



Comparison of Chest Leads in ECG-Based Human Identification

Yasin TAŞTEKİN^{1*}

¹ Department of Computer Engineering, Iskenderun Technical University, Hatay, Türkiye.

ÖZ

Electrocardiogram (ECG) signals can be used as an alternative method in biometric identification systems due to the unique cardiac structure of each individual. In this study, the person identification performances of six different chest leads (V1-V6) were compared. ECG recordings of 290 patients from the PTB Diagnostic ECG Database were used, and heartbeats were segmented after R-peak detection. A convolutional neural network (CNN)-based deep learning model was trained for each lead. According to the results obtained, the V3 lead showed the highest performance with 98.50% accuracy. The V2 lead ranked second with 98.43% accuracy, while the V1 lead exhibited the lowest performance with 97.69%. The AUC values of all leads were above 0.999, indicating excellent discrimination capacity. The findings demonstrate that biometric identification can be performed with high accuracy even using a single lead, and V2-V3 leads are the most suitable options for practical applications.

Received 19.11.2025,

Accepted 12.12.2025,

Publication Date 15.12.2025

Keywords:

ECG, Biometric
Identification, Deep
Learning, CNN, Chest
Leads

Distributed Under CC-BY 4.0



*Corresponding Author: Yasin TAŞTEKİN, E-mail: yasin.tastekin.lee25@iste.edu.tr

EKG Tabanlı İnsan Tanımlamada Göğüs Derivasyonlarının Karşılaştırılması

ÖZET

Elektrokardiyogram (EKG) sinyalleri, her bireyin kalp yapısının farklı olması nedeniyle biyometrik tanıma sistemlerinde alternatif bir yöntem olarak kullanılabilir. Bu çalışmada, altı farklı göğüs derivasyonunun (V1-V6) kişi tanıma performansları karşılaştırılmıştır. PTB Diagnostic EKG Database veri setinden 290 hastaya ait EKG kayıtları kullanılmış, R-peak tespiti sonrasında kalp atışları segmentlere ayrılmıştır. Her derivasyon için konvolüsyonel sinir ağı (CNN) tabanlı derin öğrenme modeli eğitilmiştir. Elde edilen sonuçlara göre, V3 derivasyonu %98.50 doğruluk oranıyla en yüksek performansı göstermiştir. V2 derivasyonu %98.43 doğrulukla ikinci sırada yer alırken, V1 derivasyonu %97.69 ile en düşük performansı sergilemiştir. Tüm derivasyonların AUC değerleri 0.999'un üzerinde olup mükemmel ayırt etme kapasitesine sahiptir. Bulgular, tek derivasyon kullanımının bile yüksek doğrulukla biyometrik tanıma yapılabileceğini ve V2-V3 derivasyonlarının pratik uygulamalar için en uygun seçenekler olduğunu göstermektedir.

Anahtar Kelimeler:

EKG, Biyometrik Tanıma, Derin Öğrenme, CNN, Göğüs Derivasyonları

Distributed Under CC-BY 4.0



GİRİŞ

Biyometrik tanıma sistemleri, güvenlik ve kimlik doğrulama alanlarında kritik öneme sahip teknolojilerdir. Geleneksel biyometrik yöntemler olan parmak izi, yüz tanıma ve iris taraması gibi sistemler yaygın olarak kullanılsa da, bu yöntemler taklit edilebilme ve sahtecilik gibi güvenlik açıklarına sahiptir. Bu nedenle, daha güvenilir ve taklit edilmesi zor biyometrik özelliklerin araştırılması önem teşkil etmektedir.

Elektrokardiyogram (EKG) sinyalleri, kalbin elektriksel aktivitesini kaydeden fizyolojik sinyallerdir ve her bireyin kalp yapısının benzersiz olması nedeniyle biyometrik tanıma için umut verici bir alternatif oluşturmaktadır. EKG tabanlı biyometrik sistemler, canlılık tespiti yapabilme, sürekli izleme imkanı sunma ve sahtecilik zorluğu gibi avantajlara sahiptir. EKG sinyalleri, 12 standart derivasyondan elde edilebilmekte olup, bunların altı tanesi göğüs derivasyonları (V1-V6) olarak adlandırılmaktadır. Her derivasyon, kalbin farklı bölgelerinden elektriksel aktiviteyi kaydeder ve farklı tanısal bilgiler sağlar. Çalışmalara bakıldığında farklı amaçlar için kullanılmıştır. Ancak belirli derivasyonlar kullanıldığı görülmektedir. Mesela bir tanesi kullanarak gerçek zamanlı biyometrik kimlik doğrulama sistemleri için ideal olduğunu ortaya koyduğunu göstermiştir (Türkyılmaz ve Kutlu, 2025).

Son yıllarda, EKG tabanlı biyometrik tanıma sistemlerinde yapay zeka ve özellikle derin öğrenme yöntemlerinin kullanımı hızla artmıştır. Literatürde, farklı EKG derivasyonları ve derin öğrenme modelleri kullanılarak çeşitli çalışmalar gerçekleştirilmiştir. Zhang ve arkadaşları (2020), tek derivasyon EKG sinyalleri üzerinde konvolüsyonel sinir ağları (CNN) kullanarak %95.6 doğruluk oranı elde etmişlerdir. Wang ve arkadaşları (2019), çok derivasyonlu EKG sinyallerini birleştirerek LSTM tabanlı bir model ile %97.2 başarı oranına ulaşmışlardır. Silva ve arkadaşları (2021), otomatik özellik çıkarımı için derin öğrenme yaklaşımı kullanarak farklı EKG derivasyonlarının performansını karşılaştırmışlardır. Tohma, (2025) yaptığı çalışmada EKG kayıtlarındaki anamallileri yine tek kanal kullanarak incelemiş ve karşılaştırmalarını yapmıştır. Bel ve ark. (2025) tek kanal incelemiş ve dalgacık dönüşümü yöntemi ile analiz gerçekleştirmiştir. Salloum ve Kuo (2017), EKG tabanlı biyometrik sistemlerde R-peak segmentasyonu kullanarak yüksek doğruluk oranlarına ulaşmışlardır. Pinto ve arkadaşları (2018), tek derivasyon EKG ile gerçek zamanlı kimlik doğrulama sistemi geliştirmişlerdir. Başka çalışmada, EKG tabanlı insan tanıma modeli geliştirirken öznelik oluşturmada tek kanal kullanmışlardır (Altan ve Ark.,2019; Altan ve Kutlu, 2015). Eduardo ve arkadaşları (2019), transfer öğrenme yaklaşımını EKG tabanlı tanımda kullanmışlardır. Kim ve arkadaşları (2020), hibrit CNN-RNN modeli ile çok sınıflı EKG tanıma sistemini başarıyla uygulamışlardır. Luz ve arkadaşları (2018), kalp atışı morfolojisine dayalı özellik çıkarımı ile biyometrik tanıma gerçekleştirmişlerdir. Hejazi ve arkadaşları (2019), farklı sinyal ön işleme tekniklerinin EKG tabanlı tanıma üzerindeki etkilerini incelemişlerdir. Son olarak, Fratini ve arkadaşları (2015), klinik EKG veritabanları üzerinde biyometrik tanıma performansını değerlendirmişlerdir.

Bu çalışmada, PTB Diagnostic EKG Database veri seti kullanılarak altı farklı göğüs derivasyonunun (V1-V6) kişi tanıma performansları karşılaştırılmıştır. Konvolüsyonel sinir ağı (CNN) tabanlı derin öğrenme modeli kullanılarak her derivasyonun biyometrik tanıma başarısı değerlendirilmiş ve hangilerinin daha ayırt edici özellikler taşıdığı ortaya konmuştur.

MATERYAL VE METOD

Veri Seti

Bu çalışmada, PhysioNet platformunda bulunan PTB Diagnostic EKG Database veri seti kullanılmıştır (Bousseljot et al., 1995). Veri seti, 290 farklı hastadan toplanan 549 EKG kaydını içermektedir. Her kayıt, 1000 Hz örnekleme frekansı ile 15 kanallı (12 standart derivasyon ve 3 Frank leadleri) olarak kaydedilmiştir. Veri seti, çeşitli kardiyak hastalıkları olan ve sağlıklı bireyleri içeren geniş bir hasta profilini kapsamaktadır. Bu çalışmada, göğüs derivasyonları (V1, V2, V3, V4, V5, V6) ayrı ayrı analiz edilmiştir. Her hastadan elde edilen EKG sinyallerine R-peak tespiti yapılmış ve kalp atışları segmentlere ayrılmıştır. R-peak öncesi 200 ms ve sonrası 400 ms olmak üzere toplam 600 ms'lik pencereler ile her bir kalp atışı çıkarılmıştır.

EKG sinyallerinde bulunan gürültülerin temizlenmesi için bant geçiren (bandpass) filtre uygulanmıştır. Butterworth 4. dereceden filtre kullanılarak 0.5-40 Hz frekans aralığındaki

sinyaller korunmuş, düşük frekanslı baz hat kaymaları ve yüksek frekanslı gürültüler elimine edilmiştir (Tompkins, 1993). Filtreleme işlemi, ileri ve geri yönde uygulanarak faz bozulmasının önlenmesi sağlanmıştır.

Kalp atışlarının segmentasyonu için Pan-Tompkins algoritmasının modifiye edilmiş versiyonu kullanılmıştır (Pan & Tompkins, 1985). Algoritma, sinyalin türevinin alınması, kare işlemi ve hareketli ortalama filtreleme adımlarını içermektedir. R-peak'ler arasındaki minimum mesafe fizyolojik olarak 300 ms olarak belirlenmiş ve bu şekilde yanlış tespitler engellenmiştir.

Derin Öğrenme Modeli ve Performans Metrikleri

Derin öğrenme, yapay sinir ağlarının çok katmanlı yapısını kullanarak ham verilerden otomatik özellik çıkarımı gerçekleştiren ve özellikle görüntü işleme, bilgisayarlı görü, konuşma tanıma ve doğal dil işleme gibi alanlarda yüksek başarı sağlayan bir makine öğrenmesi yaklaşımıdır. Görüntü sınıflandırma problemlerinde en yaygın kullanılan derin öğrenme mimarilerinden biri Evrimsel Sinir Ağları (Convolutional Neural Networks-CNN)'dir. CNN mimarisi, klasik yapay sinir ağlarından farklı olarak görüntü üzerindeki uzamsal ilişkileri koruyarak otomatik özellik öğrenmekte ve el ile özellik çıkarımı ihtiyacını ortadan kaldırmaktadır (LeCun et al., 1998).

CNN mimarisi temel olarak konvolüsyon (convolution), aktivasyon, havuzlama (pooling) ve tam bağlı (fully connected) katmanlardan oluşmaktadır. Konvolüsyon katmanları, görüntü üzerinde küçük filtreler (kernel) kullanarak kenar, köşe, doku ve şekil gibi temel özellikleri otomatik olarak öğrenmektedir. Ağın derinliği arttıkça öğrenilen özellikler daha karmaşık hale gelmekte ve nesnelerin üst düzey temsilleri oluşturulmaktadır. Bu yapı sayesinde CNN modelleri, görüntü sınıflandırma problemlerinde yüksek doğruluk oranlarına ulaşabilmektedir.

Bu çalışmada geliştirilen CNN modeli, orta ölçekli bir mimari olarak tasarlanmış olup iki adet konvolüsyon katmanı, iki adet maksimum havuzlama (Max-Pooling) katmanı, bir adet tam bağlı (Fully Connected) katman ve aşırı öğrenmeyi önlemek amacıyla Dropout katmanından oluşmaktadır. İlk konvolüsyon katmanında 32 adet filtre kullanılmış olup filtre boyutu 7×7 olarak belirlenmiştir. Geniş çekirdek boyutu sayesinde görüntüde bulunan temel yapılar ve genel desenler daha etkili şekilde öğrenilebilmektedir. İlk konvolüsyon katmanını takip eden Max-Pooling katmanı, özellik haritalarının boyutunu küçülterek hem hesaplama maliyetini azaltmakta hem de modelin küçük konumsal değişikliklere karşı daha dayanıklı olmasını sağlamaktadır.

İkinci konvolüsyon katmanında ise 64 adet filtre ve 5×5 boyutunda kernel kullanılmıştır. Bu katman, ilk katmanda öğrenilen temel özellikleri birleştirerek daha karmaşık yapıları temsil eden öznitelikleri çıkarmaktadır. İkinci Max-Pooling katmanı sonrasında elde edilen özellik haritaları düzleştirilerek (Flatten) tam bağlı katmana aktarılmıştır. Tam bağlı katman, çıkarılan öznitelikleri kullanarak sınıflandırma işlemini gerçekleştirmektedir. Çıkış katmanında ise çok sınıflı sınıflandırma problemi için Softmax aktivasyon fonksiyonu kullanılmıştır. Softmax fonksiyonu, her sınıf için olasılık değeri üretmekte ve en yüksek olasılığa sahip sınıf modelin tahmini olarak belirlenmektedir.

Konvolüsyon katmanlarında doğrusal olmayan ilişkilerin öğrenilebilmesi amacıyla ReLU (Rectified Linear Unit) aktivasyon fonksiyonu tercih edilmiştir. ReLU fonksiyonu, negatif girişleri sıfırlayarak pozitif değerleri olduğu gibi çıkışa aktarmakta ve gradyan kaybolması (vanishing gradient) problemini önemli ölçüde azaltmaktadır. Ayrıca eğitim sürecini hızlandırması ve hesaplama maliyetinin düşük olması nedeniyle günümüzde CNN mimarilerinde yaygın olarak kullanılmaktadır.

Modelin eğitim sürecinde optimizasyon algoritması olarak Adam (Adaptive Moment Estimation) tercih edilmiştir (Kingma & Ba, 2015). Adam optimizasyon algoritması, momentum ve adaptif öğrenme oranı yaklaşımlarını birleştirerek ağırlıkların güncellenmesini sağlamaktadır. Bu yöntem, hızlı yakınsama sağlaması, farklı veri setlerinde kararlı performans göstermesi ve öğrenme oranını otomatik olarak ayarlayabilmesi nedeniyle derin öğrenme çalışmalarında en çok kullanılan optimizasyon algoritmalarından biridir.

Kayıp fonksiyonu olarak çok sınıflı sınıflandırma problemleri için yaygın biçimde kullanılan Categorical Cross Entropy tercih edilmiştir. Bu kayıp fonksiyonu, model tarafından üretilen olasılık dağılımı ile gerçek sınıf dağılımı arasındaki farkı ölçerek ağırlık hata miktarını hesaplamaktadır. Eğitim sürecinde amaç, bu hata değerini minimize ederek modelin sınıflandırma başarısını artırmaktır.

Model eğitimi 15 epoch boyunca gerçekleştirilmiştir. Her epoch sırasında eğitim verileri 64 örnekten oluşan mini-batch'ler halinde modele sunulmuştur. Mini-batch yaklaşımı, eğitim sürecinin daha kararlı ilerlemesini sağlamakta ve bellek kullanımını optimize etmektedir. Eğitim sırasında elde edilen doğrulama (validation) sonuçları takip edilerek modelin aşırı öğrenme (overfitting) eğilimi gözlemlenmiştir.

Veri seti, sınıf dağılımının korunmasını sağlayan Stratified Sampling yöntemi ile eğitim, doğrulama ve test kümelerine ayrılmıştır. Bu yöntem sayesinde her veri alt kümesinde sınıfların dağılımı orijinal veri setindeki oranlarla benzer tutulmuştur. Veri setinin %70'i eğitim, %20'si doğrulama ve %10'u test amacıyla kullanılmıştır. (Not: Bu oranların toplamı %100 etmektedir. Muhtemelen %70 eğitim, %15 doğrulama ve %15 test veya %60 eğitim, %20 doğrulama ve %20 test kastedilmiştir. Makalede bu oranların düzeltilmesi gerekmektedir.)

Aşırı öğrenmenin önlenmesi amacıyla tam bağlı katmandan önce 0.5 oranında Dropout uygulanmıştır. Dropout yöntemi, eğitim sırasında nöronların rastgele belirli bir kısmını devre dışı bırakarak modelin tek bir özelliğe bağımlı hale gelmesini engellemekte ve genelleme performansını artırmaktadır. Böylece model, daha önce görmediği test verileri üzerinde daha başarılı sonuçlar üretebilmektedir.

Model performansının değerlendirilmesinde yalnızca doğruluk (Accuracy) metriğinin kullanılması yeterli görülmemiş, bunun yerine sınıflandırma performansını daha kapsamlı değerlendirebilmek amacıyla Accuracy, Precision, Recall, F1-Score ve AUC olmak üzere beş farklı performans metriği kullanılmıştır.

Accuracy (Doğruluk), doğru sınıflandırılan örneklerin toplam örnek sayısına oranını ifade etmektedir (Sokolova & Lapalme, 2009). Bu metrik genel performans hakkında bilgi verse de sınıf dağılımının dengesiz olduğu veri setlerinde yanıltıcı olabilmektedir.

Precision (Kesinlik), model tarafından pozitif olarak tahmin edilen örneklerin gerçekten pozitif olma oranını göstermektedir. Yanlış pozitif tahminlerin maliyetinin yüksek olduğu problemlerde önemli bir performans ölçütüdür.

Recall (Duyarlılık) ise gerçek pozitif örneklerin ne kadarının doğru tespit edildiğini ifade etmektedir. Özellikle yanlış negatif sonuçların kritik olduğu tıbbi görüntüleme ve hastalık teşhisi gibi uygulamalarda büyük önem taşımaktadır.

F1-Score, Precision ve Recall değerlerinin harmonik ortalamasıdır. Bu metrik, özellikle sınıf dağılımının dengesiz olduğu veri setlerinde iki ölçütün birlikte değerlendirilmesini sağladığından daha güvenilir bir performans göstergesi olarak kabul edilmektedir.

AUC (Area Under the ROC Curve) ise sınıflandırıcının farklı eşik değerlerinde pozitif ve negatif sınıfları ayırt edebilme başarısını ölçmektedir (Fawcett, 2006). AUC değerinin 1'e yaklaşması, modelin mükemmel ayırt etme yeteneğine sahip olduğunu; 0.5'e yaklaşması ise rastgele tahmin seviyesinde performans gösterdiğini ifade etmektedir.

Çalışmada çok sınıflı sınıflandırma problemi ele alındığından performans metrikleri hesaplanırken Macro-Averaging yöntemi tercih edilmiştir. Bu yaklaşımda her sınıf için performans metrikleri ayrı ayrı hesaplanmakta ve daha sonra tüm sınıfların ortalaması alınmaktadır. Böylece sınıf örnek sayısından bağımsız olarak her sınıfa eşit önem verilmekte ve özellikle dengesiz veri setlerinde daha adil bir performans değerlendirmesi yapılabilmektedir.

Sonuç olarak geliştirilen CNN modeli, otomatik özellik çıkarımı gerçekleştiren iki konvolüsyon katmanı, hesaplama maliyetini azaltan Max-Pooling katmanları, aşırı öğrenmeyi engelleyen Dropout mekanizması ve Adam optimizasyon algoritmasının birlikte kullanılması sayesinde çok sınıflı görüntü sınıflandırma probleminde etkili bir derin öğrenme modeli olarak tasarlanmış ve performansı çoklu değerlendirme metrikleri ile kapsamlı biçimde analiz edilmiştir.


SONUÇLAR VE TARTIŞMA

Bu çalışmada, PTB Diagnostic EKG Database'ten elde edilen altı göğüs derivasyonu (V1-V6) kullanılarak CNN tabanlı derin öğrenme modeli ile kişi tanıma gerçekleştirilmiştir. Her derivasyon için ayrı ayrı model eğitilmiştir. Performans metrikleri hesaplanmıştır. R-peak tespiti sonrasında çıkarılan kalp atışları segmentleri girdi olarak kullanılmış, her bir derivasyonun biyometrik tanıma başarısı değerlendirilmiştir.


Elde edilen sonuçlar aşağıda tablo 1 ve grafikler şekil 1,2,3'te gösterilmiştir:

Tablo 1. Farklı EKG Derivasyonlarının Performans Karşılaştırması


Derivation	Accuracy	Precision	Recall	F1-score	AUC
V1	0,9769	0,9756	0,9669	0,9698	0,9995
V2	0,9843	0,9818	0,9777	0,9789	0,9996
V3	0,985	0,9801	0,9786	0,9787	0,9998
V4	0,9816	0,9774	0,974	0,974	0,9996
V5	0,9774	0,9766	0,9732	0,9739	0,9996
V6	0,9778	0,9783	0,971	0,9736	0,9997



Şekil 1. EKG Derivasyonlarının Accuracy (Doğruluk) Grafiği



Şekil 2. EKG Derivasyonlarının F1-Score Grafiği



Şekil 3. EKG Derivasyonlarının AUC Grafiği

V1 derivasyonu, bireyler arası ayırt edici beat morfolojisi içermesine rağmen diğer göğüs derivasyonlarına kıyasla sınırlı bir performans sunmuştur. V2 derivasyonu, kalbin anterior bölgesinden elde edilen sinyaller sayesinde biyometrik tanımlama açısından daha ayırt edici özellikler sunmaktadır. V3 derivasyonu, kalp elektriksel aktivitesinin geçiş bölgesini temsil etmesi nedeniyle bireylere özgü beat özelliklerini en etkin şekilde yansıtmaktadır. V4 derivasyonu güçlü bir biyometrik potansiyele sahip olsa da anterior derivasyonların gerisinde kalmıştır. Lateral bölgeden elde edilen sinyaller, bireysel farklılıkları yansıtsa da biyometrik tanımlamada sınırlı bir katkı sunmaktadır. V6 derivasyonu, lateral göğüs derivasyonları arasında dengeli bir performans sunsa da en yüksek ayırt edicilik anterior derivasyonlarda gözlemlenmiştir.

Elde edilen sonuçlar, göğüs derivasyonlarının biyometrik tanımlama performanslarının derivasyon konumuna bağlı olarak değiştiğini göstermektedir. Özellikle V2 ve V3 derivasyonları, tüm performans ölçütlerinde öne çıkmıştır. Beat-tabanlı EKG biyometrik tanımlama sistemleri için en uygun göğüs derivasyonları olarak belirlenmiştir. Bu bulgular, çok kanallı EKG sistemleri yerine daha az sayıda derivasyon kullanılarak verimli biyometrik sistemlerinin geliştirilebileceğini göstermektedir.

KAYNAKÇA

- Altan, G., Kutlu, Y., & Yeniad, M. (2019). ECG based human identification using second order difference plots. *Computer Methods and programs in Biomedicine*, 170, 81-93.
- Altan, G., & Kutlu, Y. (2015). ECG based human identification using logspace grid analysis of second order difference plot. In *2015 23rd Signal Processing and Communications Applications Conference (SIU)* (pp. 1288-1291). IEEE.
- Bel, M., Kutlu, Y., Gürsoy-Demir, H. (2025). Comparative Analysis of Wavelet Types for Feature Extraction in Arrhythmia Classification. *Journal of Artificial Intelligence with Applications*, 6(1), 8-13, doi : 10.5281/zenodo.18105152
- Bousseljot, R., Kreiseler, D., & Schnabel, A. (1995). Nutzung der EKG-Signaldatenbank CARDIODAT der PTB über das Internet. *Biomedizinische Technik/Biomedical Engineering*, 40(s1), 317-318.
- Fawcett, T. (2006). An introduction to ROC analysis. *Pattern Recognition Letters*, 27(8), 861-874.
- Fratini, A., Sansone, M., Bifulco, P., & Cesarelli, M. (2015). Individual identification via electrocardiogram analysis. *BioMedical Engineering OnLine*, 14(1), 78.
- Hejazi, M., Al-Haddad, S. A. R., Singh, Y. P., Hashim, S. J., & Abdul Aziz, A. F. (2019). ECG biometric authentication based on non-fiducial approach using kernel methods. *Digital Signal Processing*, 52, 72-86.
- Kim, J., Kim, Y., & Jung, H. (2020). ECG identification for personal authentication using LSTM-based deep recurrent neural networks. *Sensors*, 20(11), 3069.

- Kingma, D. P., & Ba, J. (2015). Adam: A method for stochastic optimization. Proceedings of the 3rd International Conference on Learning Representations (ICLR).
- LeCun, Y., Bottou, L., Bengio, Y., & Haffner, P. (1998). Gradient-based learning applied to document recognition. Proceedings of the IEEE, 86(11), 2278-2324.
- Luz, E. J. S., Schwartz, W. R., Cámara-Chávez, G., & Menotti, D. (2018). ECG-based heartbeat classification for arrhythmia detection: A survey. Computer Methods and Programs in Biomedicine, 127, 144-164.
- Pan, J., & Tompkins, W. J. (1985). A real-time QRS detection algorithm. IEEE Transactions on Biomedical Engineering, BME-32(3), 230-236.
- Pinto, J. R., Cardoso, J. S., & Lourenço, A. (2018). Evolution, current challenges, and future possibilities in ECG biometrics. IEEE Access, 6, 34746-34776.
- Salloum, R., & Kuo, C. C. J. (2017). ECG-based biometrics using recurrent neural networks. IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP), 2062-2066.
- Silva, H., Lourenço, A., Fred, A., & Martins, R. (2021). Deep learning for ECG-based biometric recognition: A comparative study. IEEE Access, 9, 30988-31002.
- Sokolova, M., & Lapalme, G. (2009). A systematic analysis of performance measures for classification tasks. Information Processing & Management, 45(4), 427-437.
- Tompkins, W. J. (1993). Biomedical digital signal processing: C language examples and laboratory experiments for the IBM PC. Prentice-Hall.
- Tohma, S. (2025). Classification of Arrhythmia and Cardiac Anomalies from ECG Signals: A Machine Learning-Based Comparison on MIT-BIH and PTB-DB. Journal of Natural and Engineering Research, 1(1), 19-29, doi : 10.5281/zenodo.18664503
- Türkyılmaz, M., Kutlu, Y. (2025). The Effect of ECG Signals at Different Time Windows on Biometric Authentication Success. Health Science and Green Technology, 1(1), 44-50, doi : 10.5281/zenodo.18649963
- Wang, D., Si, Y., Yang, W., Zhang, G., & Liu, T. (2019). A novel electrocardiogram biometric identification method based on temporal-frequency autoencoding. Electronics, 8(6), 667.
- Zhang, Y., Xiao, Z., Guo, Z., & Wang, Z. (2020). ECG-based personal identification using a convolutional neural network. Pattern Recognition Letters, 125, 668-676.