

## KLASYFIKACJA SYGNAŁU EKG PRZY UŻYCIU KONWOLUCYJNYCH SIECI NEURONOWYCH

Maria OGRYCZAK

Politechnika Gdańska, Wydział Elektrotechniki i Automatyki  
tel.: 790 557 758 e-mail: maria.ogryczak@gmail.com

**Streszczenie:** Podniesienie jakości i zautomatyzowanie procesu diagnozy jest istotnym elementem rozwoju medycyny i samokontroli stanu zdrowia pacjentów. Od dłuższego czasu istnieją i są stosowane różne metody analizy i klasyfikacji sygnału EKG, jednak nie zawsze ich dokładność jest zadowalająca. Największym problemem jest trudność rozpoznania istniejącej nieprawidłowości, w przypadku gdy jej reprezentacja jest podobna do prawidłowej pracy serca np. przedwczesny skurcz komorowy. W ostatnich latach obserwujemy dynamiczny rozwój nowego narzędzia z rodziny metod sztucznej inteligencji - głębokich sieci neuronowych. Cechuje je duża selektywność klasyfikacji nawet najbardziej skomplikowanych sygnałów w postaci szeregów czasowych czy obrazów, często na podstawie cech niezauważalnych dla ludzkiego oka. W niniejszym artykule przedstawiono sposób analizy zarejestrowanego sygnału elektrycznej czynności mięśnia sercowego (EKG), na podstawie pojedynczego, wyodrębnionego cyklu pracy serca. Celem badania było zdiagnozowanie sześciu różnych typów ewolucji mogących świadczyć o występowaniu arytmii. Badania przeprowadzono z wykorzystaniem ogólnodostępnej bazy danych MIT-BIH Arrhythmia Database. W celu podniesienia jakości ekstrakcji cech analizowanego sygnału, dokonano jego dekompozycji czasowo - przestrzennej przy wykorzystaniu transformacji falkowej. W rezultacie uzyskano zadowalające wyniki klasyfikacji: dokładność 92,4% i swoistość (zdolność do wykrycia braku cechy) 96,5%. Osiągnięte wyniki potwierdzają skuteczność systemu automatycznej klasyfikacji cykli pracy serca, mogącego wspomóc lekarzy w procesie żmudnej analizy dużej liczby zarejestrowanych danych.

**Słowa kluczowe:** EKG, arytmia, głębokie uczenie, konwolucyjne sieci neuronowe

### 1. WSTĘP

W ostatnich latach można zauważyć dynamiczny rozwój narzędzi sztucznej inteligencji. Wykorzystuje się je w wielu dziedzinach, przede wszystkim w celu automatyzacji i przyspieszenia procesów analizy danych. Sztuczne sieci neuronowe stanowią jedną z technik używaną w uczeniu maszynowym, natomiast konwolucyjne sieci neuronowe (CNN) to jeden z typów głębokich sieci neuronowych, w których podstawową operacją jest splot. W niniejszym artykule opisane zostały badania, w których konwolucyjne sieci neuronowe, bazujące na zdekomponowanych w dziedzinie czasu i częstotliwości sygnałach z elektrokardiografu (EKG), zastosowano do klasyfikacji nieprawidłowości w pracy serca.


Choć istnieją już systemy do analizy sygnału EKG, problemem w ich dotychczasowym stosowaniu jest relatywnie niska swoistość, czyli stosunek wyników

prawdziwie ujemnych do sumy prawdziwie ujemnych i fałszywie dodatnich. W zagadnieniach medycznych, swoistość, oprócz dokładności jest niezwykle istotnym wskaźnikiem, ponieważ sytuacja, w której chory pacjent klasyfikowany jest jako zdrowy lub odwrotnie jest niedopuszczalna. Klasyfikacja sygnału EKG sprowadza się do wyznaczenia amplitudy i czasu trwania charakterystycznych załamek oraz relacji czasowych pomiędzy nimi. Klasyfikacja patologicznych stanów bazuje na porównywaniu segmentu sygnału EKG np. zespołu QRS z wzorcami różnych stanów patologicznych. Dynamiczny rozwój sieci neuronowych powoduje, że prowadzi się coraz więcej badań dotyczących automatycznej analizy i klasyfikacji sygnału EKG [1, 2, 3, 7, 8, 10, 11, 12]. Splotowe sieci neuronowe pozwalają na wyodrębnienie cech automatycznie, dzięki temu mogą zostać wykryte właściwości nie brane pod uwagę podczas korzystania z dotychczas stosowanych metod. Testuje się efektywność różnych algorytmów takich jak drzewa decyzyjne [11], przy użyciu których udało się uzyskać dokładność aż 98,03% czy korzystając z sieci typu Echo State (ESN) [10], gdzie parametr ten wyniósł 93,4 %. Badano także konwolucyjne sieci neuronowe [2], lecz proces przetwarzania danych przebiegał inaczej niż w niniejszej pracy. Pod uwagę brany był cały interwał R-R (rysunek 1), ale sygnał nie był przetwarzany. Proponowane w artykule podejście ogranicza badany sygnał do zespołu QRS, jednak dzięki użyciu transformacji falkowej możliwe jest uzyskanie większej ilości istotnych informacji, co w efekcie może skutkować pewniejszymi wynikami diagnozy. Należy również zwrócić uwagę na całościowe podejście do problemu. W niektórych pracach, jak na przykład [7] rezygnuje się z klasyfikacji niektórych chorób lub podobne nieprawidłowości klasyfikuje się jako jedną klasę. Skutkuje to lepszymi parametrami wykrywania, ale nie zapewnia w pełni automatycznego i dokładnego rozwiązania problemu. Jednym z głównych celów przedstawianych badań było zapewnienie pełnej klasyfikacji nieprawidłowych cykli pracy serca z uwzględnieniem różnych rodzajów arytmii i typów ewolucji.

### 2. ANALIZA SYGNAŁU EKG – WPROWADZENIE

Sygnał EKG reprezentuje różnicę biopotencjałów w dwóch różnych punktach ciała człowieka, które są rejestrowane za pomocą elektrod. Tor pomiarowy w elektrokardiografie zapewnia odpowiednie kondycjonowanie

sygnału pomiarowego. Na rysunku 1 przedstawiono sygnał EKG reprezentujący prawidłowy cykl pracy serca. Arytmia jest powszechnie występującym schorzeniem, które powoduje różne zmiany w zapisie sygnału EKG. W ogólności można powiedzieć, że są to wszelkie nieprawidłowości w pracy serca, zarówno te epizodyczne jak i przewlekłe. Nie każda arytmia jest groźna dla życia bądź zdrowia pacjenta i nie każdy rodzaj arytmii należy leczyć. Niemniej jednak istotne jest wykrycie wszelkich nieprawidłowości, gdyż mogą one prowadzić w przyszłości do poważniejszych schorzeń.



Rys. 1. Sygnał EKG znamieny dla prawidłowego cyklu pracy serca: depolaryzacja przedsionków (załamek P), depolaryzacja komór (zespół QRS), repolaryzacja komór (załamek T) [1]

Ponadto nieprawidłowa praca serca może być sygnałem o złym stanie innych narządów. Dany rodzaj arytmii może reprezentować kilka różnych typów ewolucji, z kolei typ ewolucji nie świadczy jednoznacznie o rodzaju arytmii. Ich określenie jest jednak niezbędne przy postawieniu właściwej diagnozy. Typy ewolucji serca oraz analizowane rodzaje arytmii serca przedstawiają Tablice 1-2.

Tablica 1. Liczba danych użytych do badań, reprezentujących poszczególne typy ewolucji serca

| Typ ewolucji serca                    | Liczba danych |
|---------------------------------------|---------------|
| Blok lewej odnogi pęczka Hisa (L)     | 7120          |
| Blok prawej odnogi pęczka Hisa (R)    | 8059          |
| Przedwczesny skurcz przedsionkowy (A) | 7240          |
| Przedwczesny skurcz komorowy (V)      | 2536          |
| Fala migotania komór (I)              | 472           |
| Komorowy rytm zastępczy (E)           | 106           |
| Prawidłowy rytm (N)                   | 15000         |

Do badań wykorzystano reprezentatywną bazę danych MIT-BIH Arrhythmia Database [6], należąca do grupy Physionet, w której zebrane zostały różne sygnały fizjologiczne. Baza ta została stworzona w 1997 roku przez Massachusetts Institute of Technology i Boston's Beth Israel Hospital. W jej skład wchodzi między innymi 48 zapisów EKG uzyskanych od 47 różnych pacjentów w wieku od 23 do 89 lat. Pliki zawierają sygnały EKG zarejestrowane w ciągu około 30 minut każdy i zostały poddane filtracji za pomocą filtru środkowoprzepustowego oraz próbkowaniu z częstotliwością 360 próbek na sekundę. W sumie zebrano

ponad 110 000 pojedynczych cykli pracy serca wraz z adnotacją o typie ewolucji i rodzaju arytmii (choroby), jaką reprezentują. Ze względu na to, że przeważającą liczbę danych stanowi prawidłowy rytm serca, co może mieć niekorzystny wpływ na proces uczenia, zdecydowano się na ograniczenie tego zbioru z 70000 do 15000 przykładów w każdym wypadku.

Tablica 2. Liczba danych użytych do badań, reprezentujących poszczególne rodzaje arytmii

| Rodzaj arytmii                          | Liczba danych |
|---|---------------|
| Migotanie przedsionków (AFIB)           | 12104         |
| Trzepotanie przedsionków (AFL)          | 708           |
| Przedwczesne skurcze komorowe (B)       | 3536          |
| Prawidłowy rytm zatokowy (N)            | 15000         |
| Rytm serca pochodzący z rozrusznika (P) | 8046          |
| Zespół preekscytacji (PREX)             | 1018          |
| Bradykardia zatokowa (SBR)              | 1810          |
| Częstoskurcz nadkomorowy (SVTA)         | 491           |
| Trigemina komorowa (T)                  | 1451          |
| Trzepotanie komór (VFL)                 | 484           |
| Częstoskurcz komorowy (VL)              | 463           |

### 3. ARCHITEKTURA PROPONOWANEGO SYSTEMU

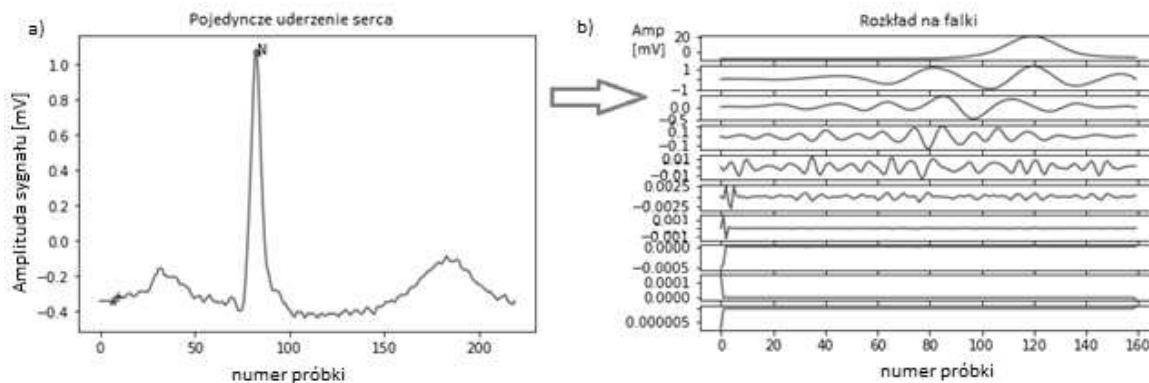
#### 3.1. Dekompozycja sygnału EKG

Efektywna analiza sygnałów niestacjonarnych wymaga innych narzędzi niż splot czy transformacja Fouriera. Do prawidłowej ekstrakcji istotnych, charakterystycznych cech analizowanego sygnału bardzo przydatna jest równoczesna analiza czasowych i częstotliwościowych jego własności. Skutecznym narzędziem do tego typu dekompozycji sygnałów jest analiza falkowa (1) [8, 9]. Analiza falkowa polega na przejściu do dziediny czas - częstotliwość (skala), w którym rozpatrywany jest sygnał. Pozwala ona analizować zmianę częstotliwości w czasie, w odróżnieniu od transformacji Fouriera, która takich informacji nie dostarcza. Zasadniczo składa się ona z funkcji falkowej pełniącej rolę filtru pasmowo - przepustowego i funkcji skalującej odpowiadającej za aproksymację. Są one ze sobą ściśle powiązane, ponieważ z falki podstawowej jest tworzona rodzina falek przez zmianę skali (Rys. 2).

$$\Psi_{j,k}(t) = 2^{\frac{j}{2}} \Psi(2^j t - k), \text{ gdzie} \quad (1)$$

$\Psi$  - falka podstawowa,  $j$  - rozdzielczość,  $k$  - przesunięcie

Podczas badań z użyciem transformacji falkowej wykorzystano falek Daubechies (db4), która jest przeważnie używana w przetwarzaniu sygnału EKG. Według [4] dostarcza ona najwięcej istotnych informacji, ponieważ jej kształt zbliżony jest do zespołu QRS. Użycie trybu 'symmetric' pozwoliło na podwojenie próbek przez odbicie lustrzane w przypadku potrzeby uzupełnienia sygnału.



Rys. 2. a) Sygnał EKG – jeden cykl pracy serca, b) Wynik dekompozycji za pomocą transformacji falkowej

Liczba falek otrzymanych z tej operacji wyniosła 10 i została wybrana automatycznie po uwzględnieniu długości sygnału (jednego cyklu pracy serca). Efektem operacji była macierz o 10 wierszach, gdzie w każdym był nowo powstały sygnał.

### 3.2. Konwolucyjna sieć neuronowa

Do klasyfikacji nieprawidłowości w zdekomponowanym w dziedzinie czasu i częstotliwości sygnale EKG wykorzystano konwolucyjną, głęboką sieć neuronową [5]. Sieci te znane są z dużej skuteczności klasyfikacji, poprzedzonej automatyczną ekstrakcją cech z danych wejściowych. Sieci konwolucyjne są naturalnie predysponowane do pracy z danymi w postaci dwuwymiarowej, co uzyskano również dzięki dekompozycji sygnału. Macierze 10x160, gdzie 10 to liczba uzyskanych sygnałów, a 160 to ich długość, zostały przekształcone przy użyciu funkcji reshape() oraz resize() tak, aby były kwadratowe i miały odpowiednio wymiary 20, 40, 70 i 100.

Tablica 3. Architektura sieci CNN

| CNN   |
|---|
| Warstwa wejściowa ( $n \times n \times 3$ ) |
| Konwolucja ( $2 \times 2, 32$ )             |
| Maxpooling ( $2 \times 2$ )                 |
| Konwolucja ( $2 \times 2, 64$ )             |
| Maxpooling ( $2 \times 2$ )                 |
| Konwolucja ( $2 \times 2, 64$ )             |
| Maxpooling ( $2 \times 2$ )                 |
| MLP (64)                                    |
| Wyjście ( $m$ neuronów sigmoidalnych)       |

Na podstawie wielu badań eksperymentalnych, zaproponowano strukturę sieci składającej się z dziewięciu warstw (Tablica 3). Pierwsza to warstwa wejściowa, kolejna to warstwa wspomnianej wcześniej konwolucji. Zdecydowano się na 32 filtry o wielkości 2x2 każdy. Spośród dostępnych funkcji aktywacji wybrano ReLU. Następną stanowiła warstwa głosująca, gdzie wykorzystany został max-pooling. Polega on na wyciągnięciu maksymalnej wartości z danego obszaru (w tym wypadku kwadrat o boku dwóch pixeli), co pozwala na zmniejszenie obrazu. Sekwencja tych dwóch warstw została powtórzona trzykrotnie. Ostatnie dwie to z kolei pełna sieć MLP i klasyfikator będący warstwą wyjściową. W tym wypadku funkcją aktywacji była funkcja softmax. Rozmiar warstwy wyjściowej był liczbą wyodrębnionych klas - dla klasyfikacji ze względu na chorobę jest ich 11, natomiast w przypadku typów ewolucji 7.

W trakcie uczenia sieci zastosowano funkcję kryterialną w postaci entropii krzyżowej (ang. sparse

categorical cross entropy loss), którą minimalizowano przy użyciu algorytmu optymalizacji Adam (ang. adaptive moment estimation), przez 20 epok. Zarówno do zbioru walidacyjnego, jak i testującego wybrano losowo po 20 cykli pracy serca reprezentujących daną klasę.

### 3.3. Wskaźniki jakości sieci

W badaniach dotyczących zagadnień medycznych z zastosowaniem sieci neuronowych niezwykle istotne jest nie tylko uzyskanie odpowiedniej dokładności, ale również swoistości. W przypadku analizy EKG, swoistość to wartość stosunku ewolucji serca zaklasyfikowanych jako prawidłowe do sumy takich właśnie przypadków i fałszywie uznanych za prawidłowe. Powinna ona znajdować się w przedziale od 0 do 1, im jej wartość jest mniejsza tym większe ryzyko pominięcia niektórych nieprawidłowości. Oprócz swoistości analizowano czułość (precyzję) będącą wartością stosunku wyników prawdziwie dodatnich do sumy prawdziwie dodatnich i fałszywie ujemnych oraz dokładność.

## 4. WYNIKI PRZEPROWADZONYCH BADAŃ

Ocenę przeprowadzonych eksperymentów oraz wyniki klasyfikacji ze względu na typ ewolucji serca oraz rodzaj choroby zamieszczono w Tablicy 4. Wyniki dla obu przypadków klasyfikacji są zadowalające, jednak klasyfikacja ze względu na typ ewolucji jest bardziej jednoznaczna. W obu przypadkach najlepsze wskaźniki otrzymano dla obrazów wejściowych o rozmiarze 40 i 100, przez co nie można zauważyć wyraźnej zależności między rozmiarem obrazu i skutecznością klasyfikacji sieci. Wpływa on jednak znacząco na liczbę parametrów sieci oraz na czas uczenia. Niecelowe wydaje się więc stosowanie rozmiarów większych niż 40.

W przypadku klasyfikacji pod względem typu ewolucji serca otrzymano największą dokładność równą 92,4% i swoistość wynoszącą 96,5%, podczas gdy dla rodzaju choroby dokładność wynosi 83,1%, a swoistość 91,1%. Wartość precyzji również jest znacząco większa - 82,9% dla sieci klasyfikującej pojedyncze cykle pracy serca ze względu na ich typ, podczas gdy w drugim przypadku wyniosła ona 55,6%. Rozbieżność tego właśnie parametru jest największa.

Dokonano również porównania otrzymanych wyników z podobnymi opublikowanymi badaniami dotyczącymi klasyfikacji nieprawidłowości w sygnale EKG. Autorzy w pracy [10] korzystając z sieci typu Echo State osiągnęli precyzję równą 86,1% oraz swoistość 92,7% przy odczycie wartości sygnału EKG z jednego kanału pomiarowego oraz 75,1% precyzji i 95,7% swoistości dla innego, podczas gdy w opisywanych w niniejszej pracy badaniach udało się uzyskać większą swoistość - 96,5% i precyzję wynoszącą

82,9%. Z kolei w pracy [2] autorzy uzyskali większą dokładność - równą 93,4%, jednak nie opublikowali oni wartości swoistości uzyskanej przez ich system. Na podkreślenie zasługuje fakt, że przedstawione podejście, w odróżnieniu od niektórych prac np. [7] jest wieloklasowe, czyli oprócz stwierdzenia anomalnego charakteru EKG, umożliwia wskazanie konkretnego schorzenia.

Tablica 4. Wyniki klasyfikacji ze względu na typ ewolucji serca oraz rodzaj choroby

| Rozmiar macierzy   | Dokładność | Precyzja | Swoistość |
|--------------------|------------|----------|-----------|
| Rodzaj choroby     |            |          |           |
| 20                 | 0,7818     | 0,5143   | 0,9006    |
| 40                 | 0,8318     | 0,5556   | 0,9106    |
| 70                 | 0,7727     | 0,4474   | 0,8931    |
| 100                | 0,8091     | 0,5588   | 0,9138    |
| Typ ewolucji serca |            |          |           |
| 20                 | 0,9095     | 0,8286   | 0,9643    |
| 40                 | 0,9238     | 0,8286   | 0,9649    |
| 70                 | 0,9143     | 0,8235   | 0,9647    |
| 100                | 0,9238     | 0,8286   | 0,9649    |

## 5. PODSUMOWANIE

Zaproponowana metoda analizy sygnału EKG umożliwia klasyfikację różnych typów ewolucji serca i chorób z dużą dokładnością i dobrą swoistością, która jest bardzo ważnym parametrem w ocenie systemów wspomagających lekarzy.

Dekompozycja sygnału EKG przy pomocy transformacji falkowej umożliwiła pozyskanie z sygnału cennych informacji, co pozwoliło na wyłonienie właściwych cech w dalszym etapie klasyfikacji, przy pomocy głębokiej, konwolucyjnej sieci neuronowej.

Zaproponowane podejście może służyć jako cenny system wspomagania decyzji lekarzy, jako narzędzie do badań przesiewowych, w telemedycynie, czy też jako narzędzie do samokontroli pacjenta. Należy jednak mieć na uwadze fakt, że klasyfikacja dokonana tą metodą powinna być każdorazowo zweryfikowana przez lekarza.

## 6. BIBLIOGRAFIA

- Ogryczak M.: Klasyfikacja sygnału EKG przy użyciu głębokich sieci neuronowych, praca magisterska, Warszawa: Politechnika Warszawska, 2019.
- Kachuee M., Fazeli S., Sarrafzadeh M.: ECG Heartbeat Classification: A Deep Transferable Representation, 2018 IEEE international conference on healthcare informatics (ICHI), Nowy Jork, 2018.
- Jose da S., Luz E., Schwartz W., Camara-Chavez G., Menotti D.: ECG-based heartbeat classification for arrhythmia detection: a survey, *Computer Methods and Programs in Biomedicine*, vol.127, 2016, pp. 144-164.
- Haddadi R., Abdelmounim E., El Hanine M.: Discrete Wavelet Transform Based Algorithm for Recognition of QRS Complexes, *World of Computer Science and Information Technology Journal*, vol. 4, nr 9, 2014, pp. 127-132.
- Goodfellow I., Bengio Y., Courville A.: *Deep Learning*, MIT Press, 2016.
- Goldberger A., Amaral L., Glass L., Hausdorff J., Ivanov P., Mark R., Mietus J., Moody G., Peng C.-K., Stanley H.: *PhysioBank*, [Online]. Available: <http://circ.ahajournals.org/content/101/23/e215.full> [Data uzyskania dostępu: 2019 06 25].
- Celesti F., Celesti A., Carnevale L., Galletta A., Campo S., Romano A., Bramanti P., Villari M.: *Big data analytics in genomics: the point on deep learning solutions*, New York, 2017.
- Białasiewicz J. T.: *Falki i aproksymacje*, Wydawnictwo Naukowo-Techniczne, 2000.
- Berkowski P., *Transformata falkowa*, [Online]. [https://iel.pl/uploads/PL/PL\\_3\\_Nasza\\_Oferta/3\\_Dzialalnosc\\_Naukowa/5\\_Studia%20doktoranckie/wyklady/wyklad\\_falki.pdf](https://iel.pl/uploads/PL/PL_3_Nasza_Oferta/3_Dzialalnosc_Naukowa/5_Studia%20doktoranckie/wyklady/wyklad_falki.pdf) [Data uzyskania dostępu: 21 05 2019].
- Alfaras M., Soriano M., Ortin S.: A Fast Machine Learning Model for ECG-Based Heartbeat Classification and Arrhythmia Detection, *Front. Phys.*, 18 07 2019.
- Alarsan F., Younes M.: Analysis and classification of heart diseases using heartbeat features and machine learning algorithms, *Journal of Big Data*, 31 08 2019.
- Acharya U., Lih Oh S., Hagiwara Y., Hong Ten J., Adam M., Gertych A., San Tan R.: A deep convolutional neural network model to classify heartbeats, vol. 89, 2017, pp. 389-396.

## ECG SIGNAL CLASSIFICATION USING CONVOLUTIONAL NEURAL NETWORKS

Automation and improvement of diagnostic process is a vital element of medicine development and patient's condition self-control. For a long time different ECG signal classification methods exist and are successfully applied, nevertheless their accuracy is not always satisfying enough. The lack of identification of an existing abnormality, which is very similar to a normal heartbeat is the biggest issue - for example premature ventricular contraction. Over the past few years there was a rapid development of an artificial intelligence tool - deep neural networks. They characterise by a high classification ability even the most complicated patterns in the form of time series or images, often based on features unnoticeable for human eye. In this paper the approach to electrocardiography (ECG) analysis was presented, taking into consideration a single heartbeat. The aim of this research was diagnosis of six different types of beat that may indicate arrhythmia occurrence. The study were performed on the public database MIT-BIH Arrhythmia Database. In order to enhance feature extraction quality of the analysed signal the time-space decomposition was made using wavelet transform. The satisfying performance with 92.4% accuracy and 96.5% specificity were accomplished. The achieved results may be used to develop an automatic heartbeat classification system that would significantly contribute medicians in the arduous process of data analysis.

**Keywords:** ECG, arrhythmia, deep learning, convolutional neural networks.