

Dmytro SABODASHKO¹

Opiekun naukowy: Volodymyr KHOMA²

NORMALIZACJA TEMPORALNA SYGNAŁU EKG W SYSTEMIE IDENTYFIKACJI BIOMETRYCZNEJ

Streszczenie: Artykuł poświęcony jest opracowaniu i testowaniu algorytmu czasowej normalizacji sygnałów elektrokardiogramu (EKG) w celu ich zastosowania w biometrycznych systemach identyfikacji podmiotów. Zaproponowano algorytm, którego zastosowanie zapewnia niezmienność klasyfikatora do zmian tętna jednostki. Testowanie proponowanego podejścia potwierdziło możliwość jego zastosowania w celu tworzenia biometrycznych systemów identyfikacji opartych na sygnałach EKG.

Słowa kluczowe: sygnał EKG, normalizacja sygnału EKG, biometryczna identyfikacja, uczenie maszynowe

ECG SIGNAL TEMPORAL NORMALIZATION IN SYSTEM OF BIOMETRIC IDENTIFICATION

Summary: The article is devoted to the development and validation of the algorithm for electrocardiogram signals normalization in time domain for biometric systems of human identification. The proposed algorithm ensures classifier's invariance to the heart rate variability of an individual. Testing of the proposed approach confirmed the possibility of its application for the design of biometric identification systems based on ECG signals.

Keywords: ECG signal, biometric identification, ECG signal normalization, machine learning, classification accuracy

1. Wstęp

Sygnał EKG jest łatwy do zmierzenia, gromadzenia na nośnikach elektronicznych, przetwarzania za pomocą metod cyfrowych itd. Te oraz inne właściwości sygnału EKG inspirują badaczy do poszukiwania możliwości stosowania go w systemach kontroli dostępu do obiektów i zasobów informacyjnych. [1,2].

¹ Lviv Polytechnic National University, Ukraine; Institute of Computer Technologies, Automation and Metrology; Cybersecurity; sabodashko.dv@gmail.com

² Politechnika Opolska, Wydział Elektrotechniki, Automatyki i Informatyki, Automatyka i Robotyka; v.khoma@po.edu.pl

Jednak w przeciwieństwie do odcisków palców i innych „stabilnych” cech biometrycznych sygnał EKG cechuje się znaczną wariantywnością, co komplikuje algorytmy jego przetwarzania w celu, na przykład, uwierzytelnienia tożsamości. Z jednej strony, wariantywność sygnału EKG jest korzystną cechą gdyż unikalnie wyróżnia daną osobę spośród innych, a z drugiej -zależność od stanu fizycznego i psychicznego stwarza trudności do zapewnienia prawidłowego uwierzytelniania podmiotu.

Z tego powodu aktualnym jest badanie zmienności sygnału EKG i poszukiwanie pewnych niezmienników (ang. invariants), które mogłyby z dużym prawdopodobieństwem identyfikować podmiot w krótkim okresie czasu. Badania danego typu mogą być przeprowadzone w szczególności poprzez analizę statystyczną danych eksperymentalnych, uzyskanych przez pomiar wykresów EKG, zależnych od aktualnego tętna, oraz znalezienie sposobów ich przekształcenia (normalizacji), które pozwoliłyby w znacznym stopniu zmniejszyć ich rozrzut.

Przegląd znanych badań dotyczących zmienności sygnału EKG ujawnił ich ściśle medyczne ukierunkowanie [5,6,7]. Zapisy EKG są traktowane głównie jako dane wejściowe niezbędne dla uzyskania ważnych medycznych cech diagnostycznych. Tylko kilka publikacji dotyczyło problemu zmienności sygnału EKG w aplikacjach biometrii [8,9]. Dotyczą one zastosowania temporalnej normalizacji EKG sygnału, osiąganą przez poprzez próbkowanie każdego segmentu sygnału do z góry określonego czasu trwania. Jednak takie podejście ma swoje ograniczenie, ponieważ zmiana tętna nie oznacza jednolitej zmiany we wszystkich przedziałach sygnału EKG, w takich jak, na przykład, zespół QRS.

Autorzy badań [10,11] rozwiązywali problem temporalnej normalizacji sygnału EKG, poprzez normalizację jedynie odstępu QT, który jest bardziej podatny na zmiany tętna. Inne badacze, na przykład [12], poszli jeszcze dalej, dzieląc każdy cykl serca na tradycyjne komponenty P, QRS i T, oddzielnie je próbkując przed ponownym połączeniem. Jednak w powszechnie znanych badaniach zwykle wykorzystywano tak zwane metody fiducjalne (ang. fiducial) selekcji cech. Dla tego typu metod punktem kluczowym jest lokalizacja punktów charakterystycznych, tj. fiducjalnych oraz metryka między nimi, co właśnie czyni dane wejściowe klasyfikatora. W tym kontekście nie badano wpływu zmienności tętna na dokładność rozpoznawania tożsamości bezpośrednio poprzez próbkowanie EKG.

Celem pracy jest określenie wpływu zmienności sygnału EKG podmiotu na dokładność jego identyfikacji za pomocą sieci neuronowych bez poprzedniej selekcji cech informacyjnych lub zastosowania przekształceń funkcjonalnych przed klasyfikacją, a także opracowanie i wdrożenie nowego algorytmu temporalnej normalizacji sygnału EKG i jego testowanie na wielu EKG-podmiotach.

2. Problem zmienności sygnału EKG z perspektywy biometrii


Sygnał EKG jest generowany przez impulsy elektryczne pochodzące z mózgu do serca. Każdy impuls stymuluje różne części mięśnia sercowego, w celu wykonania pełnego cyklu pracy serca. Proces ten powtarza się cyklicznie, dlatego sygnał EKG ma quasi-okresowy charakter. Ponadto można obserwować rozkład pola elektrycznego na całym ciele, a pomiar różnicy potencjałów z różnych części na powierzchni ciała jest istotą powstawania sygnału EKG.

Poziom sygnału EKG jest niski, a zatem podatny na wszelkiego rodzaju zniekształcenia. Aby zapewnić wysoką jakość zarejestrowanego sygnału EKG w praktyce klinicznej stosuje się takie metody i narzędzia, jak żel do zwiększenia przewodności kontaktu „ciało-elektrod”, wielokanałowy zapis biopotencjałów z różnych punktów klatki piersiowej i kończyn (zwykle 12 odprowadzeń) komfortowe warunki badanej osoby (wygodne leżenie na kanapie), zatrzymanie oddechu w momencie zapisu EKG. Oczywiście podobne metody uzyskiwania EKG nie da się zastosować w zadaniach biometrycznych, w szczególności w systemach kontroli dostępu. W takich przypadkach konieczne jest zapewnienie, aby sygnał EKG był zapisywany tak łatwo, jak to jest możliwe, na przykład suche elektrody z palców lewej i prawej dłoni (wersja jednokanałowa zwana pierwszym odprowadzeniem). Oczywiście, że skutkuje to pogarszaniem jakości sygnału.

Jednak nie tylko liczba kanałów i jakość sygnału EKG różnią się w zastosowaniach diagnostyki medycznej czy biometrii, zupełnie inne są cele badania: w medycynie - ustalenie czy występuje odchylenie od normy EKG, a dla biometrii - dokonanie rozróżnienia EKG należących różnym podmiotom.

Uważa się, że na kształt sygnału EKG wpływa struktura mięśnia sercowego, jego lokalizacja w klatce piersiowej i inne cechy fizjologiczne. Liczne badania wykazały, że elektrokardiogram jest wiarygodnym markerem biometrycznym [15,16], ale w przeciwieństwie do rozpoznawania twarzy lub głosu, jest wcale niewygodny dla ludzkiej percepcji wzroku i słuchu. Klasyczne algorytmy cyfrowego przetwarzania sygnałów również okazały niską skuteczność, przede wszystkim ze względu na znaczną zmienność sygnału EKG. Tylko systemy oparte na uczeniu maszynowym mogą sprostać wyzwaniu polegającym na rozpoznawaniu ludzi za pomocą elektrokardiogramu. Ponadto dla biometrii istotnym jest to, że kształt fali tętna różni się w zależności od podmiotu [15].

Istnieją jednak poważne problemy z praktycznym zastosowaniem technologii uczenia maszynowego w rzeczywistych systemach biometrycznych opartych na EKG, jednym z których jest zależność od tętna. Tego rodzaju zmienność tętna może być obserwowana nie tylko między różnymi podmiotami, ale także dla jednej osoby w różnych okresach czasu (rys. 1).



Rysunek 1. Fragmenty sygnału EKG o różnym czasie trwania rytmu serca

W codziennym użyciu biometryczny system identyfikacji musi zapewniać inwariantność do zmiany tętna spowodowanej czynnikami fizycznymi, emocjonalnymi lub innymi. Problem z zestawami danych wykorzystywanymi do nauczania klasyfikatorów polega na tym, że EKG jest zwykle mierzone w ciągu jednego dnia przez krótki okres czasu. W rezultacie tętno w uzyskanych rekordach

jest dość stałe. Badania wykazały, że klasyfikatory stworzyły między innymi cechy charakterystyczne na podstawie tętna. Jest to oczywiście niepoprawnie, ponieważ aplikacje uwierzytelniające zwiększają liczbę odmów w dostępie dla prawdziwych użytkowników (rośnie liczba błędów typu 2).


Dlatego oprócz normalizacji amplitudy sygnał EKG, jako funkcja przestrzeni 2D, powinien podlegać normalizacji czasowej. Istotą podejścia zaproponowanego przez autorów jest skalowanie każdego segmentu elektrokardiogramu do danego standardowego okna, maksymalnie zachowując kształt sygnału EKG względem istotnych cech fizjologicznych każdego podmiotu. Zapewni to inwariantność systemu rozpoznawania do kompresji/rozciągania EKG zarówno w pionie, jak i w poziomie.

3. Struktura biometrycznego systemu identyfikacji

Schemat blokowy biometrycznego systemu identyfikacji oparty na sygnale EKG przedstawiono na rys. 2, a jego funkcjonowanie (z wyjątkiem węzła normalizacji tętna) opisano w pracach [17,18,19].

System identyfikacji biometrycznej obejmuje następujące elementy:

- Ogniwko pomiaru sygnału EKG;
- Ogniwko cyfrowego przetwarzania sygnału (CPS);
- Ogniwko segmentacji;
- Węzeł wykrywania i korekcji anomalii;
- Węzeł zmniejszający wymiar danych;
- Węzeł klasyfikacji i identyfikacji.



Rysunek 2 Schemat blokowy biometrycznego systemu identyfikacji

Ogniwo pomiaru EKG składa się z elektrod i elektroniki pomocniczej, za pomocą których mierzona jest zmiana różnicy potencjałów palców prawej i lewej dłoni, które odzwierciedlają pracę serca. Ta metoda rejestracji elektrokardiogramu odpowiada pierwszemu standardowemu odprowadzeniu, które jest stosowane w diagnostyce medycznej.

W kanale DSP zmierzony sygnał jest digitalizowany i poddawany filtrowaniu i normalizacji amplitudy. Do filtrowania zastosowano filtr pasmowo przepustowy Butterworth'a, umożliwiając odfiltrowanie fluktuacji niskiej częstotliwości z zarejestrowanego sygnału EKG, spowodowane ruchami lub oddychaniem człowieka, zakłóceniem sieci zasilania i szumami o wysokiej częstotliwości.

Ogniwo segmentacji służy do detekcji R-pików w zapisie EKG sygnału, umożliwiając wyodrębnienie segmentów odpowiadających jednemu uderzeniu serca. Do segmentacji wykorzystywany jest dobrze znany algorytm Hamiltona. Ponadto na tym etapie wykonywana jest normalizacja amplitudy sygnału (do skali ± 1). W pracy

tej zaproponowano również dodatkowe dostosowanie każdego segmentu EKG do określonego czasu trwania. Ta metoda normalizacji temporalnej stanowi cel niniejszej pracy i została szczegółowo opisana w następnym rozdziale.

W pracach [18,19,20] wykazano, że nawet po filtrowaniu w sygnale EKG pozostają zniekształcenia w postaci anomalnych odchyień pojedynczej lub serii próbek, co powoduje zmniejszenie dokładności identyfikacji osoby. W tym badaniu zastosowano statystyczną metodę wykrywania i korygowania anomalii, opisaną szczegółowo w [19].

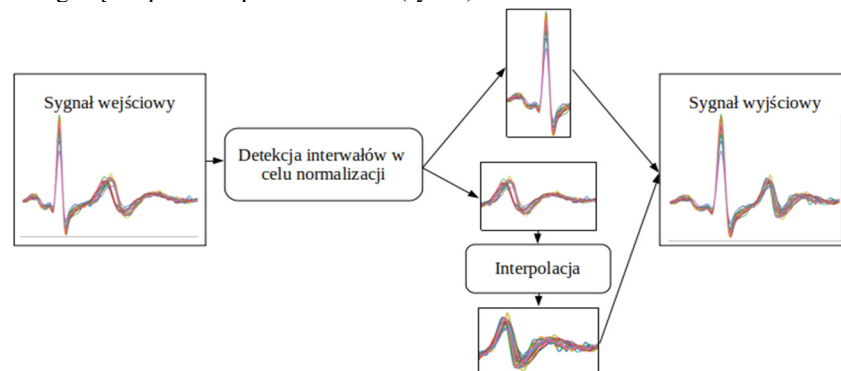
W uczeniu maszynowym jest często stosowane zmniejszenie wymiaru danych w celu poprawy wydajności klasyfikatora. W tym badaniu postanowiono zastosować metodę głównych składowych (Principle Component Analysis - PCA) jako jeden z najprostszyc, ale skutecznych algorytmów redukcji wymiaru danych [20].

Klasyfikator opiera się na kilku popularnych algorytmach uczenia maszynowego. Na podstawie eksperymentów sugeruje się wybranie najlepszego spośród: metody K najbliższych sąsiadów (KNearestNeighbor- KNN) [21], metody wektorów nośnych (SupportVector Machine - SVM)[22] i liniowej analizy dyskryminacyjnej (LinearDiscriminant Analysis - LDA)[23].

4. Opis metody temporalnej normalizacji sygnału EKG i jej wdrożenie

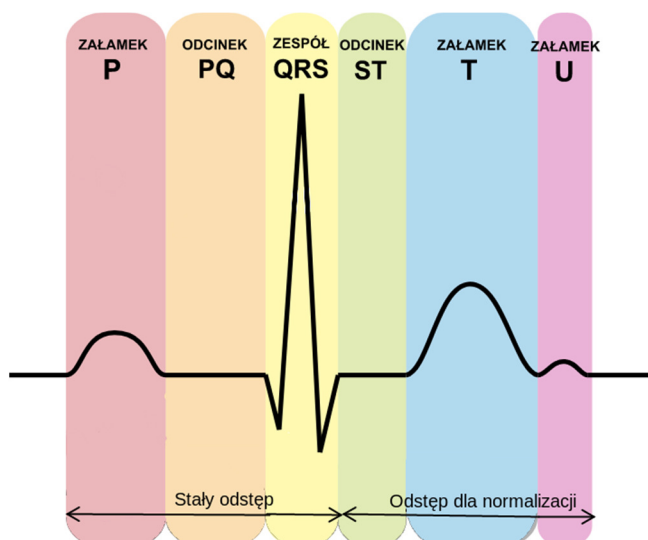
Aby zapewnić niezmiennosc klasyfikatora względem tętna, autorzy opracowali i zbadali metodę normalizacji czasu trwania każdego segmentu. Algorytm implementujący proponowaną metodę temporalnej normalizacji, prowadzi sygnały EKG od wszystkich ludzi do ustalonej, z góry określonej, jednakowej dla wszystkich wartości tętna. Wybór optymalnej wartości tętna dla zadań identyfikacji biometrycznej jest podany niżej.

Zestaw sygnałów EKG odpowiadających jednemu cyklowi serca jest podawany na wejście algorytmu. Długość tych sygnałów jest odwrotnie proporcjonalna do ludzkiego tętna podczas pomiaru EKG (rys. 3).



Rysunek 3. Schemat blokowy układu normalizacji temporalnej

W EKG cykl pracy serca dzieli się na załamki i odcinki, z których każdy odpowiada określonej fazie propagacji fali wzbudzenia w mięśniu sercowym (rys. 4).

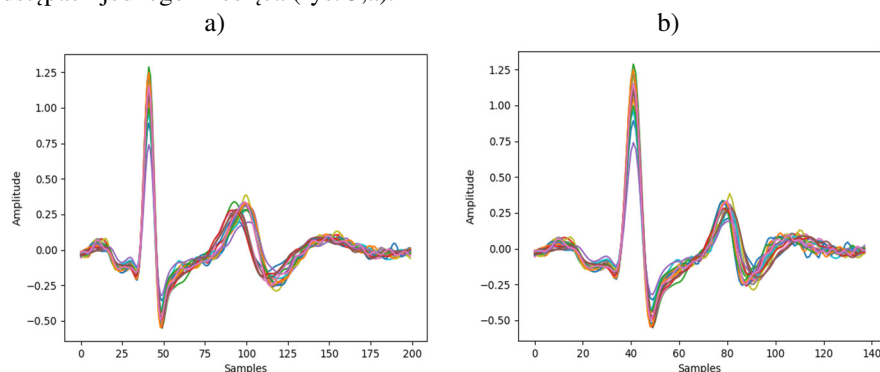


Rysunek 4 Struktura sygnału EKG w cyklu pracy serca [24]

Odstęp od początku załamka P do końca zespołu QRS pozostaje praktycznie stały, to znaczy, że niewiele zależy od zmiany tętna i dlatego na rys. 4 jest wskazany jako stały odstęp. Dlatego zadaniem bloku detekcji dla temporalnej normalizacji jest znalezienie i odizolowanie od sygnału każdego uderzenia serca zmiennego odstępu od początku odcinka ST do końca załamka U.

Węzeł interpolacji zmienia liniowo odstępy dla normalizacji tak, aby ich czas trwania zapewniał określone z góry okno. Na wyjściu algorytmu tworzony jest zestaw cykli sygnału EKG ze znormalizowanym tętnem w sposób połączenia stałych odstępuów z odpowiednimi interpolowanymi.

Zestaw wejściowy EKG powstał z wyników dwóch pomiarów wykonanych w odstępach jednego miesiąca (rys. 5,a).



Rysunek 5. Segmentowany sygnał EKG przed (a) i po (b) temporalnej normalizacji

Podczas pierwszego pomiaru uzyskano 6 cykli sygnału EKG z tętnem 90 uderzeń/min (uderzenia na minutę), podczas drugiego - 10 cykli z tętnem 75 uderzeń/min. Na wyjściu algorytmu temporalnej normalizacji wszystkie sygnały

są redukowane do tętna 120 uderzeń/min. Na rys. 5 można zaobserwować wyniki pracy algorytmu. Ważne jest zbadać i oszacować w jaki sposób normalizacja temporalna wpływa na dokładność klasyfikacji.

5. Metodologia eksperymentu i omówienie wyników

Do badań wykorzystano dane ze zgromadzonego przez autorów zestawu LvivBiometric Data Set [25], który w momencie pisania artykułu zawierał ponad 1400 zapisów EKG 95 osób. Wszystkie zapisy zostały zarejestrowane za pomocą urządzenia elektronicznego eHealth Sensor Platform v2.0 [26] i Arduino Uno [27]. Proces pomiarowy i specyfikacje sprzętu opisano bardziej szczegółowo w [17].

Aby ocenić efektywność algorytmu temporalnej normalizacji sygnału EKG w biometrycznych systemach identyfikacji, autorzy przeprowadzili eksperymenty w następujących konfiguracjach:

- Bez temporalnej normalizacji.
- Z temporalną normalizacją do wartości odpowiadającej 90 uderzeń/min.
- Z temporalną denormalizacją

Ponieważ baza danych zawiera głównie elektrokardiogramy zarejestrowane w krótkim okresie czasu, wartość tętna w tych pomiarach jest stała. Testowanie algorytmu temporalnej normalizacji sygnału EKG na podstawie tych pomiarów nie reprezentuje jego skuteczności. Dlatego do testów wdrożyliśmy temporalny denormalizator EKG, który dla każdego pomiaru zmienia wartość tętna na losową, która znajduje się w przedziale od 60 do 120 uderzeń na minutę.

Również dla powyższych konfiguracji sugeruje się opcjonalne zastosowanie algorytmu korekcji anomalii, ponieważ znacznie poprawia on dokładność zarówno systemu z temporalną normalizacją EKG, jak i systemu bez normalizacji. Powinno to zwiększyć reprezentatywność zastosowania algorytmu normalizacji temporalnej we współczesnych systemach, gdyż korekcja anomalii jest ich integralną częścią.

Jak wspomniano powyżej w badaniach wykorzystano trzy popularne metody uczenia maszynowego (LDA, SVM i KNN), a w celu redukcji danych wraz z zachowaniem ważnych informacji zastosowano metodę PCA.

Następnie losowo w proporcji 0,7/0,3 elektrokardiogramy podzielono na zestawy do treningu i testowania. W celu oceny skuteczności klasyfikacji został wybrany jeden z kluczowych wskaźników stosowanych w uczeniu maszynowym - dokładność [28]

$$ACC = \frac{(TP + TN)}{(P + N)}$$

gdzie TP i TN są odpowiednio liczbą poprawnie sklasyfikowanych klas pozytywnych i negatywnych, a P i N są odpowiednio całkowitą liczbą klas pozytywnych i negatywnych.

Dokładność rozpoznawania elektrokardiogramów z zestawu testowego podano w tabeli 1.

Dane w tabeli 1 na pierwszy rzut oka wykazały negatywny wynik zastosowania normalizacji temporalnej - zmniejszyła się dokładność rozpoznawania (około 5%) w porównaniu z wariantem bez normalizacji tętna. Wynika to z faktu, że klasyfikator systemu identyfikacji bez normalizacji sygnału EKG w trakcie nauczania

wykorzystuje wartość tętna jako parametr informacyjny. W systemach identyfikacji z normalizacją wartość tętna jest dostosowana do ustalonej z góry jednakowej wartości, więc wytrenowany w ten sposób klasyfikator popełnia błąd drugiego rodzaju, odrzucając kardiogramy prawdziwych podmiotów.

Tabela 1. Wydajność algorytmu normalizacji czasowej

Metoda klasyfikacji	Znormalizowane tętno	Znormalizowane tętno + korektor anomalii	Bez temporalnej normalizacji	Bez temporalnej normalizacji + korektor anomalii	Denormalizowane tętno	Denormalizowane tętno + korektor anomalii
LDA	79.61	93.49	86.12	95.56	68.28	90.01
SVM	71.93	89.50	74.15	93.78	54.71	80.23
KNN	65.23	89.79	77.63	96.95	44.32	63.47
PCA+LDA	78.50	95.87	83.09	96.25	63.16	92.34
PCA+SVM	67.56	91.00	69.85	93.95	47.63	82.37
PCA+KNN	72.48	90.40	78.72	97.09	47.87	64.17

Zastosowanie algorytmu temporalnej normalizacji eliminuje problem opisany powyżej. Dokładność systemów z temporalną normalizacją sygnału EKG jest o 10–15% wyższa niż w systemach ze denormalizowanym sygnałem wejściowym. Potwierdza to, że algorytm normalizacji temporalnej jest ważnym i niezbędnym elementem w rzeczywistym systemie identyfikacji biometrycznej.

6. Wnioski

Na podstawie testowania podejścia opisanego powyżej możemy wyciągnąć następujące wnioski.

Algorytm zastosowany w tej pracy wykazał dobre wyniki w testowaniu ze zdenormalizowanym tętnem, co reprezentuje codzienne korzystanie z biometrycznego systemu identyfikacji.

Cechą dostępnych zestawów elektrokardiogramów jest to, że ich rejestracja dla każdego obiektu była wykonywana przez krótki okres czasu. Tętno w tych pomiarach jest prawie identyczne. Klasyfikatory systemów biometrycznych wykorzystują tę funkcję jako cechę informacyjną, za pomocą której przeprowadzają identyfikację. Problem ten można rozwiązać za pomocą jednego z trzech podejść: zwiększenia objętości danych, wykorzystania algorytmów temporalnej normalizacji sygnału EKG lub zastosowania algorytmów temporalnej denormalizacji do szkoleniowych zbiorów danych klasyfikatorów.

Zgodnie z wynikami eksperymentów najlepszy wynik identyfikacji (dokładność 95,87%) uzyskano przy zastosowaniu zaproponowanego algorytmu normalizacji

temporalnej sygnałów EKG, metody wykrywania i korekcji anomalii, metody głównych składowych (PCA) do redukcji wymiaru danych i liniowej analizy dyskryminacyjnej (LDA) jako klasyfikatora .

LITERATURA

1. GACEK A., PEDRYCZ W. (Eds) ECG signal processing, classification and interpretation. A comprehensive framework of computational intelligence. Springer - London, Dordrecht, Heidelberg, New York, 2012
2. KHOMA V., PELC M., KHOMA Y. Artificial Neural Network Capability for Human Being Identification based on ECG // Proceedings: The 23rd International Conference on Methods and Models in Automation and Robotics, Miedzyzdroje, 27-30 August 2018. pp. 479 – 482.
3. Heart rate variability: standards of measurement, physiological interpretation, and clinical use. Guidelines. - European Heart Journal (1996) 17, 354–381.
4. SHAFFER F., GINSBERG J. P. An Overview of Heart Rate Variability Metrics and Norms. *Front. Public Health* 5:258. (2017).
5. KOSHY A., OKWOSE N. C., NUNAN D. Association between heart rate variability and haemodynamic response to exercise in chronic heart failure. *Scandinavian Cardiovascular Journal*, 2019.
6. SELVARAJ N., JARYAL A., SANTHOSH J., DEEPAK K. K., ANAND S. Assessment of heart rate variability derived from finger-tip photoplethysmography as compared to electrocardiography. *Journal of Medical Engineering & Technology*, Volume 32, 2008 - Issue 6.
7. PORGES S.W. . The Polyvagal Theory: phylogenetic contributions to social behavior. *Physiology & Behavior*. 2003, 79 (3): pp503–513.
8. Li M., NARAYANAN S. Robust ECG biometrics by fusing temporal and cepstral information, in Proc. IEEE Int. Conf. Pattern Recognit. (ICPR), Aug. 2010, pp. 1326_1329.
9. KIM K.S., YOON T.H., LEE J.W., KIM D.J., KOO H.S. A robust human identification by normalized time-domain features of electrocardiogram. In: 27th annual international conference of the engineering in medicine and biology society, 2005 IEEE-EMBS 2005. 2005. p. 1114–7.
10. RABKIN S.W., SZEFER E., THOMPSON D. J.S.. A New QT Interval Correction Formulae to Adjust for Increases in Heart Rate. *JACC: Clinical Electrophysiology*, Volume 3, Issue 7, 2017, pp. 756-766.
11. TAWFIK M.M., SELIM H., KAMAL T. Human identification using time normalized QT signal and the QRS complex of the ECG. In Proc. 7th Int. Symp. Commun. Syst. Netw. Digit. Signal Process. (CSNDSP), Jul. 2010, pp. 755-759.
12. FATEMIAN S. Z., HATZINAKOS D. A new ECG feature extractor for biometric recognition. In Proc. IEEE Int. Conf. Digit. Signal Process., Jul. 2009, pp. 1-6.
13. LOURENÇO A., SILVA H., FRED A. Unveiling the biometric potential of finger-based ECG signals, *Comput. Intell. Neurosci*, vol. 2011, p. 5, Jan. 2011.
14. JENKINS, D., GERRED, S.: ECGs by Example, 3rd edn., 238 p. Eلسilver, 2011.

15. PINTO J.R., CARDOSO J.S., LOURENÇO A. Evolution, Current Challenges, and Future Possibilities in ECG Biometrics. *IEEE Access*, Volume 6, 2018, pp. 34746-34776.
16. PELC M., KHOMA Y., KHOMA V. ECG Signal as Robust and Reliable Biometric Marker: Datasets and Algorithms Comparison // *Sensors*, 2019, 19(10), 2350, p. 1-8.
17. WIECLAW, L., KHOMA, Y., FAŁAT, P., SABODASHKO, D., HERASYMENKO V. Biometric identification from raw ECG signal using deep learning techniques. In 2017 9th IEEE International Conference on Intelligent Data Acquisition and Advanced Computing Systems: Technology and Applications (IDAACS) (Vol. 1, pp. 129-133).
18. URIGÜEN, J.A, GARCIA-ZAPIRAIN B.: EEG artifact removal-state-of-the-art and guidelines. *J Neural Eng.* 12 (3), June (2015)
19. KHOMA, V., PELC, M., KHOMA, Y., SABODASHKO D. Outlier Correction in ECG-Based Human Identification. *Biomedical Engineering and Neuroscience: Proceedings of the 3rd International Scientific Conference on Brain-Computer Interfaces, BCI 2018, Opole, Poland (Vol. 720, p. 11)*. Springer.
20. KARPINSKI, M., KHOMA, V., DUDYKEVYCH, V., KHOMA, Y., & SABODASHKO, D. Autoencoder Neural Networks for Outlier Correction in ECG-Based Biometric Identification. In 2018 IEEE 4th International Symposium on Wireless Systems within the International Conferences on Intelligent Data Acquisition and Advanced Computing Systems (IDAACS-SWS) (pp. 210-215). IEEE.
21. Serwis internetowy K najbliższych sąsiadów: <https://scikit-learn.org/stable/modules/generated/sklearn.neighbors.KNeighborsClassifier.html>, 01.10.2019
22. Serwis internetowy Maszyna wektorów nośnych: <https://scikit-learn.org/stable/modules/generated/sklearn.svm.SVC.html>, 01.10.2019
23. Serwis internetowy Analiza dyskryminacyjna: <https://scikit-learn.org/0.16/modules/generated/sklearn lda.LDA.html>, 01.10.2019
24. Serwis internetowy Elektrokardiografia: <https://pl.wikipedia.org/wiki/Elektrokardiografia>, 01.10.2019
25. Serwis internetowy Lviv Biometric Data : <https://github.com/YuriyKhoma/Lviv-Biometric-Data-Set>, 01.10.2019
26. Serwis internetowy e- Health Sensor Platform V2.0 for Arduino and Raspberry Pi: <https://www.cooking-hacks.com/documentation/tutorials/ehealth-biometric-sensor-platform-arduino-raspberry-pi-medical>, 01.10.2019
27. Serwis internetowy Arduino UNO & Genuino UNO: <https://www.arduino.cc/en/Main/arduinoBoardUno>, 01.10.2019
28. Serwis internetowy Accuracy and precision: https://en.wikipedia.org/wiki/Accuracy_and_precision, 01.10.2019