

Použití kumulantů vyšších řádů pro automatickou klasifikaci EKG

Use of higher order cumulants for automatic classification of ECG

Lucie Maršánová, Marina Ronzhina, Radovan Smíšek, Martin Vitek

xmars08@stud.feec.vutbr.cz, ronzhina@feec.vutbr.cz, xsmise00@stud.feec.vutbr.cz, vitek@feec.vutbr.cz

Fakulta elektrotechniky a komunikačních technologií VUT v Brně

DOI: -

Abstract: This article deals with the variety of applications of higher-order cumulants for the representation of cardiac cycles in the process of automatic classification. It is obvious from the previous studies that higher-order cumulants enable lesser variance of beats in one class and easier classification ECG. Distinctive properties are minimalization of amplitude and time shift and Gaussian noise. The heart beats have been classified into four groups. Classification has been realized with two approaches such as k-Nearest Neighbours and support vector machines. Higher-order cumulants calculated from ECG beats are represented by morphological and spectral parameters during the classification. Parameters have been statistically analysed with the filter feature selection. Testing has been performed on isolated rabbit hearts. With the use of higher-order cumulants for the classification of heart beats, 98,80 % success rate has been achieved.

Použití kumulantů vyšších řádů pro automatickou klasifikaci EKG

Lucie Maršánová, Marina Ronzhina, Radovan Smíšek, Martin Vítek

Fakulta elektrotechniky a komunikačních technologií VUT v Brně

Email: xmarsa08@stud.feec.vutbr.cz, ronzhina@feec.vutbr.cz, xsmise00@stud.feec.vutbr.cz, vitek@feec.vutbr.cz

Abstrakt – Tento článek se zabývá možnostmi použití kumulantů vyšších řádů pro reprezentaci srdečních cyklů při automatické klasifikaci. Kumulanty 2., 3., a 4. řádu jsou při automatické klasifikaci použity namísto časových průběhů srdečních cyklů. Z dřívějších studií vyplývá, že kumulanty vyšších řádů vykazují vlastnosti, díky kterým lze snížit variabilitu vzorů (srdečních cyklů) v rámci jedné klasifikační třídy a zvýšit klasifikační úspěšnost. Jako nástroj pro realizaci automatické klasifikace je zvolena metoda nejbližších sousedů a metoda support vector machine, jejichž využití je v dané oblasti velmi rozšířeno. Kumulanty vypočtené ze srdečních cyklů jsou při klasifikaci reprezentovány průběhy podvzorkovaných kumulantů a z kumulantů vypočtenými morfologickými a spektrálními parametry. Pro každou skupinu je odvozeno určité množství příznaků, z nichž je pomocí filtrů vždy vybrána nejvhodnější kombinace, která je následně při klasifikaci použita. Metoda je testována na signálech z izolovaných králičích srdcí. Použitím kumulantů vyšších řádu pro klasifikaci srdečních cyklů bylo dosaženo úspěšnosti klasifikace 98,80 %.

1 Úvod

Nejčastější příčinou úmrtí jsou v současné době onemocnění kardiovaskulárního systému. V České republice a i celkově ve světě na tyto choroby připadá více než 50 % všech úmrtí. V posledních letech ale celková úmrtnost na kardiovaskulární choroby mírně klesá. A to i přesto, že výskyt kardiovaskulárních onemocnění naopak stoupá. Je tomu tak díky zvyšující se úrovni léčby, která jde stále kupředu díky výzkumu a vývoji nových metod diagnostiky a léčby [1]. Další výzkum v této oblasti je klíčem například k časnější diagnostice onemocnění v jeho raném stadiu a tím předejití jeho přechodu v závažnější. Nejčastěji používaným vyšetřením kardiovaskulárního systému je elektrokardiografie (EKG). Při hodnocení křivky EKG, a to zejména při hodnocení dlouhodobých záznamů EKG (např. holterovských), je nezbytné využít automatických počítačových metod. Přes velkou iniciativu výzkumu v této oblasti stále neexistují metody automatické klasifikace, které by dokázaly vyhodnotit záznam EKG zcela bezchybně. Proto je snaha vylepšit stávající metody, popř. nalézt nové, stále žádoucí.

Automatické klasifikaci předchází předzpracování sejmutoho elektrokardiogramu (EKG) a odstranění nežádoucích artefaktů a rušení vzniklých při snímání. Jedním z principů, na kterých může být předzpracování signálu EKG založeno, jsou i kumulanty vyšších řádů. Z předcházejících studií (např. z [2] a [3]) vyplývá, že kumulanty vyšších řádů jsou díky svým

vlastnostem schopny potlačovat Gaussovský šum, snižovat rozdíly amplitud kmitů a vln a stejně tak i snižovat rozdíly způsobené časovým posunem cyklů. Kvůli těmto vlastnostem jsou kumulanty dobrou volbou pro reprezentaci cyklů EKG při jejich automatické klasifikaci. Pro vysokou úspěšnost klasifikace je potřeba, aby variabilita cyklů v rámci jednotlivých skupin byla co nejmenší. A právě snížení variability cyklů EKG v rámci určité klasifikační skupiny je hlavním důvodem proč jsou kumulanty pro předzpracování záznamu EKG využívány.

Cílem této práce je ověření využitelnosti kumulantů vyšších řádů pro analýzu reálných signálů EKG. Jejich vlastnosti jsou nejprve ukázány a potvrzeny na simulovaných situacích a až poté je realizována samotná automatická klasifikace. Jako nástroj pro její realizaci je zvolena metoda nejbližších sousedů a metoda support vector machine, jejichž využití je v dané oblasti výzkumu velmi rozšířeno [4–7] a dosahují nejlepších výsledků. Dále se pro klasifikaci také často využívají vícevrstvé neuronové sítě (MDL) [8], diskriminační analýza (LDA), bayesovské klasifikátory (NB) [9], či shluková analýza [10].

Srdeční cykly (QRS-T segmenty) jsou při automatické klasifikaci obvykle reprezentovány například podvzorkovanými průběhy srdečních cyklů [8], koeficienty vlnkové transformace [4], morfologickými parametry [5], [7], spektrálními parametry [5], kumulanty vyšších řádů [6], či statistickými parametry [10]. V této práci jsou srdeční cykly při automatické klasifikaci reprezentovány pouze výrazně podvzorkovanými průběhy kumulantů a z kumulantů vypočtenými morfologickými a spektrálními parametry. Morfologických a spektrálních parametrů je v obou případech odvozeno větší množství, z nichž je pomocí filtrů pro výběr příznaků vybrána nejvhodnější kombinace.

Použitá databáze signálů, na kterých byly metody testovány obsahovala 4 typy srdečních cyklů, a to: fyziologické sinusové cykly, sinusové cykly pozmeněné určitým stupněm ischemie (počátek ischemie a pokročilé stádium) a komorové extrasystoly (PVC) z období ischemie.

Signály, na kterých je výzkum prováděn, byly získány z izolovaných králičích srdcí, kterým byla uměle navozována globální ischemie a jsou dostupné na Ústavu biomedicínského inženýrství VUT v Brně. Použití králičích srdcí a aplikace závěrů na nich zjištěných na srdce lidská je vhodná proto, že vykazují podobné fungování iontových kanálů, které se podílí na vzniku a šíření akčního napětí [11] (z toho vyplývá morfologická podobnost cyklů zaznamenaných v elektrogramech (EG)).

Veškeré výpočty jsou realizovány pomocí programového prostředí Matlab 2015a (The MathWorks, Inc.).

2 Kumulanty vyšších řádů

EKG může být popisováno mnoha způsoby, z nichž jedním jsou i kumulanty vyšších řádů. Z literatury vyplývá, že nevhodnější je použít kumulanty druhého, třetího a čtvrtého řádu. Kumulanty vykazují vlastnosti, které umožňují snížit variabilitu srdečních cyklů v rámci jedné klasifikační skupiny – oproti původním průběhům srdečních cyklů. V této kapitole je popsáno detailní matematické odvození kumulantů a jejich vlastnosti. Informace nutné pro odvození byly čerpány z [3], [12–16].

2.1 Odvození kumulantů

Pro pochopení výpočtu kumulantů ze signálu je důležité nejprve objasnit pojem obecné momenty, jejichž pomocí se kumulanty definují. Momenty jsou pojmem z matematické statistiky a charakterizují pravděpodobnostní rozdělení náhodné veličiny. Pro zjednodušení bude níže uvedené odvození obecných momentů a pomocí nich i samotných kumulantů vysvětleno pouze pro jednorozměrný proces.

Nejprve definujeme hustotu rozložení pravděpodobnosti náhodné proměnné X jako

$$\int_{-\infty}^{\infty} f(x) dx = 1, \quad (1)$$

kde $f(x)$ je hustota pravděpodobnosti veličiny X . Pak pravděpodobnostní funkce spojitě veličiny x se definuje následovně:

$$E(x) = \int_{-\infty}^{\infty} g^x f(x) dx. \quad (2)$$

Pokud nyní položíme v rovnici (2) $g=e^t$, získáme momentovou vytvořující funkci $M_X(t)$ náhodné veličiny X :

$$M_X(t) = E(e^{tx}) = \int_{-\infty}^{\infty} e^{tx} f(x) dx. \quad (3)$$

Pro diskrétní náhodnou veličinu X je momentová vytvořující funkce definována takto:

$$M_X(t) = E(e^{tx}) = \sum_x e^{tx} P(x), \quad (4)$$

kde $P(x) = P(X=x)$ je pravděpodobnostní funkce veličiny X .

Vytvořující funkci $M_X(t)$ lze vyjádřit pomocí Taylorovy řady, jejíž definice je:

$$s(x) = \sum_{n=0}^{\infty} \frac{f^n(a)}{n!} (x-a)^n = f(a) + \frac{f'(a)}{1!} (x-a) + \frac{f''(a)}{2!} (x-a)^2 + \dots \quad (5)$$

Z výše uvedeného je známo, že $M_X(t) = E(e^{tx})$. Pokud položíme v Taylorově polynomu $a=0$ a zároveň využijeme znalosti $e^0=1$, získáme rozvoj momentové vytvořující funkce v Taylorův polynom

$$\begin{aligned} M_X(t) &= E \left[e^0 + \frac{X}{1!} (t-0) + \frac{X''}{2!} (t-0)^2 + \frac{X'''}{3!} (t-0)^3 + \dots \right] \\ &= E \left[e^0 + \frac{X \cdot t}{1!} + \frac{X'' \cdot t^2}{2!} + \frac{X''' \cdot t^3}{3!} + \dots \right] \\ &= E(1) + \frac{E(X) \cdot t}{1!} + \frac{E(X'') \cdot t^2}{2!} \\ &\quad + \frac{E(X''') \cdot t^3}{3!} + \dots \end{aligned} \quad (6)$$

Vztahu (5 a 6) využijeme nyní při důkazu toho, že momenty dostaneme jako derivaci charakteristické vytvořující funkce $M_X(t)$ v nule. Zderivujeme ji a položíme $t=0$

$$\begin{aligned} \frac{dt}{t} \left\{ E(1) + \frac{E(X) \cdot t}{1!} + \frac{E(X'') \cdot t^2}{2!} + \frac{E(X''') \cdot t^3}{3!} + \dots \right\} \Big|_{t=0} \\ = 0 + \frac{E(X)}{1!} + \frac{2 \cdot E(X'') \cdot t}{2!} + \frac{3 \cdot E(X''') \cdot t^2}{3!} \\ + \dots \Big|_{t=0} \\ = \frac{E(X)}{1!} + \frac{2 \cdot E(X'') \cdot 0}{2!} + \frac{3 \cdot E(X''') \cdot 0^2}{3!} \\ = E(X) = m_1. \end{aligned} \quad (7)$$

Dostali jsme první obecný moment m_1 . Pokud bychom nyní provedli druhou derivaci této funkce získáme druhý obecný moment. Z toho již plyne základní význam momentové vytvořující funkce, tj. její n -tá derivace v bodě 0 dává n -tý obecný moment m_n .

Pokud nyní momentovou generující funkci zlogaritmujeme, získáme kumulanty generující funkci $g_X(t)$:

$$\begin{aligned} g(t) = \log(E(e^{tx})) &= - \sum_{n=1}^{\infty} \frac{1}{n} (1 - E(e^{tx}))^n = - \sum_{n=1}^{\infty} \frac{1}{n} \\ &\quad - \left(\sum_{m=1}^{\infty} m_n \frac{t^m}{m!} \right)^n \\ &= m_1 + (m_1 - m_1^2) \frac{t^2}{2!} \\ &\quad + (m_3 - 3m_2 m_1 - 3m_1^3) \frac{t^3}{3!} + \dots \end{aligned} \quad (8)$$

Nyní stejným způsobem, jako jsme výše dostali momenty, dostaneme kumulanty, čili n -tá derivace kumulanty generující funkce $g(t)$ v bodě 0 nám dá n -tý kumulant. V této práci budou využity kumulanty 1–4. řádu, proto jsou níže uvedeny jejich výsledné definice, které jsou získány z rovnice (8):

$$c_1 = m_1, \quad (9)$$

$$c_2 = m_2 - m_1^2, \quad (10)$$

$$c_3 = m_3 - 3m_2 m_1 - 3m_1^3, \quad (11)$$

$$c_4 = m_4 - 4m_3 m_1 - 3m_2^2 + 12m_2 m_1^2 - 6m_1^4. \quad (12)$$

2.2 Tvorba kumulantů ze signálu v praxi

Kumulanty ze signálu $x(n)$ pro $n = \langle 0; N-1 \rangle$, který je reálný, diskrétní a náhodný a má nulovou střední hodnotu, počítáme při programové realizaci tak, že mezi sebou násobíme signál, posunutý vůči sobě o určitý časový okamžik (tj. určitý počet

vzorků). V případě kumulantu 2. řádu se jedná o dva časové okamžiky, tzn. násobíme mezi sebou vzorky signálu ve dvou různých časových okamžicích:

$$c_{2x}(k) = m_{2x} = E[x(n)x(n+k)] = \frac{1}{N_3} \sum_{n=N_1}^{N_2} x^*(n)x(n+k) \quad (13)$$

V případě kumulantu 3. a 4. řádu se jedná o 3, respektive 4, časové okamžiky:

$$c_{3x}(k, l) = m_{3x} = E[x(n)x(n+k)x(n+l)] = \frac{1}{N_3} \sum_{n=N_1}^{N_2} x^*(n)x(n+k)x(n+l), \quad (14)$$

$$c_{4x}(k, l, m) = E[x(n)x(n+k)x(n+l)x(n+m)] - c_{2x}(k)c_{2x}(m-l) - c_{2x}(l)c_{2x}(m-k) - c_{2x}(m)c_{2x}(k-l) = \frac{1}{N_3} \sum_{n=N_1}^{N_2} x^*(n)x(n+k)x(n+l)x(n+m) - c_{2x}(k)c_{2x}(l-m) - c_{2x}(l)c_{2x}(k-m) - m_{2x}(m)m_{2x}(l-k), \quad (15)$$

kde k, l, m jsou časové okamžiky (posunutí signálu), $x^*(n)$ je komplexně sdružená posloupnost vstupního signálu, N_1 a N_2 nabývají hodnot rozmezí 0 až $N-1$. Pro výpočet „neposunutého odhadu“ (angl. unbiased) kumulantů se N_3 nastavuje na hodnotu, která odpovídá délce (počtu vzorků) signálu, ze kterého je kumulant počítán. Při výpočtu posunutého (angl. biased) odhadu se zadává hodnota menší, než je délka signálu. Z definice vyplývá, že kumulanty mají vždy délku $2 * n - 1$. [3]

Pro nulové hodnoty k, l a m reprezentují normalizované hodnoty kumulantů známé charakteristiky rozdělení náhodných veličin a to: kumulant 2. řádu - rozptyl, kumulant 3. řádu - koeficient šikmosti a kumulant 4. řádu - koeficient špičatosti [6].

2.3 Základní vlastnosti kumulantů

Nejdůležitější vlastnosti kumulantů jsou následující [13], [17]:

1. Jestliže $x(n)$ je Gaussovský proces, potom k -tý kumulant veličiny $x(n)$ pro $k > 2$ je nulový. A tedy veškeré informace budou obsaženy v prvním a druhém kumulantu. Této vlastnosti můžeme využít pro potlačení Gaussovského šumu neznámé střední hodnoty.
2. Jestliže $x(n)$ má symetrickou distribuci kolem nuly, potom každý k -tý kumulant $x(n)$ pro $k=0,3,5,7$ bude nulový. Toho se využívá například pro zjištění tvaru signálu.
3. Jestliže $x(n)$ má nulovou střední hodnotu, potom k -tý kumulant bude roven k -tému obecnému momentu pro $k \leq 3$. Díky tomu lze velice zjednodušit výpočet.
4. Jestliže $z(n) = x(n) + y(n)$, kde $x(n)$ a $y(n)$ je stacionární a statisticky nezávislý proces, potom se kumulant veličiny $z(n)$ bude rovnat součtu kumulantů veličin $x(n)$ a $y(n)$. Toho lze využít při detekci aditivních směsí v signálu. Tato vlastnost neplatí pro momenty.

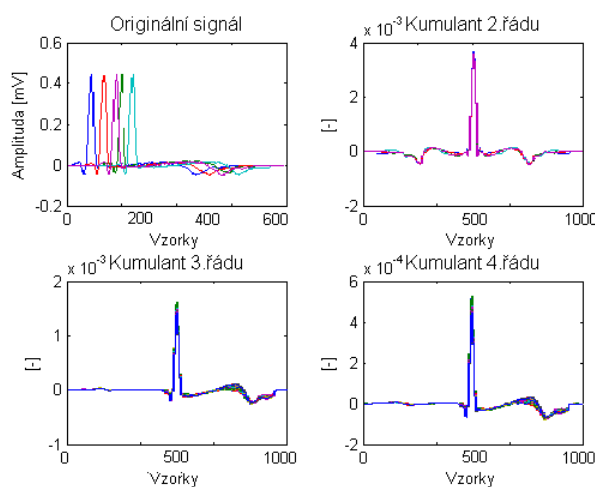
2.4 Testování vlastností kumulantů

Předchozí studie uvádí (např. [3]), že kumulanty jsou díky svým vlastnostem schopny snižovat variabilitu cyklů patřících do jedné skupiny (např. klasifikační třídy). To proto, že dokáží potlačit rozdíly způsobené časovým posunem, či kolísáním nulové izolinie. Dále také studie uvádí, že dokáží v signálech EKG potlačit šum. V následující části práce jsou tyto schop-

nosti kumulantů ověřeny. Zmíněné situace jsou namodelovány a z takto připravených signálů jsou spočítány kumulanty druhého, třetího i čtvrtého řádu, čímž je ukázáno chování kumulantů v daných situacích. Originální průběhy segmentů QRS-T mají délku 500 vzorků, což znamená, že z nich vypočtené kumulanty mají délku 999 vzorků.

2.4.1 Vliv posunu po ose x (časová osa)

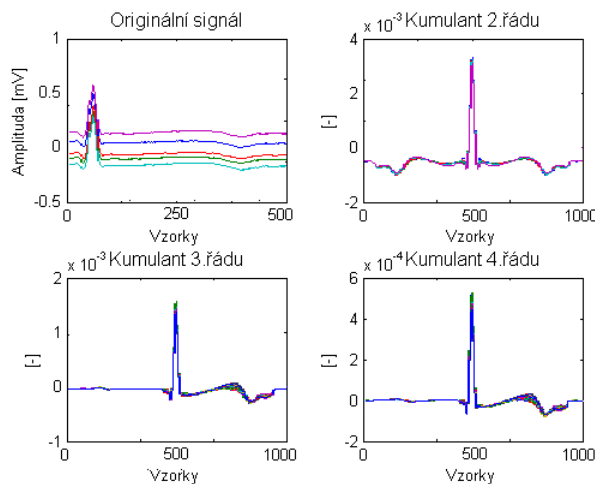
Na Obr. 1 vlevo nahoře je zobrazeno pět cyklů EKG, které jsou posunuty po časové ose x . Toto bylo namodelováno přidáním odlišného počtu nulových vzorků před začátek jednotlivých cyklů (pro zachování stejné délky segmentů také na konec jednotlivých cyklů). Poloha vlny R se po provedeném posunu pohybovala v rozmezí 40–110 ms. Obr. 1 ukazuje, že kumulanty všech tří řádů vykazují snížení variability jednotlivých cyklů, tzn. minimalizování posunu a vytvoření cyklů mezi sebou zcela srovnatelných.



Obr. 1: Potlačení posunu po ose x (časový posun)

2.4.2 Vliv posunu po ose y (výchylka elektrogramu)

Na Obr. 2 je namodelována situace, kdy jsou srdeční cykly vůči sobě posunuty v ose y . Posun byl namodelován přičtením náhodně vygenerované hodnoty k celému cyklu. Po výpočtu kumulantů z této skupiny cyklů došlo k potlačení těchto rozdílů.



Obr. 2: Potlačení posunu po ose y (posun hodnot)

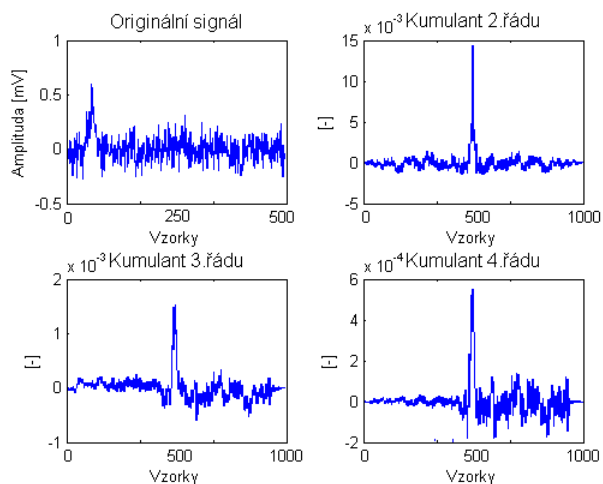
2.4.3 Vliv přítomnosti Gaussovského šumu

Obr. 3 potvrzuje, že vlastnosti kumulantů umožňují i *potlačení Gaussovského šumu*. Šum byl simulován náhodně generovaným bílým aditivním šumem s gaussovským rozložením, jehož parametry byly nastaveny tak, aby výsledná hodnota poměru signál/šum (angl. signal-to-noise ratio, SNR) byla -3 dB. Takto vygenerovaný šum byl sečten se vstupním signálem. Tím byla získána směs šumu a signálu, přičemž výkon signálu byl poloviční oproti výkonu šumu.

Výrazný šum v originálním signále, který by s největší pravděpodobností znesnadňoval jakékoliv další využití signálu, byl po vypočítání kumulantů značně potlačen. Výsledná hodnota SNR vypočítaná dle vzorce:

$$SNR = 10 \cdot \log \frac{\frac{1}{N} \sum_{n=0}^{N-1} s^2(n)}{\frac{1}{N} \sum_{n=0}^{N-1} s^2(n)}, \quad (16)$$

kde s značí signál a n šum, je pro kumulant druhého řádu 3,49 dB. To znamená, že výkon signálu je oproti výkonu šumu více než dvojnásobný. U kumulantů třetího a čtvrtého řádu vyšla hodnota SNR ještě vyšší, tj. 9,89 dB, respektive 7,98 dB.



Obr. 3: Potlačení náhodného šumu v signálu

Všechny výše ukázané vlastnosti kumulantů byly potvrzeny i v předchozí studii [3].

3 Databáze EKG

Tato kapitola popisuje data, která byla v práci použita. Nejprve je popsán způsob získání signálů EKG a dále jednotlivé klasifikační skupiny, do kterých byly cykly při jejich reprezentaci kumulanty klasifikovány. Nakonec je ukázáno, jak vypadaly původní průběhy srdečních cyklů (QRS-T segmenty) a jak z nich vypočtené kumulanty.

3.1 Akvizice a předpracování dat

Signály, které jsou zpracovávány v této práci, jsou dostupné na ústavu Biomedicínského inženýrství VUT v Brně [13]. Tyto elektrogramy (EG) byly získány z izolovaných králičích srdcí v průběhu experimentu se dvěma opakovanými fázemi ischemie a reperfuze. Při experimentu byl použit Langendorffův perfuzní systém, což je zařízení, které umožňuje perfuzi izolovaného srdce, tedy průtok roztoku obsahujícího důležité látky pro výživu srdečního svalu koronárním systé-

mem. Po celou dobu experimentů byly snímány elektrogramy pomocí tří diferenčně zapojených ortogonálních svodů (šest Ag-Cl bezdotykových elektrod umístěných ve stěně měřící komůrky naplněné vodivým K-H roztokem). Pro každé srdce byly vždy získány tři elektrogramy. Záznamy byly vzorkovány s vzorkovací frekvencí 2000 Hz. Podrobnější popis metody lze najít v [22]. Celkem bylo provedeno 31 experimentů (na 31 králičích srdcích) a bylo naměřeno 406 248 srdečních cyklů.

Z naměřených elektrogramů byly vybrány úseky bez artefaktů (vzniklých při manipulaci se srdcem, či při dočasném odpojení svodu). Úseky signálu byly filtrovány pomocí Lynnova filtru typu horní propust s mezní frekvencí 0,5 Hz pro odstranění kolísání nulové izoliny. Software, který byl pro tuto filtraci využit je [18]. Poté byly detekovány maxima vln R pomocí detektoru [19] pracujícího na principu vlnkové transformace, tato automatická detekce byla následně manuálně zkontrolována a v případě potřeby zkorigována. Dle pozic QRS byly vybrány úseky QRS-T (tedy bez vlny P), jako úseky signálu 29,5 ms vzorků před detekovanou vlnou R, až 220 ms po vlně R. Takto vzniklé segmenty QRS-T měly délku 250 ms. Nakonec byl každý cyklus manuálně klasifikován. Jednotlivé srdeční události byly konzultovány s experty.

3.2 Klasifikační skupiny

Z výše popsaných dat byla pro účely této práce vytvořena redukovaná testovací databáze. Tato redukovaná databáze obsahuje 4 typy srdečních cyklů (stejně jako v předchozí práci [7]) a to:

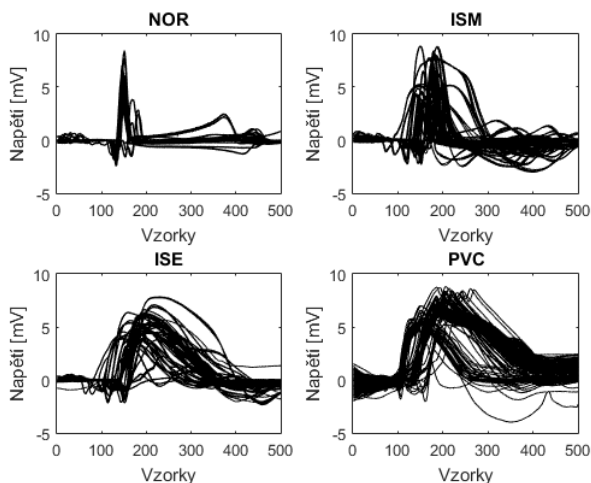
- **fyzilogické sinusové cykly** (z angl. normal, NOR),
- **sinusové cykly pocházející z 5. minuty ischemické fáze** – tj. z období, kdy již začíná ischemie pozměňovat morfologii cyklů (z angl. ischemia middle, ISM),
- **sinusové cykly pocházející z 10. minuty ischemické fáze** – tj. z období, kdy už je morfologie cyklů změněna výrazně (z angl. ischemia end, ISE),
- **komorové extrasystoly** (z angl. premature ventricular contraction, PVC).

Ve všech záznamech bylo nalezeno celkem 172 cyklů PVC – všechny jsou podrobeny klasifikaci. Cykly ve skupinách NOR, ISM a ISE byly vybrány ze všech analyzovaných experimentů tak, aby byl každý experiment zastoupen přibližně stejně a jejich celkový počet byl srovnatelný s počtem cyklů PVC. Tyto skupiny obsahují vždy 220 cyklů. Celkem je tedy klasifikováno 832 cyklů. Pracováno bylo pouze s prvními dvěma svody, protože třetí svod obsahoval velké množství artefaktů.

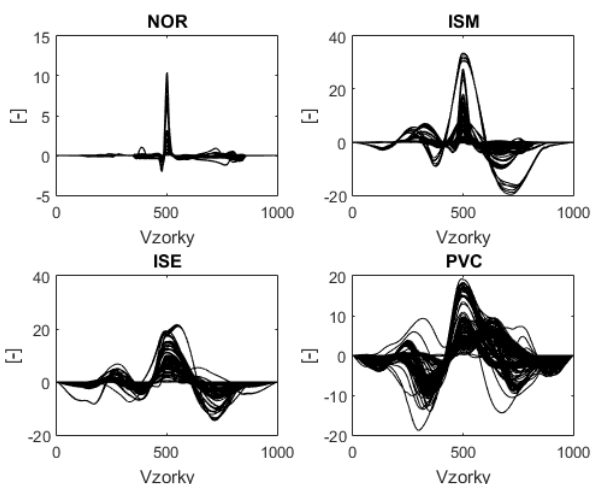
3.3 Výpočet kumulantů z použitých dat

Ze všech dat popsaných v kapitole 3.2 byly z prvních dvou svodů vypočteny kumulanty 2., 3. a 4. řádu za pomoci programového prostředí Matlab.

Na Obr. 4 a 5 je možno porovnat původní průběhy segmentů QRS-T z jednotlivých klasifikačních skupin (NOR, ISM, ISE a PVC) s průběhy z nich vypočtených kumulantů 3. řádu. Průběhy kumulantů nejsou v práci vykresleny.



Obr. 4: Klasifikované skupiny segmentů QRS-T – původní průběhy



Obr. 5: Klasifikované skupiny segmentů QRS-T – kumulanty 3. řádu

4 Automatická klasifikace

Pro ověření toto, zda kumulanty dokáží srdeční cykly věrně reprezentovat při jejich automatické klasifikaci, byla realizována klasifikace dvěma různými klasifikačními metodami a to metodou SVM a k-NN.

Kumulanty vypočtené ze segmentů QRS-T byly při klasifikaci reprezentovány několika různými způsoby. V prvním z nich se jednalo o samotné podvzorkované průběhy kumulantů 2., 3. a 4. řádu, dále z nich vypočtené morfologické parametry a nakonec spektrální parametry, které byly vypočteny pro první i druhý svod. Bližší popis parametrů z jednotlivých skupin je uveden níže. Z jednotlivých skupin příznaků byly za pomoci filtrů vybrány nejvhodnější kombinace nesoucí nejvíce informací a ty byly použity při následné klasifikaci. Automatická klasifikace byla realizována metodou nejbližšího souseda a metodou podpůrných vektorů.

4.1 Skupiny příznaků

4.1.1 Podvzorkované průběhy kumulantů

Prvním a nejjednodušším způsobem, jakým byly QRS-T segmenty při automatické klasifikaci reprezentovány, jsou podvzorkované průběhy kumulantů. Kumulanty z obou dvou svodů (každý o délce 999 vzorků) jsou podvzorkovány s faktorem 60 proto, aby byl jejich počet srovnatelný s ostatními skupinami příznaků. Výsledný počet vzorků (získaných z obou svodů) vstupujících do klasifikátorů je 34.

4.1.2 Morfologické parametry

Dalším způsobem reprezentace QRS-T segmentů jsou z kumulantů odvozené morfologické parametry. Celkem bylo vypočteno 38 parametrů z obou dvou svodů. Dle jejich charakteru je lze rozdělit do několika skupin:

1. Parametry vyjadřující maximální a minimální hodnotu výchylky daného kumulantu, jejich rozdíl, či pozici minima (maximum bylo vždy na stejné pozici). Celkem 8 příznaků.
2. Parametry vyjadřující plochu pod určitou částí křivky kumulantu. Jedná se o parametry vyjadřující plochu pod křivkou 100 ms před a za pozicí maxima (vždy vzorek 500), plochu v úseku 150 ms před a 300 ms za pozicí maxima, či plochu pod celou křivkou kumulantu. A to jak pouze pozitivní, či negativní části těchto ploch, tak celé plochy. Celkem 18 příznaků.
3. Parametry stanovené jako poměry parametrů popsanych v bodě 2. Celkem 12 příznaků.

4.1.3 Spektrální parametry

Celkem bylo vytvořeno 24 spektrálních parametrů založených na rozměření EG (tj. 12 parametrů v každém z obou svodů). Všechny parametry byly vytvořeny z úseků signálu 50 ms před a po komplexu QRS (skupina Spekt100) a z úseků 75 ms před a 150 ms po komplexu QRS (skupina SpektAll). Tyto parametry byly odvozeny ze 4 oblastí. Využita byla časově-frekvenční oblast, frekvenční oblast, časově-měřítková oblast a Wigner-Villeho (W-V) distribuce.

V časově-frekvenční oblasti vypočtené pomocí krátkodobé Fourierovy transformace, byly výsledné parametry spočítány jako průměr, medián a maximum z výsledného spektrogramu.

Ve frekvenční oblasti vypočtené pomocí rychlé Fourierovy transformace, jsou výsledné parametry dány součtem frekvenčních složek ve vybraných frekvenčních pásmech (0–35 Hz, 35–90 Hz, 125–250 Hz).

V časově-měřítkové oblasti vypočtené pomocí spojité vlnkové transformace, byly první dva parametry vypočteny jako průměr a maximum matice obsahující vlnkové koeficienty. Další parametr byl spočítán jako průměr hodnot v čase s nejvyšší korelací signálu a různě roztažené vlnky. Poslední parametr byl spočítán jako průměr hodnot při roztažení vlnky s nejvyšší korelací ve všech časech.

Výstupní parametry z W-V distribuce byly spočítány jako maximum z W-V distribuce komplexu QRS a jako průměr z W-V distribuce komplexu QRS v rozmezí 0–500 Hz.

4.1.4 Normalizace

Cykly byly při automatické klasifikaci vždy reprezentovány normalizovanými hodnotami příznaků. Normalizace prvku x_i (škálování do rozsahu hodnot 0–1) byla provedena dle vzorce (1), kde x značí vektor všech hodnot daného parametru [3]:

$$\text{norm}_i = \frac{x_i - \min(x)}{\max(x) - \min(x)}. \quad (17)$$

Normalizace byla provedena vždy pro skupinu trénovacích dat a jejich koeficienty (minimální a maximální hodnoty daného parametru) byly poté použity i na normalizaci testovacích dat.

4.2 Filtry pro výběr příznaků

Abychom dosáhli co nevyšší úspěšnosti klasifikace, je nutné zvolit co nejvhodnější kombinaci příznaků z celé množiny, kterou máme k dispozici. Metody používané pro výběr příznaků se na dělí na tzv. wrappery, filtry, a embedded metody. V této práci byla použita metoda filtrů. Pro filter metody je charakteristická jejich nezávislost na klasifikátoru. Jsou méně výpočetně náročné a to je předurčuje pro použití na rozsáhlejších databázích. Filtry vyhodnocují kvalitu příznaků a podle ní pak vytvářejí výstupní množinu [20]. Konkrétně byla použita metoda Random Subset Feature Selection (RSFS) převzatá z [21]. Tato metoda vyhodnocuje kvalitu příznaku na základě jeho příspěvku ke správné klasifikaci. Níže je v bodech popsán princip celého algoritmu RSFS:

1. V každé iteraci (zde provedeno 1000 iterací) dochází k náhodnému výběru setu S_i z celého setu F obsahujícího n příznaků.
2. Dojde k provedení klasifikace za použití setu S_i a je vypočtena hodnota kritériální funkce c_i , která určí klasifikační výkon při použití setu S_i .
3. Váhy (kvality) r_j jednotlivých příznaků f_j jsou upraveny dle vzorce

$$r_j' = r_j + c_j - E\{c\}, \quad (18)$$
 kde c_i je hodnota kritériální funkce v aktuální iteraci i a $E\{c\}$ je očekávaná hodnota kritériální funkce, která je stanovena jako průměrná hodnota c_i všech předchozích iterací.
4. Proces je opakován s novým náhodným setem příznaků.

Do výsledného setu příznaků, které budou použity pro klasifikaci, jsou pak zahrnuty jenom ty příznaky, jejichž váhy jsou větší než průměrná váha všech příznaků.

Tímto způsobem byly z výše uvedených skupin příznaků pro použití při klasifikaci vybrány pouze některé. Z celkového počtu parametrů bylo vždy vybráno jen určité množství (viz. Tabulka 1). Podvzorkované průběhy kumulantů metodě RSFS podrobeny nebyly.

Tabulka 1: Počet příznaků, vybraných pomocí filtrů z celkového počtu, které byly použity při automatické klasifikaci.

Typ příznaků	Použito pro klasifikaci		
	CUM 2	CUM 3	CUM 4
Morf.	18/38	22/38	17/38
Spect100	13/22	14/22	14/22
SpectAll	11/22	14/22	13/22

4.3 Klasifikační metody

V této práci byly vyzkoušeny dvě klasifikační metody a to metoda podpurných vektorů (z angl. Support Vector Machine, SVM) a metoda k-nejbližších sousedů (z angl. k-Nearest Neighbors, k -NN), které pracují na principu tzv. učení s učitelem. Data jsou nejprve rozdělena na trénovací a testovací množinu. Nastavení klasifikátoru probíhá na trénovací množině a pro testování úspěšnosti se používají testovací data, která se neúčastní učení klasifikátoru. Tato kapitola přiblíží principy obou metod a uvede, jaké nastavení bylo v této práci vyzkoušeno.

4.3.1 Metoda podpurných vektorů

Metoda podpurných vektorů se snaží nalézt diskriminační funkci, která dokáže vhodně oddělit klasifikační třídy. V původním n -rozměrném vstupním prostoru lineárně neoddelitelná data převádí do charakteristického m -rozměrného prostoru (kdy $m > n$), v němž je možné realizovat lineární separaci.

Řešením optimálního oddělení dvou tříd (maximalizování vzdálenosti navzájem nejbližších objektů od hranice separace) je nalezení hodnot parametrů p , které maximalizují výraz [16]:
$$A = \sum_i p_i - \frac{1}{2} \sum_{i,j} p_i p_j y_i y_j (x_i \cdot x_j), \quad (19)$$
 kde x_i jsou objekty a y_i klasifikační třídy, přičemž platí omezení $p_i > 0$ a $\sum_i p_i \cdot y_i = 0$. Výraz $x_i \cdot y_i$ se nazývá jádrová funkce a nemusí být vždy přesně tohoto tvaru (záleží na konkrétním nastavení). Dle omezení při hledání p platí, že pouze body, které jsou nejbližší vlastnímu oddělovači, mají nenulové váhy. Tyto body se nazývají podpurné vektory (support vectors) a pouze tyto body jsou důležité pro nalezení tvaru lineárního oddělovače.

V této práci byla testována lineární jádrová funkce a funkce s radiální bází (z angl. Radial Basis Function, RBF).

4.3.2 K-nejbližších sousedů

Další vyzkoušenou metodou klasifikace je metoda k-nejbližších sousedů. Metoda zařadí právě testovaný neznámý objekt do skupiny, do které náleží prvek (popř. nejvíce z uvažovaných prvků v případě $k > 1$) z trénovací množiny dat, ke kterému má nejmenší vzdálenost (ta může být vypočtena různými typy metrik). Pro výpočet vzdálenosti je v této práci použita Euklidovská vzdálenost [14], která se stanovuje dle vzorce:

$$E(x_1, x_2) = \sqrt{\sum_{i=1}^n (x_{1i} - x_{2i})^2}, \quad (20)$$

(20) kde x_1 a x_2 jsou objekty, jejichž vzdálenost je počítána a n je počet parametrů, kterými jsou objekty popsány.

V této práci byly vyzkoušeny hodnoty $k = 1, 5$ a 10 .

4.3.3 Trénování a testování navržených klasifikátorů

Trénování klasifikátorů (nastavení parametrů pro optimální oddělení skupin) a jejich testování bylo provedeno 10násobnou křížovou validací. Data byla náhodně rozdělena na 10 přibližně stejně velkých podmnožin (každá z nich obsahovala přibližně stejný počet segmentů QRS-T). Devět z nich se použilo na trénování modelu a jedna na jeho testování, postupně tak proběhlo testování na všech 10 podmnožinách.

Výsledná klasifikační úspěšnost (Acc) udává procento správně klasifikovaných cyklů ze všech testovaných při trénování a testování 10násobnou křížovou validací.

5 Výsledky

Tato kapitola uvádí, jaké úspěšnosti automatické klasifikace segmentů QRS-T náležících do skupin NOR, ISM, ISE a PVC bylo dosaženo při jejich reprezentaci kumulanty 2., 3. a 4. řádu. Vyzkoušena byla klasifikace dle podvzorkovaných průběhů kumulantů a dále z nich odvozených morfologických a spektrálních parametrů za použití klasifikačních metod SVM a k -NN.

Všechny výsledky jsou přehledně zobrazeny v tabulce 2. Nejvyšší úspěšnosti klasifikace bylo dosaženo při výpočtu kumulantů 4. řádu, použití morfologických parametrů a klasifikátoru k -NN (Acc=98,80 %).

Pokud ovšem porovnáme průměrné úspěšnosti pro všechny parametry a všechny typy klasifikátorů při použití různých řádů kumulantů je zřejmé, že nejvyšší průměrné úspěšnosti je dosaženo při použití kumulantů 2. řádu (Acc=81,59 %) a naopak kumulanty 4. řádu jsou nejméně úspěšné (Acc=78,31 %).

Při porovnání jednotlivých klasifikačních metod dojdeme k zjištění, že nejúspěšnější je metoda k -NN pro $k=1$ (Acc=94,20 %). Metoda k -NN (Acc=90,61 %) je celkově úspěšnější než metoda SVM (Acc=63,79 %).

Na základě výsledků je též zřejmé, že je výhodnější použít původní data (Acc=88,76 %), než data normalizovaná (Acc=70,99 %).

Při porovnání typů použitých příznaků lze dojít k zjištění, že nejkvalitnější jsou morfologické parametry (průměrné Acc=83,57 %), dále podvzorkované průběhy (Acc=79,78 %) a nejhorší Acc dosáhly spektrální parametry (Acc=78,08 %). Při klasifikaci metodou SVM je ovšem nejkvalitnějších výsledků dosahováno právě při použití spektrálních parametrů.

6 Diskuze

Dobrou použitelnost kumulantů pro reprezentaci srdečních cyklů při jejich automatické klasifikaci v kombinaci s metodami k -NN a SVM lze podtrhnout srovnáním s dřívějšími studii, které pro reprezentaci srdečních cyklů používají také kumulanty. Jedná se o starší studie, bohužel aktuálnější studie týkající se přesně našeho tématu neexistují. Srovnání je přehledně shrnuto v tabulce 3. Při použití nejkvalitnějších příznaků a nevhodnějšího řádu kumulantů jsme v naší práci dosáhli Acc=96,27 % pro SVM a Acc=98,80 % pro k -NN. Počty skupin v ostatních studiích, do kterých byly cykly tříděny, byly srovnatelné s počtem skupin v této práci.

Tabulka 2: Výsledky klasifikace metodami k -NN a SVM při použití morfologických parametrů, spektrálních parametrů odvozených z úseků 100 ms před a 100 ms za maximem kumulantu a z úseku 150 ms před a 300 ms za maximem kumulantů a podvzorkovaných průběhů kumulantů vypočtených z kumulantů 2., 3. a 4. řádu

Typ příznaků	Řád kumulantu	k-NN						SVM			
		1		5		10		RBF		Linear	
		Init.	Norm.	Init.	Norm.	Init.	Norm.	Init.	Norm.	Init.	Norm.
Morfologické	Cum2	98,68	90,02	92,07	91,34	90,34	89,34	64,44	78,12	84,98	73,20
	Cum3	97,96	88,35	94,12	86,46	85,53	83,16	55,64	84,98	77,87	75,00
	Cum4	98,80	86,18	91,59	87,04	86,74	87,24	50,83	80,40	79,80	72,35
Podvzorkované průběhy	Cum2	96,88	90,15	90,50	87,72	87,72	86,21	92,30	59,85	84,73	45,92
	Cum3	98,08	93,39	93,40	89,41	89,41	85,23	87,50	36,66	91,22	28,73
	Cum4	98,56	93,03	92,91	88,81	86,81	90,81	77,17	28,85	94,22	29,45
Spekt100	Cum2	97,60	92,31	93,75	87,86	89,1	86,1	95,91	44,59	87,03	30,04
	Cum3	97,83	90,38	92,07	87,21	88,81	85,81	89,67	28,85	86,90	29,81
	Cum4	97,24	91,83	93,03	87,83	89,21	79,85	79,46	29,81	82,59	30,42
SpektAll	Cum2	97,72	91,35	91,35	89,43	89,43	89,43	96,27	39,89	84,73	30,53
	Cum3	97,47	90,14	90,63	91,62	87,62	85,62	91,59	28,85	87,27	29,81
	Cum4	97,12	89,78	90,75	87,1	89,1	86,1	84,25	29,81	79,42	30,42

Tabulka 3: Porovnání výsledků předchozích metod s výsledky získanými v této práci

Metoda	Příznaky	Úspěšnost klasifikace	Autoři
Neuronová síť	Podvzorkované kumulanty	96 %	Ronzhina et al. [8]
Neuronová síť	Statistické příznaky odvozené z kumulantů	98 %	Ying-Hsiang et al. [16]
SVM	Celé průběhy kumulantů	54 %	Hanneschlager. Et al.[13]
SVM	Podvzorkované kumulanty	86,7 %	Park et al.[6]
k -NN ($k=1$)	Morfologické, odvozené z podvzorkovaných kumulantů 4. řádu	98,80 %	Tento čl.
SVM (RBF)	Spektrální, odvozené z podvzorkovaných kumulantů 2. řádu	96,27%	Tento čl.

7 Závěr

V tomto článku byly ověřeny, ukázány a diskutovány možnosti použití kumulantů vypočtených ze srdečních cyklů při klasifikaci. Z kumulantů byly vypočítány parametry v časové

a spektrální oblasti. Tyto parametry a také samotné podvzorkované průběhy kumulantů vstupovaly do dvou různých klasifikátorů (metody SVM a k -NN). Bylo zjištěno, že pro klasifikaci jsou vhodnější parametry vypočítané v časové oblasti, než parametry ze spektrální oblasti. Přesnější klasifikační metoda byla metoda k -NN. Při porovnání úspěšnosti jednotlivých řádů kumulantů dopadly nejlépe kumulanty 2. řádu. Při zvolení nejvhodnější skupiny parametrů a nejvhodnějšího řádu kumulantů jsou naše výsledky lepší, než výsledky jiných studií zabývajících se klasifikací EKG [6, 8, 13, 16]. Z toho vyplývá dobrá využitelnost kumulantů vyšších řádů při klasifikaci srdečních cyklů do skupin NOR, ISM, ISE a PVC v kombinaci s metodami k -NN a SVM. V budoucí práci je žádoucí provést testování na více datech pocházejících z běžně používaných veřejně dostupných databází (MIT-BIH, CSE).

8 Poděkování

Tato publikace vznikla v rámci projektu GAP102/12/2034 Grantové agentury České republiky.

Literatura

- [1] MARTINÍK, K. Hodnocení kardiovaskulárního systému. [online]. [cit. 2014-12-23]. Dostupné z: <http://www.profmartinik.cz/wp-content/soubory/fvmvhp-2hodnoceni-kardiovaskulsyst.pdf>
- [2] KARIMIFARD, Saeed a Alireza AHMADIAN. A robust method for diagnosis of morphological arrhythmias based on Hermitian model of higher-order statistics. *BioMedical Engineering OnLine* [online]. 2011, **10**(1), [cit. 2016-06-22]. DOI: 10.1186/1475-925X-10-22. ISSN 1475-925X.
- [3] MENDEL, J.M. Tutorial on higher-order statistics (spectra) in signal processing and system theory: theoretical results and some applications. *Proceedings of the IEEE* [online]. **79**(3), 278-305 [cit. 2016-06-22]. DOI: 10.1109/5.75086. ISSN 00189219.
- [4] ARIF, M., M. U. AKRAM a F. A. AFSAR. Arrhythmia Beat Classification Using Pruned Fuzzy K-Nearest Neighbor Classifier: theoretical results and some applications. *2009 International Conference of Soft Computing and Pattern Recognition* [online]. IEEE, 2009, **79**(3), 37-42 [cit. 2016-06-22]. DOI: 10.1109/SoCPaR.2009.20. ISBN 978-1-4244-5330-6. ISSN 00189219.
- [5] ZIDELMAL, Z., A. AMIROU, D. OULD-ABDESLAM a J. MERCKLE. ECG beat classification using a cost sensitive classifier: theoretical results and some applications. *Computer Methods and Programs in Biomedicine* [online]. IEEE,
- [6] PARK, K.S., B.H. CHO, D.H. LEE, S.H. SONG, J.S. LEE, Y.J. CHEE, I.Y. KIM a S.I. KIM. Hierarchical support vector machine based heartbeat classification using higher order statistics and hermite basis function. *2008 Computers in Cardiology* [online]. IEEE, 2008, , 229-232 [cit. 2016-06-22]. DOI: 10.1109/CIC.2008.4749019.
- [7] MARŠANOVÁ, L.; RONZHINA, M.; VÍTEK, M. Automatická klasifikace EKG s použitím morfologických parametrů. *Elektrorevue–elektronický časopis pro elektrotechniku*. 2015, **17**(4) 115-123. ISSN 1213-1539.
- [8] RONZHINA M., POTOČNÁK T., JANOUŠEK O., KOLÁŘOVÁ J., NOVÁKOVÁ M., PROVAZNÍK I. Spectral and higher-order statistics analysis of ECG: application to study of ischemia in rabbit isolated hearts. In: *Computing in Cardiology*. 2012, **39**(1). 645-648 [cit. 2015-07-16].
- [9] SAYADI, O., M.B. SHAMSOLLAHI, G.D. CLIFFORD, S.H. SONG, J.S. LEE, Y.J. CHEE, I.Y. KIM a S.I. KIM. Robust Detection of Premature Ventricular Contractions Using a Wave-Based Baye-

- sian Framework. *IEEE Transactions on Biomedical Engineering* [online]. IEEE, 2010, **57**(2), 353-362 [cit. 2016-06-22]. DOI: 10.1109/TBME.2009.2031243. ISBN 978-1-4244-3706-1. ISSN 0018-9294.
- [10] SHEN, Chia-Ping, Wen-Chung KAO, Yueh-Yiing YANG, Ming-Chai HSU, Yuan-Ting WU, Feipei LAI, I.Y. KIM a S.I. KIM. Detection of cardiac arrhythmia in electrocardiograms using adaptive feature extraction and modified support vector machines. *Expert Systems with Applications* [online]. IEEE, 2012, **39**(9), 7845-7852 [cit. 2016-06-22]. DOI: 10.1016/j.eswa.2012.01.093. ISBN 978-1-4244-3706-1. ISSN 09574174.
- [11] CURTIS, Michael J., Jules C. HANCOX, András FARKAS, et al. The Lambeth Conventions (II): Guidelines for the study of animal and human ventricular and supraventricular arrhythmias. *Pharmacology* [online]. IEEE, 2013, **139**(2), 213-248 [cit. 2016-06-22]. DOI: 10.1016/j.pharmthera.2013.04.008. ISBN 978-1-4244-3706-1. ISSN 01637258.
- [12] ANDĚL, J. *Matematická statistika*. 2. vyd. Praha: SNTL, 1985, 346 s.
- [13] HANNESSCHLAGER, G. HOSA – Higher Order Spectra Analysis. 2004. [cit. 2012-10-15]. Dostupné z: http://www.emt.jku.at/education/Inhalte/se_moderne_methoden/WS0405/hannesschlaeger_hosa.pdf. 2004
- [14] PETROPULU, A. *Higher-Order Spectral Analysis* [online]. CRC Press LLC, 2000 [cit. 2012-10-25]. Dostupné z: <http://dsp-book.narod.ru/DSPMW/76.PD>
- [15] Wolfram MathWorld: Cumulant. [online]. [cit. 2012-11-09]. Dostupné z: <http://mathworld.wolfram.com/Cumulant.html>
- [16] YING-HSIANG, Ch. a Y. SUNG-NIEN. Subband Features Based on Higher Order Statistics for ECG Beat Classification. Proceedings of the 29th Annual International Conference of the IEEE EMBS Cité Internationale [online]. 2007, 1859-1862. Dostupné z: <http://ieeexplore.ieee.org/stamp/stamp.jsp?tp=&arnumber=4352677&userType=inst>
- [17] SIGG, D. C. *Cardiac electrophysiology methods and models*. New York: Springer, 2010, 491 s. ISBN 14-419-6658-7.
- [18] KOZUMPLÍK, J., L. SMITAL a M. VÍTEK. Eliminator. Software pro korekci driftu nulové izolované signálu EKG. Ústav biomedicínského inženýrství: Vysoké učení technické v Brně. [cit. 2012-10-28]. Dostupné z: <http://www.ubmi.feec.vutbr.cz/vyzkum-a-vyvoj/produkty> (software)
- [19] VÍTEK, M. a J. KOZUMPLÍK. QRS seeker. Software pro detekci komplexů QRS. Ústav biomedicínského inženýrství: Vysoké učení technické v Brně. (software)
- [20] SAEYS, Y., I. INZA a P. LARRANAGA. A review of feature selection techniques in bioinformatics. *Bioinformatics* [online]. 2007, **23**(19), 2507-2517 [cit. 2015-12-16]. DOI: 10.1093/bioinformatics/btm344.
- [21] POHJALAINEN, Jouni, Okko RÄSÄNEN a Serdar KADIOGLU. Feature selection methods and their combinations in high-dimensional classification of speaker likability, intelligibility and personality traits. *Computer Speech & Language* [online]. 2015, **29**(1): 145-171 [cit. 2015-12-16]. DOI: 10.1016/j.csl.2013.11.004.
- [22] KOLÁŘOVÁ, J. *Metody měření a analýzy elektrické aktivity srdce v základním kardiologickém výzkumu*. VUT v Brně. 2009.