

# HEART BEATS CLASSIFICATION USING ARTIFICIAL NEURAL NETWORK

**Radovan Smíšek**

Bachelor Degree Programme (3), FEEC BUT

E-mail: xsmise00@stud.feec.vutbr.cz

Supervised by: Marina Ronzhina

E-mail: ronzhina@feec.vutbr.cz

**Abstract:** Use of artificial neural network (ANN) for automatic classification of the heart beats is highly topical. Both appropriate preparation of ECG data as well as selection of the ANN model allow performing effective and correct classification. The type of segments selected from ECG influences not only the type and maximum number of recognized classification groups but also the complexity of classification model. The latter affects PC memory requirements as well as the time needed for the classification. The main goals of this work are to design ANN model for heart beats classification and to study the influence of various factors (such as character of ECG data, ANN topology, etc.) on the results of classification.

**Keywords:** electrocardiogram, heart beat classification, artificial neural network, isolated heart

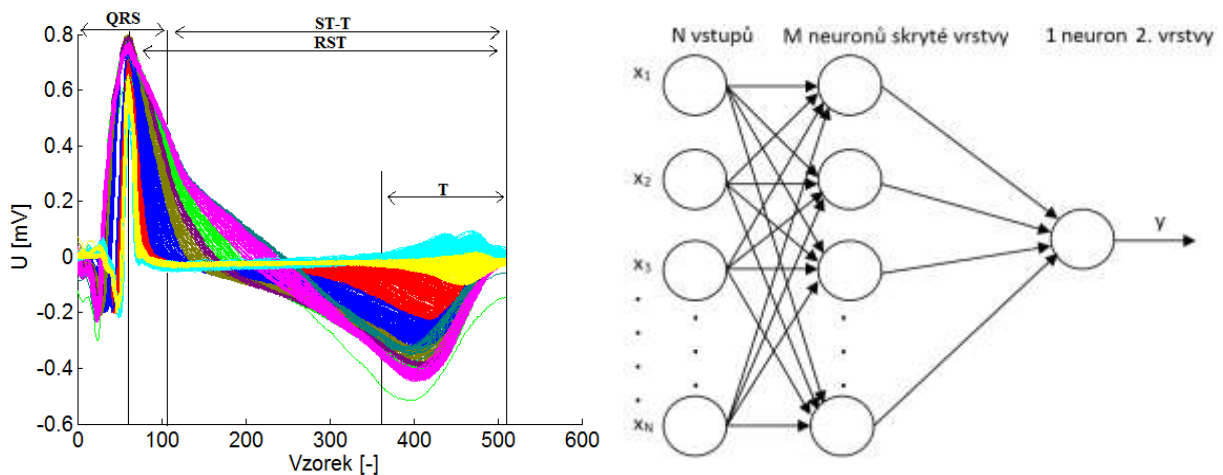
## 1. ÚVOD

Elektrokardiografie je moderní, neinvazivní, hojně využívané vyšetření funkce srdce. Kardiovaskulární onemocnění jsou hlavní příčinou úmrtí v České republice a ve většině evropských států [1]. Přesná klasifikace EKG je tudíž velmi důležitá. Potřebná je též vysoká rychlost klasifikace jednotlivých cyklů, jelikož při dlouhodobějším snímání EKG (EKG Holter) je zaznamenáno obvykle kolem 100 000 cyklů. Klasifikace pomocí umělé neuronové sítě (UNS) je moderní metoda, která našla uplatnění v různých oborech (viz např. [3]). Cílem této práce je najít optimální nastavení parametrů a struktury UNS pro klasifikaci cyklů EKG a porovnání úspěšnosti a rychlosti klasifikace při různých vstupních úsecích EKG (QRST, RST, QRS, ST-T, T).

## 2. PŘEDZPRACOVÁNÍ CYKLŮ EKG PŘED KLASIFIKACÍ

Data určená ke klasifikaci byla získána z databáze Ústavu biomedicínského inženýrství VUT v Brně. Jde o EKG snímané ortogonálním svodovým systémem se vzorkovací frekvencí 2kHz z izolovaných králičích srdcí v průběhu experimentů s vyvoláním opakované ischemie [2]. QRST úseky (9806 úseků) byly vybrány jako interval [R-59; R+450] vzorků (výsledné délky 250 ms), kde R je předem detekované maximum R kmitu. Před vstupem cyklů do neuronové sítě byl signál podvzorkován na jednu třetinu vzorků kvůli menší časové náročnosti klasifikace.


Dalším krokem bylo roztrždit jednotlivé úseky podle typu. Třídění proběhlo podle svodu X v rámci každé fáze experimentu zvlášť. Cykly *kontrolní* fáze byly rozděleny na čtyři typy. Ostatní fáze měly rozmanitější tvary úseků QRST a proto byly rozděleny v případě *druhé ischemie*, *druhé reperfuze* a *třetí reperfuze* do devíti typů a v případě *první ischemie*, *první reperfuze* a *třetí ischemie* do deseti typů. Cykly byly nejdříve rozděleny podle hodnoty výchylky vlny T do šesti typů. Po tomto rozdělení se v rámci každého typu cykly rozdělily podle výchylky šedesátého pátého vzorku (32,5 ms) po vrcholu kmitu R, která reprezentuje odchylku úseku ST a to do 4 typů. Po tomto dělení jsme dostali výše uvedený počet jednotlivých typů v rámci každé fáze experimentu, které následně byly rozděleny na určité úseky (viz příklad obrázek 1, vlevo).



**Obrázek 1:** Rozdělení cyklů na typy ve fázi ischemie 2 (vlevo) a obecné schéma použité UNS (vpravo)

### 3. KLASIFIKACE

Ke klasifikaci byly použity UNS se zpětným šířením chyby (angl. back propagation, BPG) (viz např. [3]) navržené v programovém prostředí MATLAB. Na obrázku 1 (vpravo) je zobrazeno obecné schéma použité UNS.  $N$  vstupů odpovídá počtu vzorků každého cyklu. Ve skryté vrstvě bylo použito  $M$  neuronů s charakteristikou hyperbolický tangens s mezemi  $-1$  a  $+1$ , ve výstupní vrstvě 1 neuron s lineární charakteristikou (viz např. [3]). Ideální počet neuronů ve skryté vrstvě  $M$  byl stanoven experimentálně. Závislost počtu chybně klasifikovaných cyklů na počtu neuronů je zobrazena na obrázku 2, vlevo. Z obrázku vyplývá, že při použití více než 24 neuronů počet chyb kolísá kolem konstantní hodnoty a již se nezmenšuje. Proto  $M$  bylo nastaveno na hodnotu 24.



**Obrázek 2:** Závislost počtu chybně klasifikovaných cyklů na počtu neuronů ve skryté vrstvě (vlevo) a závislost střední kvadratické odchylky na počtu epoch (vpravo)

Pro učení UNS byl použit pružný algoritmus BPG (angl. resilient BPG), který je rychlejší než většina ostatních algoritmů a přesto má relativně malé paměťové požadavky. V průběhu učení se parametry jednotlivých neuronů měnily podle algoritmu sestupu gradientu s přidáním momentem, což je metoda, při které se parametry neuronů mění nejen podle směru sestupu gradientu, ale také se bere ohled na poslední změny v chybovosti sítě. Tím je dáno, že síť neuvízne v mělkém lokálním minimu. Výkon sítě je popsán pomocí střední kvadratické odchylky. Závislost střední kvadratické odchylky na počtu epoch učení je zobrazena na obrázku 2, vpravo.

Výsledky dosažené při použití QRST úseků získaných pro různé fáze experimentu jako vstupu pro klasifikátor jsou shrnuté v tabulce 1. Tabulka 2 obsahuje výsledky dosažené při použití EKG cyklů reprezentovaných různými úseky EKG v rámci fáze ischemie 3.

Fáze experimentu	Počet typů QRST úseků, [-]	Epochy učení, [-]	Celkový počet cyklů, [-]	Čas potřebný k učení UNS, [s]	Počet chybně klasifikovaných cyklů, [-]	Podíl chybně klasifikovaných cyklů, [%]
Kontrolní fáze	4	52	3213	10,73	109	3,39
Ischemie 1	10	186	921	12,34	61	6,62
Reperfuze 1	10	200	1037	17,12	68	6,56
Ischemie 2	9	159	940	11,57	37	3,94
Reperfuze 2	9	200	998	17,86	138	13,83
Ischemie 3	10	200	954	15,19	47	4,93
Reperfuze 3	9	200	1743	18,29	155	8,89

**Tabulka 1:** Úspěšnost klasifikace cyklů v jednotlivých fázích experimentu podle QRST úseků

Úsek EKG cyklu použitý jako vstup pro UNS	Počet typů jednotlivých úseků, [-]	Epochy učení, [-]	Celkový počet cyklů, [-]	Čas potřebný k učení UNS, [s]	Čas potřebný ke klasifikaci, [ms]	Počet chybně klasifikovaných cyklů, [-]	Podíl chybně klasifikovaných cyklů, [%]
QRST	10	200	954	15,19	84,7	47	4,93
RST	10	200	954	12,62	82,5	74	5,97
QRS	10	200	954	10,65	73,1	162	16,98
ST-T	10	200	954	11,98	81,5	88	9,22
T	10	200	954	11,61	77,5	133	13,94

**Tabulka 2:** Úspěšnost klasifikace fáze ischemie 3 při různých vstupních úsecích EKG

#### 4. ZÁVĚR

V práci byla navržena funkční struktura UNS a zjištěna závislost klasifikační úspěšnosti na fázi experimentu (ischemie, reperfuze, kontrolní fáze) a na vstupním úseku. V prvním případě bylo nejvyšší úspěšnosti dosaženo v kontrolní fázi (zeleně vyznačený řádek v tabulce 1), což je dáno tím, že klasifikace probíhala pouze do čtyř skupin (typů). Naopak nejnižší klasifikační úspěšnost byla ve fázi reperfuze 2 (červeně označený řádek v tabulce 1), protože některé typy jsou zde zastoupeny málo cykly a tudíž na ně nebyla síť dobře naučená. Při klasifikaci s použitím různých úseků EKG získaných z fáze ischemie 3 bylo nejvyšší úspěšnosti dosaženo při použití úseku QRST (zeleně vyznačený řádek v tabulce 2), následoval úsek RST, segment ST-T, vlna T a nejnižší úspěšnost byla při použití komplexu QRS (červeně označený řádek v tabulce 2), což odpovídá předpokladům, jelikož komplex QRS nenese příliš důležitou informaci při diagnostice ischemie, naopak segment ST-T je důležitý. Potvrdil se předpoklad, že čím delší úsek EKG cyklu bude použit ke klasifikaci, tím déle učení sítě a samotná klasifikace potrvá (viz tabulka 2). Jako nejvhodnější pro klasifikaci se jeví použití úseků RST vzhledem k vysoké přesnosti klasifikace při současné relativně nízké časové náročnosti procesu učení sítě (modře vyznačený řádek v tabulce 2).

#### REFERENCE

- [1] BÝMA, Svatopluk. *Prevence kardiovaskulárních onemocnění* [online]. Praha: Společnost všeobecného lékařství ČLS JEP, 2004 [cit. 2012-12-01]. ISSN 80-903573-5-0.
- [2] KOLÁŘOVÁ, Jana aj. Experimental methods for simultaneous measurement of action potentials and electrograms in isolated heart. *Physiological research*. 2010. ISSN 1802-9973.
- [3] RONZHINA, Marina aj. Sleep scoring using artificial neural networks. *Sleep Medicine Reviews*. 2012, roč. 16, č. 3, s. 251-263. ISSN 10870792. DOI: 10.1016/j.smrv.2011.06.003.