenmemiş Sürüm - Uncorrected Version