

# HEART BEAT CLASSIFICATION

**Tomáš Potočňák**

Master Degree Programme (2), FEEC BUT

E-mail: xpotoc00@stud.feec.vutbr.cz

Supervised by: Marina Ronzhina

E-mail: ronzhina@feec.vutbr.cz

**Abstract:** The aim of this work was to develop the method for classification of ECG beats into two classes, namely ischemic and non-ischemic beats. Heart beats (QRS-T cycles) from animal orthogonal ECGs were preprocessed and used as input signal. Spectral features vectors (values of cross spectral coherency) were derived from the beats and the beats were classified using feedforward multilayer neural network designed in Matlab. Classification performance reached the value approx. 99%. Presented results can be suitable in future studies aimed to automatic classification of ECG.

**Keywords:** Heart beat classification, cardiac ischemia, cross spectral coherency analysis, artificial neural network

## 1. ÚVOD

Klasifikácia srdečných cyklov poskytuje prostriedok k správnej predikcii, výbere medikácie ako aj pochopeniu jednotlivých dejov v oblasti srdečných abnormalít a patológií. Zatiaľ čo ručná klasifikácia EKG je pomerne presná, vytvorenie komplexnej štúdie dlhodobého merania je časovo náročné. Tu môže pomôcť počítačová klasifikácia s vhodne zvolenou analýzou signálu a klasifikačnou metódou. V dnešnej dobe je často používanou metódou klasifikácia pomocou neurónovej siete, ktorá dokáže pomocou procesu učenie vytvoriť aj náročnejšie logické väzby (viď napr. [1]). V našom prípade sme sa zamerali na klasifikáciu srdečnej ischémie. Zatiaľ čo sa pre jej detekciu obyčajne používajú štúdie založené na morfológii EKG, ktoré sú náročne na detekciu jednotlivých častí EKG krivky a taktiež na kvalitu signálu, dochádza aj k experimentom s detekciou ischémie vo frekvenčnej oblasti. Výhodou frekvenčnej analýzy EKG je ľahšia detekcia (postačuje detekovať R-pik) a vyššia odolnosť voči šumu (viď napr. [1], [2], [3]).

## 2. VSTUPNÉ DATA

Ako vstupné dáta experimentu slúžia animálne elektrogramy (EG), získané meraním na chirurgicky extrahovanom králičom srdci pomocou troch ortogonálnych zvodov I, II a III so vzorkovacou frekvenciou  $f_{vz} = 2000\text{Hz}$  [4].

V priebehu experimentu sa odpojením perfúzie srdca fyziologickým roztokom vyvolávala opakovane srdečná ischémia. Takto získané dáta boli rozdelené do viacerých fázy pričom ako vstupné dáta slúžia srdečné cykly (P-QRS-T segmenty) z kontrolnej fázy (3175 cyklov), z prvej (248 cyklov), druhej (409 cyklov) a tretej (531 cyklov) ischemickej fázy.

V nameraných signáloch boli detekované R-piky a následne zostavená matica o veľkosti 800 vzoriek ( $R - 299 : R + 500$  vzoriek)  $\times$  počet cyklov v danej fázy. Pre naše účely sme cykly skrátili len na úseky QRS-T o 550 vzorkách ( $R-49 : R+500$  vzoriek), keďže práve v oblasti QRS komplexu a vlny T sa ischémia najvýraznejšie prejavuje. Taktiež sme tým odstránili vplyv vlny P na spektrálne zloženie daného segmentu (vlny P a T sú energeticky rozložené v podobnom frekvenčnom rozsahu) čo hrá dôležitú úlohu v nasledujúcej fázy odvodenia príznakového vektoru (viď ďalšia kapitola).

### 3. VYTVÁRENIE PRÍZNAKOVÉHO VEKTORA

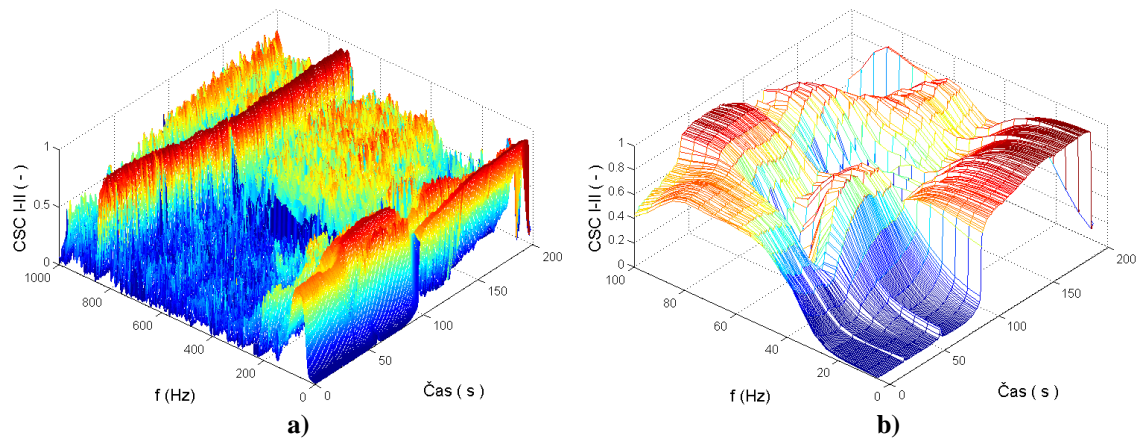
Ako príznakový vektor bol použitý vektor koeficientov vzájomnej koherencie spektier (angl. cross spectral coherence, CSC) [5]:

$$C_{I,II} = |P_{I,II}|^2 / (P_I P_{II}), \quad (1)$$

kde  $P_I$  a  $P_{II}$  sú výkonové spektrá signálu zo zvodov I a II,  $P_{I,II}$  je vzájomné výkonové spektrum z týchto zvodov a  $C_{I,II}$  je hodnota vzájomnej koherencie spektier zo zvodov I a II, ktoré mali pre študovanú patológiu najväčšiu variantnosť dát. Teoretický predpoklad použitia tejto metódy vychádza z predpokladu, že pri ischémii dochádza k narušeniu pozície hlavného srdečného vektora. To sa prejaví pri skúmaní vzájomného vzťahu medzi dvoma ortogonálnymi zvodmi. Výstupná hodnota CSC reprezentuje mieru podobnosti signálov na jednotlivých frekvenciách a nadobúda hodnoty od 0 do 1. [2], [5]

Pre všetky nasledovné výpočty sme využili programové rozhranie Matlab. U výpočtu spektier sme zvolili metódu s kľavým Hammingovým oknom o dĺžke 100 vzoriek s prekrytím 90 vzoriek a dĺžku spektra 2000 vzoriek, čím pri  $f_{vz} = 2000\text{Hz}$  dosiahneme krok 1Hz vo výslednom CSC (viď obrázok 1 a)).

Následne sme takto získané CSC orezali na rozsah 5 až 100 Hz, kde sa zmeny v CSC pri ischémii najviac prejavujú. Zároveň sa tým potlačí vplyv jednosmernej zložky signálu. Takto upravené CSC sme následne podvzorkovali s frekvenčným krokom 5Hz (viď obrázok 1 b)), čím zabezpečíme istú kompresiu dát (výsledná dĺžka príznakového vektora je 20 vzoriek) a tým zjednodušíme proces klasifikácie a zároveň nenarušíme informačnú hodnotu vstupných dát. Použitie CSC ako príznakového vektora je výhodnejšie oproti napr. morfológickým príznakom, ktoré sú závislé na funkčnosti detektoru jednotlivých morfológických častí EKG. Taktiež je táto metóda oproti použitiu celých cyklov menej náročná na pamäť PC a tým aj na čas potrebný k výpočtom.



Obrázok 1 Vzájomné koherenčné spektrum pre zvodov I a II fázy I: a) v celom rozsahu 0 až  $f_{vz}/2$ , b) v upravenom rozsahu 5 až 100Hz s krokom 5Hz

### 4. KLASIFIKÁCIA


Ako klasifikačný nástroj bola použitá dopredná neurónová sieť so spätným šírením chyby (angl. back propagation neural network, BPNN) (viď napr. [1], [5]). Tento typ klasifikátora vytvára logické väzby medzi jednotlivými neurónmi počas procesu učenia. Na to sa v praxi využíva tzv. tréningová odborne klasifikovaná množina vstupných príznakových vektorov. V našom prípade sme si zvolili experimentálne rozdelenie srdečných cyklov na základe toho v akej fázy experimentu boli získané.

Takto vytvorená tréningová množina bola ešte pred privedením na vstup samotnej neurónovej siete náhodne usporiadaná (tak aby nedošlo k dlhým ischemickým/neischemickým úsekom) a rozdelená do troch množín: tréningovej obsahuje 60% dát a dvoch testovacích obsahujúcich 20% dát.

Pre následnú klasifikáciu bola vytvorená BPNN. Parametre siete boli zvolené nasledovne: počet skrytých vrstiev = 2, celkový počet neurónov v skrytých vrstvách = 12, aktivačná funkcia nižšej vrstvy = sigmoída, aktivačná funkcia vyššej vrstvy = čisto lineárna, gradientný algoritmus učenia s adaptívnou rýchlosťou, gradientná funkcia zmeny váh pri učení, výpočet výkonu siete metódou strednej kvadratickej chyby a maximálny počet epoch 1000. Taktiež boli pred každým učením siete vynulované váhy na všetkých vrstvách. Takto navrhnutá neurónová sieť vykazovala po tréningu úspešnosť detekcie **99,24%** na tréningovej množine a **98,97%** na oboch testovacích množinách. Výsledky metódy sú teda zrovnateľné s výsledkami bežne dosahovanými v iných štúdiách (viď napr. [3]).

## 5. ZHODNOTENIE A ZÁVER

Na obrázku 2 je ukážka vstupných príznakových vektorov odvodených pre cykly z druhej ischemickej fázy a grafická reprezentácia odpovedajúceho výstupu BPNN. U ischemickej fázy predpokladáme malý počet neischemických cyklov na počiatku (prechodný dej v priebehu cca prvých dvoch minút na začiatku fázy) a ischemické cykly až do konca fázy (viď obrázok 2, hore).



**Obrázok 2** Test klasifikačnej metódy na fázy i2

U klasifikátoru ale musíme brať v úvahu že tréningová množina bola vytvorená intuitívne a teda hranica medzi ischemickým a neischemickým srdečným cyklom nemusí byť určená presne. Napriek tomu sa však domnievam, že s dostupnosťou odborne klasifikovaných dát by bolo možné vytvoriť efektívny a súčasne voči šumu odolný klasifikačný nástroj, na určenie srdečnej ischemie a pravdepodobne aj iných patológií narušujúcich hlavný srdečný vektor.

## REFERENCIE

- [1] GHONGADE, R., GHATOL, A.: *A Robust and Reliable ECG Pattern Classification using QRS Morphological Features and ANN*, TENCON 2008 - 2008 IEEE Region 10 Conference, 2008, 6 s.
- [2] DARWICH, A., FOKAPU, O.: *The Effect of Pathologic Cardiac Events on the Spectral content of ECG*, Engineering in Medicine and Biology Society, 2007, 4 s.
- [3] MANOCHA, A. K., MANDEEP S.: *An Overview of Ischemia Detection Technique*, International Journal of Scientific & Engineering Research, 2011, 5 s.
- [4] KOLÁŘOVÁ, J., JANOUŠEK, O., NOVÁKOVÁ, M., FIALOVÁ, K., PROVAZNÍK, I.: *Influence of ischemia on left ventricular depolarization in isolated rabbit hearts perfused according to Langendorff*, IFMBE Proceeding, Volume 25, World Congress on Medical Physics and Biomedical Engineering, 2009, 4 s.
- [5] CLIFFORD, G. D., AZUAJE, F., MCSHARRY, P. E.: *Advanced Methods and Tools for ECG Data Analysis*, Artech House Publishing, Boston/London, 2006, 384 s.