



Düzce Üniversitesi Bilim ve Teknoloji Dergisi

Araştırma Makalesi

Atriyal Fibrilasyon Tespiti için Evrişimli Sinir Ağı Tabanlı Bir Derin Ağ Modeli¹

 Fatma MURAT^{a,*},  Ferhat SADAK^b,  Muhammed TALO^c,  Özal YILDIRIM^d,
 Yakup DEMİR^a

^a Elektrik-Elektronik Mühendisliği Bölümü, Mühendislik Fakültesi, Fırat Üniversitesi, Elazığ, TÜRKİYE

^b Makine Mühendisliği Bölümü, Mühendislik, Mimarlık ve Tasarım Fakültesi, Bartın Üniversitesi, Bartın, TÜRKİYE

^c Yazılım Mühendisliği Bölümü, Mühendislik Fakültesi, Fırat Üniversitesi, Elazığ, TÜRKİYE

^d Yazılım Mühendisliği Bölümü, Teknoloji Fakültesi, Fırat Üniversitesi, Elazığ, TÜRKİYE

* Sorumlu yazarın e-posta adresi: fmurat@firat.edu.tr

DOI:10.29130/dubited.1011246

ÖZ

Atriyal Fibrilasyon (AFib), yaşlılarda ve hatta herhangi bir kalp hastalığı olmayan gençlerde bile görülebilen yaygın bir kalp ritim bozukluğudur. AFib; inme, kalp yetmezliği ve ani ölümlere neden olabilir. Tüm bu mevcut ve gelecekteki endişeler, dünya çapında AFib'in erken tespitinde önemli önlemlerin alınmasını gerektirir. Elektrokardiyografik (EKG) dalga formları, AFib gibi anormal kalp ritimlerini saptamak için en güvenilir yöntem olarak kabul edilmektedir. Ancak EKG sinyallerinin karmaşıklığı ve doğrusal olmaması nedeniyle bu sinyalleri manuel olarak analiz etmek zordur. Bunun yanı sıra, EKG sinyallerinin yorumlanması kişiye özgü ve uzmanlar arasında farklılık gösterebilmektedir. Bu nedenle otomatik ve güvenilir bir AFib algılama için bilgisayar destekli teşhis (BDT) sistemlerinin kullanımı önemlidir. BDT sistemleri, EKG sinyallerinin değerlendirilmesinin objektif ve doğru olmasını sağlayacak potansiyele sahiptir. Bu çalışmada, derin öğrenme yapısı kullanılarak EKG sinyallerinden otomatik AFib tespiti gerçekleştirilmiştir. Derin öğrenme algoritmalarından evrişimli sinir ağı (ESA) mimarisinin AFib sınıflandırma probleminde kullanımı için çalışma kapsamında derin bir ağ modeli tasarlanmıştır. Kullanılan verisetinde normal sinüs ritimlerinin (SR) yanısıra AFib ve Atriyal Flutter (AFL) aritmileri bulunmaktadır. AFib ve AFL sınıfları birleştirilerek model çıkışında SR ve AFib ayırımının otomatik yapılması sağlanmıştır. Önerilen model, 2222 SR ve 2218 AFib tanısı alan kişilere ait her biri 5000 örneğe sahip EKG sinyali içeren veri seti üzerinde uygulanmıştır. Çalışma kapsamında hazırlanan ESA modeli, test aşamasında sırasıyla %95.09 hassasiyet, %97.27 özgüllük ve %97.26 kesinlik değerlerine ulaşmıştır. Modelin test verileri üzerindeki doğruluk oranı %96.17 olarak elde edilmiştir.

Anahtar Kelimeler: Atriyal fibrilasyon, Evrişimsel sinir ağları, Derin öğrenme

A Convolutional Neural Network Based Deep Network Model for Atrial Fibrillation Detection

ABSTRACT

Atrial Fibrillation (AFib) is a common heart rhythm disorder that can occur in the elderly and even young people without any heart disease. AFib can result in a stroke, heart failure, or sudden death.. All of these existing and future concerns require significant efforts in the early diagnosis of AFib around the world.. Electrocardiographic (ECG) waveforms are considered the most reliable method for detecting abnormal heart rhythms such as AFib. However, due to the complexity and non-linearity of ECG signals, it is difficult to analyze these signals

¹ICAAME 2021 konferansında sunulmuştur.

Geliş: 18/10/2021, Düzeltme: 07/12/2021, Kabul: 10/12/2021

manually. Furthermore, the interpretation of ECG data is subjective and may differ amongst specialists.. Therefore, the use of computer-assisted diagnostic (CAD) systems is important for automatic and reliable detection of AFib. CAD systems have the potential to make objective and accurate evaluation of ECG signals. In this paper, automatic AFib detection from ECG signals was performed using deep learning system. A deep network model was proposed within the scope of this study for the use of convolutional neural network (CNN) architecture, one of the deep learning algorithms, in the AFib classification problem. The dataset used includes normal sinus rhythms (SR) as well as AFib and Atrial Flutter (AFL) arrhythmias. By combining AFib and AFL classes, automatic classification of SR and AFib is provided at the model output. The suggested model was tested on a data set of 5000 samples of ECG signals from patients with 2222 SR and 2218 AFib, respectively. The CNN model developed within the scope of this study achieved 95.09% sensitivity, 97.27% specificity and 97.26% precision values, respectively, during the test phase. The accuracy percentage of the model on the test data was 96.17%.

Keywords: Atrial fibrillation, Convolutional neural networks, Deep learning

I. GİRİŞ

Kalp hastalıklarında ölüm oranlarının yüksek olması nedeniyle hastalığın erken teşhisi ve aritminin kesin olarak ayırt edilmesi, hastaların tedavisi için hayati öneme sahiptir [1]. Aritmiler, kardiyovasküler hastalık gruplarında önemli bir yer tutar. Aritmi, kendiliğinden veya diğer kardiyovasküler hastalıklar ile birlikte ortaya çıkabilir [2]. Bir aritmi çeşidi olan atriyal fibrilasyon (AFib), en yaygın kalp ritmi bozukluğudur. Çoğunlukla yaşlılarda görülür, ancak kalp hastalığı geçmişi olmayan gençler bile bundan muzdarip olabilir. AFib'nin kendisi nadiren öldürücü olmasına rağmen, kalp yetmezliği ve tromboembolizm gibi AFib ile ilişkili durumlarda komplikasyon riskini artırarak morbidite ve mortalitede artışa neden olur [3].

Aritmi saptama için en yaygın uygulanan çözüm, cilt üzerine yerleştirilen elektrotları kullanarak kalbin elektriksel aktivitesini belirli bir süre boyunca kaydeden elektrokardiyografidir (EKG). Farklı aritmiler, farklı EKG dalga formları ile temsil edilen farklı kalıplara karşılık gelir [4]. Bu kalıplar, kalbin çalışması ve durumu hakkında bilgiler içerir. Bundan dolayı, EKG sinyallerinin izlenmesi ve tanınması biyomedikal alanda son derece önemli bir konudur [5].

Bilgisayar destekli yorumlama, ortaya atılmasından bu yana geçen yaklaşık 50 yıllık süreçte sağlık alanında giderek daha önemli hale gelmiştir [6]. Bu sistemlerin geliştirilmesiyle birlikte kardiyologların iş yükü azaltılmış; hastalık tespitinin etkinliği ve doğruluğu artırılmıştır. Görsel hataları ve kişisel yorumları telafi etmek için araştırmacılar, EKG'yi otomatik olarak teşhis etmek amacıyla bilgisayar destekli teşhis (BDT) sistemleri geliştirmeye başladılar [7]. Etkili bir BDT sisteminin, güçlü bir sınıflandırıcı gereksiniminin yanı sıra ham verilerden gizli katmanlar yardımıyla önemli bilgileri çıkarabilen çok iyi bir özellik çıkarıcı gereksinimi de bulunur [1]. Sinyallerin ön işleme, dalga formu algılama, özellik çıkarma ve sınıflandırma işlemleri için geleneksel yöntemlerde el yapımı özelliklerin kullanılması gerekmektedir. Bu yöntemlerde, kodlanmış özellikler genellikle deneme-yanılma yoluyla ya da deneyimle tasarlanır ve seçilir. Bu yüzden bu sistemlerde yanlış tanı ve uygunsuz tedaviye yol açabilecek daha yanlış pozitifler üretme eğilimleri söz konusudur. Geleneksel sistemlerin karşılaştığı bu zorlukların üstesinden gelmek ve kodlanmış sabit özellikler kullanmadan daha iyi tespit doğruluğu sağlamak amacıyla derin öğrenme teknikleri geliştirilmiştir [8].

Evrişimli sinir ağları (ESA'lar), EKG sinyallerinin analizi ve sınıflandırılması için derin öğrenme modellerinde yaygın olarak kullanılmaktadır [9-15]. ESA'lar, karmaşık temsili özellikleri doğrudan verilerden otomatik olarak öğrenebildiklerinden, el yapımı özelliklere olan ihtiyacı ortadan kaldırırlar [16]. Xia ve ark. [17] AFib tespiti amacıyla ESA'ları kullanan ilk çalışma iddiasını taşımaktadır. Diğer geleneksel AFib tespiti algoritmaları ile karşılaştırıldığında önerilen yöntem, P-dalgası ve R-dalgası tespitini ve dahası herhangi bir manuel özellik çıkarımı ihtiyacını ortadan kaldırmıştır. Nguyen ve ark. [18] çalışmalarında özellik çıkarım işlemine gereksinim duymadan her segmenti otomatik olarak sınıflandırmak için bir ESA mimarisi geliştirmiştir. ESA, aşırı uydurmadan kaçınırken küçük bir

eđitim setinin tümünden yararlanmak için herhangi bir dođrulama verisi kullanmadan eđitilmiřtir. Ayrıca, her bir EKG sinyalinin sınıflandırılması için ESA'den gelen çıktıları girdi olarak alan bir destek vektör makinesinin(DVM) kullanımı önerilmiřtir. Özetle tasarladıkları modelde derin özellikleri çıkarmak için ESA yapısını, sınıflandırma için ise DVM kombinasyonunu kullanmışlardır. Attia ve ark. [19] standart 10 saniyelik, 12 kanallı EKG'leri kullanarak normal sinüs ritmi sırasında mevcut olan atriyal fibrilasyonun elektrokardiyografik imzasını saptamak için bir evriřimsel sinir ađı kullanan yapay zeka özellikli bir elektrokardiyograf geliřtirmişlerdir. AFib tespitinde kullandıkları model tek konvolüsyon katmanına sahip ESA modelidir.

Bu çalışmada, derin öğrenme yapısı kullanılarak EKG sinyallerinden otomatik AFib tespiti gerçekleştirilmiştir. Derin öğrenme algoritmalarından evriřimli sinir ađı (ESA) mimarisinin AFib sınıflandırma probleminde kullanımı için çalışma kapsamında derin bir ađ modeli tasarlanmıştır.

II. METARYAL VE YÖNTEM

A. VERİ SETİ


ESA mimarisinin AFib sınıflandırma görevindeki performansını gözlemlemek için çalışma kapsamında bir ESA modeli tasarlanmıştır. Bu çalışmada, Chapman University and Shaoxing People's Hospital (Shaoxing Hospital Zhejiang University School of Medicine) tarafından toplanan ve 10,000 üzerinde hasta kaydı içeren bir veriseti kullanılmıştır [20]. Kayıtlar her biri 5000 örnek içeren 12-kanal sinyalleri içeren 11 ritim sınıfından oluşmaktadır. Model için 11 ritim sınıfından sadece 4 tanesi seçilmiş ve Tablo 1'de gösterildiđi gibi birleştirilmiştir. Sinüs Düzensizliđi (SD) ve Sinüs Ritimleri (SR), SR sınıfı olarak; AFib ve Atriyal flutter (AFL) ritimleri ise AFib sınıfı olarak birleştirilmiştir. 2218 AFib ve 2222 SR sınıfı olmak üzere toplam 4440 örnek üzerinde uygulama yapılmıştır.

Tablo 1 Kullanılan birleştirilmiş ECG ritimlerine ait sayısal deđerler ve etiket bilgileri.

Birleştirilmiş Ritimler	Sınıf İsmi	Toplam Örnek Sayısı
AFib, AFL	AFib	2218
SR, SD	SR	2222
Toplam Örnek Sayısı		4440

B. ESA MODELİ

EKG sinyalleri, kullanılan cihazlara veya sinyallerin elde edildiđi ortama bađlı olarak çeřitli gürültüler içermektedir. Sinyal içerisinde istenmeyen bileřenlerin silinmesi ve sinyallerin standardize edilmesi için çeřitli ön işleme teknikleri arařtırmacılar tarafından uygulanmıştır. Derin öğrenme yöntemleri ile bahsedilen ön işleme tekniklerine olan ihtiyaç ortadan kalkmaktadır. Bu çalışmada, ön işleme olmadan ham EKG sinyallerinden AFib tespitinin yapılması amaçlanmıştır. Oluřturulan model, standart ESA mimarisi katmanları olan konvolüsyon, havuzlama(pooling) ve tamamen bađlı(fully-connected) katmanlarından oluşan 13 katmanlı bir yapıya sahiptir. Bu katmanların yanı sıra son zamanlarda kullanılan iki adet yığın normalizasyon(batch-normalization) katmanları modele yerleştirilmiştir. Çalışma kapsamında oluşturulan ESA modeline ait bir blok gösterim Şekil 1'de verilmiştir.

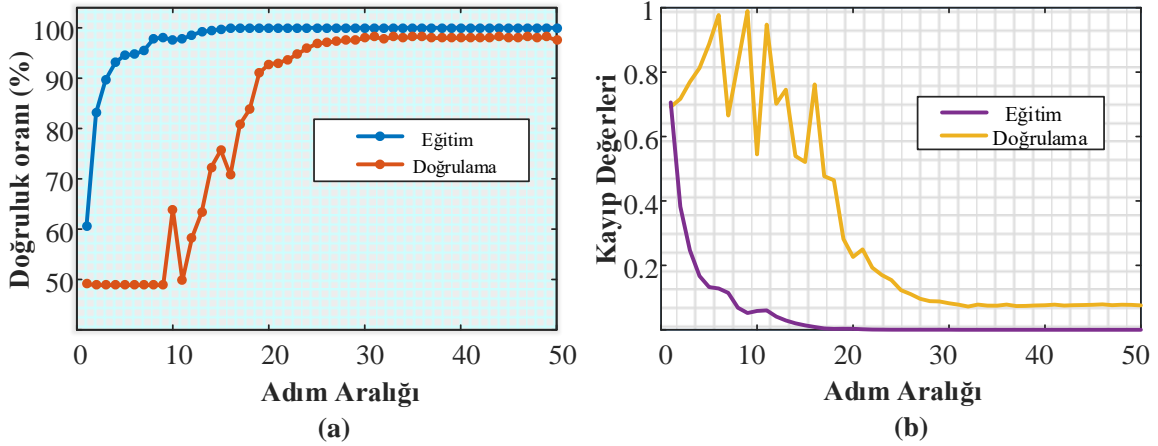


Şekil 1. Tasarlanan ESA Modelinin blok gösterimi

Model içerisindeki ilk iki konvolüsyon katmanı 128×5 ve 128×3 boyutlu filtrelerle sahip iken sonraki konvolüsyon katmanları ise sırasıyla 256×5 ve 64×3 boyutlu filtrelerle sahiptir. Her bir konvolüsyon katmanını takip eden havuzlama katmanları model içerisine yerleştirilmiştir. Yığın normalizasyon katmanları ise ilk ve ikinci havuzlama katmanlarından sonra yerleştirilmiştir. ESA modelinin sınıflandırma katmanından önce iki adet yoğun katmanı yerleştirilmiştir. Modelde “ReLU” aktivasyon fonksiyonu ile son katmanda sınıflandırma amaçlı “softmax” katmanı kullanılmıştır. Sınıflandırma çıktısını veren iki birimli softmax katmanı ile AFib ve SR sınıflarına ait olasılık değerleri elde edilerek tespit işlemi tamamlanmıştır.

III. DENEYSEL BULGULAR

ESA modeli uygulanırken toplam verilerin %80’i üzerinde eğitim, %10’u üzerinde doğrulama ve %10’u üzerinde test işlemi yapılmıştır. Tüm deneyler Intel Core i7-7700HQ 2.81GHz CPU, 16GB bellek ve 8 GB NVIDIA GeForce GTX 1070 grafik kartı özelliklerine sahip bir bilgisayar kullanılarak gerçekleştirilmiştir. Modelin standart hiper parametreleri 0,001 öğrenme hızına ayarlanmıştır. Adam optimizeri, modelin ağırlıklarını kategorik bir çapraz entropi kaybı işleviyle ayarlamak için kullanılmıştır. ESA modelinin eğitim ve doğrulama aşamalarında katman çıktılarında elde edilen öznetelikler üzerinde sınıflandırıcıların performansı Şekil 2’de verilmiştir.



Şekil 2. Tasarlanan modelin eğitim ve doğrulama aşamasındaki (a) Doğruluk oranı ve (b) Kayıp değerleri

Eğitilmiş model 444 adet eğitim aşamasında kullanılmamış test verisi üzerinde 50 adım aralığında yürütülerek AFib tespit performansı test edilmiştir. Model test için kullanılan 219 AFib sinyalinin 213 tanesini doğru tespit etmiştir. Böylelikle model test aşamasında sırasıyla %95.09 duyarlılık, %97.27 özgüllük ve %97.26 kesinlik başarımına ulaşmıştır. Modelin test doğruluk oranı %96.17 olarak elde edilmiştir.

Tablo 2. ESA ile AFib tespiti çalışmaları.

Yazar, Yıl	Sınıflandırıcı	Girdi	Model doğruluğu (%)
Acharya, 2017 [21]	11-katmanlı ESA	8683 5s EKG sinyali	94.9
Attia, 2019 [19]	ESA	649,931 10s EKG sinyali	83.3
Lai, 2020 [22]	8-katmanlı ESA	510,472 10s EKG sinyali	93.1
Nurmaini, 2020 [23]	13-katmanlı ESA	6114 örnek (9s)	99.98
Mevcut çalışma	13-katmanlı ESA	4440 kayıt	96.17

Tablo 2’de bildiri kapsamında incelenen AFib çalışmalarına ait performansların bir karşılaştırılması sunulmuştur. AFib çalışmalarından elde edilen doğruluk oranlarının genellikle %90 üzerinde bir değere sahip olduğu görülmektedir. Acharya [21], 11 katmanlı bir ESA modeli ile %94.9 başarımla elde etmiştir. Benzer şekilde 8 katmanlı [22], 13 katmanlı [23] modeller oluşturularak AFib tespiti sağlanmıştır.

IV. SONUC

Bu çalışmada, derin öğrenme tabanlı AFib tespiti gerçekleştirmek amacıyla 4440 hasta verisi içeren bir veri seti üzerinde yeni bir ESA modeli tasarlanarak sonuçlar elde edilmiştir. Önerilen model aynı problem için oluşturulan literatürdeki benzer çalışmalarla karşılaştırıldığında %96.17’lik doğruluk ile başarılı bir sonuç elde etmiştir. Tüm deneyler hasta düzeyinde tasarım kullanılarak gerçekleştirilmiş ve önerilen sınıflandırıcıların performansının EKG sinyalleri üzerinde AFib tespiti için umut verici olduğu görülmüştür. Gelecekteki çalışmalarda, 12 kanallı EKG sinyalinin tümünü kullanarak derin öğrenme modelleri tasarlayacak ve farklı kanallarda model performansını karşılaştıracaktır. Derin öğrenme modellerinin AFib tespitinde başarılı olduğu ancak bu alanda hala çalışılması gereken boşlukların olduğu söylenebilir.

V. KAYNAKLAR

- [1] S. N. Yu and K. T. Chou, “Integration of independent component analysis and neural networks for ECG beat classification,” *Expert Syst. Appl.*, vol. 34 no. 4, pp. 2841-2846, 2008.
- [2] J. Huang, B. Chen, B. Yao and W. He, “ECG arrhythmia classification using STFT-Based spectrogram and convolutional neural network,” *IEEE Access*, vol. 7, pp. 92871-92880, 2019.
- [3] C. D. Furberg, B. M. Psaty, T. A. Manolio, J. M. Gardin, V. E. Smith, and P. M. Rautaharju, “Prevalence of atrial fibrillation in elderly subjects (the Cardiovascular Health Study),” *Am. J. Cardiol.*, vol. 74, no. 3, pp. 236–241, 1994.
- [4] Y. Li, Y. Pang, J. Wang, and X. Li, “Patient-specific ECG classification by deeper CNN from generic to dedicated,” *Neurocomputing*, vol. 314, pp. 336-346, 2018.
- [5] Ö. Yildirim, “A novel wavelet sequences based on deep bidirectional LSTM network model for ECG signal classification,” *Comput. Biol. Med.*, vol. 96, pp. 189-202, 2018.
- [6] A. Y. Hannun, P. Rajpurkar, M. Haghpanahi, G. H. Tison, C. Bourn, M. P. Turakhia and Y. A. Ng, “Cardiologist-level arrhythmia detection and classification in ambulatory electrocardiograms using a deep neural network,” *Nature Medicine*, vol. 25 no. 1, pp. 65-69, 2019.

- [7] J. Jiang, H. Zhang, D. Pi, and C. Dai, "A novel multi-module neural network system for imbalanced heartbeats classification," *Expert Syst. with Appl.* vol. X, no. 1, p. 100003, 2019.
- [8] S. L. Oh, E. Y. K. Ng, R. S. Tan, and U. R. Acharya, "Automated diagnosis of arrhythmia using combination of CNN and LSTM techniques with variable length heart beats," *Comput. Biol. Med.*, vol. 102, pp. 278-287, 2018.
- [9] B. M. Maweu, S. Dakshit, R. Shamsuddin, and B. Prabhakaran, "CEFEs: A CNN Explainable Framework for ECG Signals," *Artif. Intell. Med.*, vol. 115, p. 102059, 2021.
- [10] F. Rabbi, S. Islam, D. Kumar, S. M. R. Islam, and M. Ali, "SCNN : Scalogram-based convolutional neural network to detect obstructive sleep apnea using single-lead electrocardiogram signals," *Comput. Biol. Med.*, vol. 134, p. 104532, 2021.
- [11] X. Yang, X. Zhang, M. Yang, and L. Zhang, "12-Lead ECG arrhythmia classification using cascaded convolutional neural network and expert feature," *J. Electrocardiol.*, vol. 67, pp. 56–62, 2021.
- [12] Y. Zhang, Z. Zhao, Y. Deng, X. Zhang, and Y. Zhang, "Biomedical Signal Processing and Control Human identification driven by deep CNN and transfer learning based on multiview feature representations of ECG," *Biomed. Signal Process. Control*, vol. 68, no. April, p. 102689, 2021.
- [13] M. Sepahvand and F. Abdali-mohammadi, "Biomedical Signal Processing and Control A novel multi-lead ECG personal recognition based on signals functional and structural dependencies using time-frequency representation and evolutionary morphological CNN," *Biomed. Signal Process. Control*, vol. 68, no. January, p. 102766, 2021.
- [14] Z. Yao, Z. Zhu, and Y. Chen, "Atrial fibrillation detection by multi-scale convolutional neural networks," In 2017 20th International Conference on Information Fusion (Fusion) (pp. 1-6). IEEE, 2017.
- [15] L. S. Y Huang, J Lin, G Wang, Z Ding, "A Multi-dilation Convolution Neural Network for Atrial Fibrillation Detection," in *ICDSP 2020: Proceedings of the 2020 4th International Conference on Digital Signal Processing*, pp. 136–140, 2020.
- [16] F. Murat, O. Yildirim, M. Talo, U. B. Baloglu, Y. Demir, and U. R. Acharya, "Application of deep learning techniques for heartbeats detection using ECG signals-analysis and review," *Comput. Biol. Med.*, vol. 120, no. April, p. 103726, 2020.
- [17] Y. Xia, N. Wulan, K. Wang, and H. Zhang, "Detecting atrial fibrillation by deep convolutional neural networks," *Comput. Biol. Med.*, vol. 93, no. July 2017, pp. 84–92, 2018.
- [18] Q. H. Nguyen, B. P. Nguyen, T. B. Nguyen, T. T. T. Do, J. F. Mbinta, and C. R. Simpson, "Stacking segment-based CNN with SVM for recognition of atrial fibrillation from single-lead ECG recordings," *Biomed. Signal Process. Control*, vol. 68, no. April, p. 102672, 2021.
- [19] Z. I. Attia *et al.*, "An artificial intelligence-enabled ECG algorithm for the identification of patients with atrial fibrillation during sinus rhythm: a retrospective analysis of outcome prediction," *Lancet*, vol. 394, no. 10201, pp. 861–867, 2019.
- [20] J. Zheng, J. Zhang, S. Danioko, H. Yao, H. Guo, and C. Rakovski, "A 12-lead electrocardiogram database for arrhythmia research covering more than 10,000 patients," *Sci. Data*, vol. 7, no. 1, pp. 1-8, 2020.

[21] U. R. Acharya, H. Fujita, O. S. Lih, Y. Hagiwara, J. H. Tan, and M. Adam, "Automated detection of arrhythmias using different intervals of tachycardia ECG segments with convolutional neural network," *Inf. Sci. (Ny)*, vol. 405, pp. 81–90, 2017.

[22] D. Lai, Y. Bu, Y. Su, X. Zhang, and C. S. Ma, "Non-standardized patch-based ECG lead together with deep learning based algorithm for automatic screening of atrial fibrillation," *IEEE J. Biomed. Heal. Informatics*, vol. 24, no. 6, pp. 1569–1578, 2020.

[23] S. Nurmaini, A. E. Tondas, A. Darmawahyuni, M.N. Rachmatullah, R. U. Partan, F. Firdaus, B. Tutuko, F. Pratiwi, A. H. Juliano and R. Khoirani, "Robust detection of atrial fibrillation from short-term electrocardiogram using convolutional neural networks," *Futur. Gener. Comput. Syst.*, vol. 113, pp. 304–317, 2020.