



VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ

BRNO UNIVERSITY OF TECHNOLOGY



**FAKULTA ELEKTROTECHNIKY A KOMUNIKAČNÍCH
TECHNOLOGIÍ**

ÚSTAV BIOMEDICÍNSKÉHO INŽENÝRSTVÍ

FACULTY OF ELECTRICAL ENGINEERING AND COMMUNICATION
DEPARTMENT OF BIOMEDICAL ENGINEERING

KLASIFIKACE SRDEČNÍCH CYKLŮ

HEART BEAT CLASSIFICATION

DIPLOMOVÁ PRÁCE

MASTER'S THESIS

AUTOR PRÁCE

AUTHOR

Bc. TOMÁŠ POTOČŇÁK

VEDOUCÍ PRÁCE

SUPERVISOR

Ing. MARINA RONZHINA

BRNO 2013



VYSOKÉ UČENÍ
TECHNICKÉ V BRNĚ

Fakulta elektrotechniky
a komunikačních technologií

Ústav biomedicínského inženýrství

Diplomová práce

magisterský navazující studijní obor
Biomedicínské a ekologické inženýrství

Student: Bc. Tomáš Potočňák

ID: 106731

Ročník: 2

Akademický rok: 2012/2013

NÁZEV TÉMATU:

Klasifikace srdečních cyklů

POKYNY PRO VYPRACOVÁNÍ:

1) Proveďte literární rešerši v oblasti klasifikace srdečních cyklů. Popište parametry elektrokardiogramů, které lze pro tento účel použít. Seznamte se s různými klasifikačními metodami. 2) Navrhněte klasifikátor srdečních cyklů založeného na vybrané metodě. Navrhněte metodu pro vyhodnocení klasifikace. 3) Seznamte se s databází signálů z experimentu. Popište různé druhy srdečních cyklů, které se vyskytují v daných signálech. Navrhněte metodiku klasifikace a použijte získané signály pro vytvoření vektorů příznaků vhodných pro následnou klasifikaci. 4) Navržený postup klasifikace realizujte v prostředí Matlab. 5) Proveďte hodnocení vlivu nastavení parametrů klasifikátoru na výsledky klasifikace. Uveďte nejvhodnější příznaky, které umožňují dosažení nejlepších výsledků. Výsledky porovnejte s dostupnými údaji z literatury. 6) Proveďte diskusi získaných výsledků. Zhodnoťte účinnost použití vybrané klasifikační metody pro řešení daného problému.

DOPORUČENÁ LITERATURA:

[1] SALEM, A.B.M. Mashine Learning in Electrocardiogram Diagnosis. In: Proseedings of the International Multiconference on Computer Science and Information Technology IMCSIT '09. Mragowo, 2009, s. 429-433. ISSN 1896-7094.

[2] CLIFFORD, G.D., AZUAJE, F. a MCSHARRY, P. Advanced methods and tools for ECG data analysis. Boston: Artech House, 2006. ISBN 1-58053-966-1.

Termín zadání: 11.2.2013

Termín odevzdání: 24.5.2013

Vedoucí práce: Ing. Marina Ronzhina

Konzultanti diplomové práce:

prof. Ing. Ivo Provazník, Ph.D.

Předseda oborové rady

UPOZORNĚNÍ:

Autor diplomové práce nesmí při vytváření diplomové práce porušit autorská práva třetích osob, zejména nesmí zasahovat nedovoleným způsobem do cizích autorských práv osobnostních a musí si být plně vědom následků porušení ustanovení § 11 a následujících autorského zákona č. 121/2000 Sb., včetně možných trestněprávních důsledků vyplývajících z ustanovení části druhé, hlavy VI. díl 4 Trestního zákoníku č.40/2009 Sb.

ABSTRAKT

Cieľom tejto práce bolo vyvinúť metódu klasifikácie EKG cyklov do dvoch tried, ischemických a neischemických cyklov. Ako vstupný signál boli použité spracované srdečné cykly (P-QRS-T cykly) získané meraním animálneho EKG ortogonálnym zvodovým systémom. Príznakový vektor bol vytvorený ako výsledok analýzy vzájomnej koherencie spektier, analýzy primárnych komponentov, HRV parametrov a ich kombinácií. Výsledné cykly boli klasifikované za pomoci doprednej neurónovej siete so spätným šírením chyby. Klasifikátor bol navrhnutý v Matlabe. Výkon klasifikácie dosahoval hodnôt v rozmedzí 87,2 až 100%. Výsledky experimentu môžu byť vhodné pre budúce štúdie automatickej klasifikácie EKG.

KLÚČOVÉ SLOVA

Klasifikácia srdečných cyklov, ischemia, analýza vzájomnej koherencie spektier, analýza primárnych komponentov, umelá neurónová sieť

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 (P-QRS-T cycles) selected from animals orthogonal ECGs were preprocessed and used as the input signals. Spectral features vectors (values of cross spectral coherency), principal component and HRV parameters were derived from the beats. The beats were classified using feedforward multilayer neural network designed in Matlab. Classification performance reached the value approx. from 87,2 to 100%. Presented results can be suitable in future studies aimed at automatic classification of ECG.

KEYWORDS

Heart beat classification, cardiac ischemia, cross spectral coherency analysis, principal component analysis, artificial neural network

POTOČŇÁK, T. *Klasifikace srdečních cyklu*. Brno: Vysoké učení technické v Brně, Fakulta elektrotechniky a komunikačních technologií. Ústav biomedicínského inženýrství, 2013. 47 s.. Diplomová práce. Vedúca práce: Ing. Marina Ronzhina

PROHLÁŠENÍ

Prohlašuji, že svou diplomovou práci na téma Klasifikace srdečních cyklů jsem vypracoval samostatně pod vedením vedoucího diplomové práce a s použitím odborné literatury a dalších informačních zdrojů, které jsou všechny citovány v práci a uvedeny v seznamu literatury na konci práce.

Jako autor uvedené diplomové práce dále prohlašuji, že v souvislosti s vytvořením této diplomové práce jsem neporušil autorská práva třetích osob, zejména jsem nezasáhl nedovoleným způsobem do cizích autorských práv osobnostních a/nebo majetkových a jsem si plně vědom následků porušení ustanovení § 11 a následujících zákona č. 121/2000 Sb., o právu autorském, o právech souvisejících s právem autorským a o změně některých zákonů (autorský zákon), ve znění pozdějších předpisů, včetně možných trestněprávních důsledků vyplývajících z ustanovení části druhé, hlavy VI. díl 4 Trestního zákoníku č. 40/2009 Sb.

V Brně dne

.....
(podpis autora)

POĎAKOVANIE

Ďakujem vedúcej diplomovej práce Ing. Marine Ronzhine za účinnú metodickú, pedagogickú a odbornú pomoc, ľudský prístup, ochotu pri riešení vzniknutých problémov a ďalšie cenné rady pri spracovaní mojej diplomovej práce.

V Brne dňa

.....
(podpis autora)

OBSAH

Zoznam obrázkov	ix
Úvod	1
1 Elektrokardiografické vyšetrenie	2
1.1 Snímanie elektrokardiogramu	2
1.1.1 Bipolárne zvody končatinové	2
1.1.2 Unipolárne zvody končatinové	2
1.1.3 Unipolárne hrudné zvody podľa Wilsona.....	3
1.1.4 Ortogonálne zvody.....	3
1.2 Krivka EKG	4
2 Klinická elektrokardiografia	5
2.1 Fyziologické zmeny srdečného rytmu	5
2.2 Abnormálne zmeny srdečného rytmu	6
2.2.1 Ektopický srdečný sťah, tachykardia a fibrilácia.....	6
2.2.2 Bloky vedenia, bradykardia a oneskorené rytmy.....	7
2.2.3 Ischémia, iné metabolické narušenia a abnormality štruktúry.....	8
3 Klasifikácia srdečného cyklu	9
3.1 Výber a spracovanie vstupných dát	10
3.1.1 Zdroje vstupných dát	10
3.1.2 Spracovanie vstupného signálu.....	11
3.1.3 Selekcia signálu	12
3.2 Vytváranie príznakového vektora.....	12
3.2.1 Metódy vytvárania príznakového vektora	12
3.2.2 Výber relevantných príznakov	14
3.2.3 Dodatočné spracovanie vektora príznakov	17
3.3 Klasifikácia	17
3.3.1 Klasifikačné triedy.....	18
3.3.2 Typ klasifikátora	18
3.3.3 Výber najlepšieho klasifikátora	21
3.3.4 Zrovnanie metód detekcie ischémie	22

4	Návrh metódy detekcie ischémie	23
4.1	Vstupné experimentálne dáta.....	25
4.1.1	Experimentálne meranie EG na izolovanom srdci	25
4.1.2	Selekcia vstupných dát.....	27
4.2	Vytváranie príznakového vektora.....	28
4.2.1	Kompresná metóda PCA	28
4.2.2	Analýza EG v spektrálnej oblasti.....	32
4.3	Klasifikácia	36
4.3.1	Vytvorenie vstupnej sady klasifikátora.....	36
4.3.2	Návrh klasifikátora	38
4.3.3	Diskusia výsledkov klasifikácie.....	43
5	Záver	44
	Literatúra	45
	Zoznam skratiek	47
	Zoznam príloh	48

ZOZNAM OBRÁZKOV

Obr. 1.1:	Bipolárne zvody končatinové – Einthovenov trojuholník (prevzaté z [1])....	2
Obr. 1.2:	Unipolárne zvody končatinové (prevzaté z [1]).....	3
Obr. 1.3:	Umiestnenie unipolárnych hrudných zvodov (prevzaté z [1]).....	3
Obr. 1.4:	Krivka EKG s označenými morfológickými časťami (prevzaté z [3]).....	4
Obr. 2.1:	Normálny sínusový rytmus (prevzaté z [3])	6
Obr. 2.2:	Predčasný sťah siení (APC, šípky označujú výskyt ektopie, prevzaté z [3]).	6
Obr. 2.3:	Predčasný sťah komôr (VPC, prevzaté z [3])	6
Obr. 2.4:	Tachykardia komôr (VT, prevzaté z [3])	7
Obr. 2.5:	Fibrilácia siení (AF, prevzaté z [3]).....	7
Obr. 2.6:	Fibrilácia komôr (AF, prevzaté z [3])	7
Obr. 2.7:	AV-blok druhého stupňa (šípky poukazujú na variantnosť PQ intervalu, prevzaté z [3])	8
Obr. 2.8:	Akútny infarkt myokardu, veľké plochy ischemického predného myokardu – elevácia ST segmentu vo viacerých zvodoch (prevzaté z [3]).....	9
Obr. 3.1:	Štruktúra procesu klasifikácie srdečného cyklu.....	9
Obr. 3.2:	Vplyv arytmií na tvar PSD, sinus – sínusový rytmus, VT – tachykardia komôr, VFL – kmitanie komôr, VF – fibrilácia komôr (prevzaté z [3])	13
Obr. 3.3:	Vzájomná spektrálna koherencia, C1xy – CSC medzi zvodmi I a II, C2xy – CSC medzi 10 sekundovými úsekmi zo zvodu I (prevzaté z [3]).....	14
Obr. 3.4:	Umelý neurón (prevzaté z [16]).....	18
Obr. 3.5:	Viacvrstvá neurónová sieť (prevzaté z [16]).....	19
Obr. 3.6:	Priebeh MSE v procese učenia siete	20
Obr. 4.1:	Vývojový diagram vytvárania PCA a PCA + HRV príznakovej matice	23
Obr. 4.2:	Vývojový diagram vytvárania CSC a PCA z CSC príznakovej matice.....	23
Obr. 4.3:	Vývojový diagram klasifikácie pomocou ANN	24
Obr. 4.4:	Pristroj na meranie EG, rozloženie ortogonálnych zvodov v priestore a protokol experimentu (prevzaté z [26]).....	25
Obr. 4.5:	Ukážka vstupného signálu EG z troch zvodov: a) I – neischemický, b) I – ischemický, c) II – neischemický, d) II – ischemický, e) III – neischemický, f) III – ischemický –signal_20130402	27
Obr. 4.6:	Variantnosť primárnych komponentov – zvod I, signal_20130402	29
Obr. 4.7:	%PRDN rekonštruovaného signálu – zvod I, signal_20130402.....	30
Obr. 4.8:	Normalizovaná matica príznakov PCA – zvod I, signal_20130402 s vyznačenými ischemickými fázami	30

Obr. 4.9: Príznakový vektor PCA – zvod I, signal_20130402.....	31
Obr. 4.10: Príznakový vektor HR a RR-pomer – signal_20130327	32
Obr. 4.11: CSC medzi zvodmi I a II – signal_20130327	33
Obr. 4.12: CSC medzi zvodmi I a II 1 až 200Hz: cykly 1 – 100 fáza sc, cykly 101 – 200 fáza i1 – signal_20130327	33
Obr. 4.13: Upravená matica CSC medzi zvodmi I a II – signal_20130327.....	34
Obr. 4.14: Matica PCA CSC medzi zvodmi I a II – signal_20130327 s vyznačenými ischemickými fázami	35
Obr. 4.15: Príznakový vektor PCA CSC medzi zvodmi I a II – signal_20130402.....	35
Obr. 4.16: Užívateľské rozhranie softwaru na anotáciu srdečných cyklov (prevzaté z [27]).....	36
Obr. 4.17: Anotačný vektor testovacej (modrý) a tréningovej (červený) sady	37
Obr. 4.18: Prechodové funkcie na vrstvách ANN a) tansig, b) logsig, c) satlins.....	38
Obr. 4.19: Tréningové funkcie a) traingd, b) traingdm, c) traingda, d) traingdx	39
Obr. 4.20: Grafické zobrazenie priebehu trénovania siete v Neural Network Tollbox.	40
Obr. 4.21: Testovanie tréningových funkcií siete s príznakovým vektorom CSC.....	41
Obr. 4.22: Odozva siete na ischemickú fázu i1 signal_20130402 – elipsa označuje miesto hysterézie.....	43

ÚVOD

Klasifikácia srdečných cyklov je z pohľadu klinickej medicíny veľmi užitočný nástroj. Poskytuje nám prostriedok k správnej predikcii, výberu medikácie ako aj pochopeniu jednotlivých dejov v oblasti srdečných abnormalít a patológii. Zatiaľ čo ručná klasifikácia EKG je pomerne presná, vytvorenie komplexnej štúdie dlhodobého merania je časovo náročné. V tomto probléme môže pomôcť počítačová klasifikácia pomocou vhodne zvolenej analýzy signálu a klasifikačnej metódy. Oblasť automatickej (počítačovej) klasifikácie je stále oblasťou vo vývoji, hlavne z dôvodu komplikovaného nahradenia naučených znalosti a skúsenosti lekára. Pri dobrom výbere parametrov má táto metóda predpoklad vykazovať nižšiu chybovosť a vyššiu časovú efektívnosť klasifikácie voči ručnej klasifikácii.

Cieľom diplomovej práce bolo zoznámiť sa s problémom počítačovej klasifikácie, preskúmať rôzne metódy analýzy EKG signálu, ktoré táto metóda vyžíva, ako aj rôzne klasifikačné nástroje. Ďalším cieľom práce bolo zoznámiť sa s abnormalitami srdečného cyklu a ich vplyvom na EKG signál. Hlavným bodom diplomovej práce je návrh klasifikačnej metódy a testovanie jej úspešnosti. Keďže najlepšie sa teoretické znalosti overia praktickým experimentom, tento bod je v práci riešený ako demonštračný experiment klasifikácie ischemických cyklov z priebehu animálneho elektrogramu, získaného meraním na extrahovanom srdci kráľika. Všetky metódy v tejto práci sú vyhotovené v programovacom prostredí Matlab.

1 ELEKTROKARDIOGRAFICKÉ VYŠETRENIE

1.1 Snímanie elektrokardiogramu

Elektrická aktivita srdca sa meria neinvazívne na povrchu tela, pripojením sady elektród na kožu. Elektródy sú na tele umiestnené tak, aby dostatočne odrážali časopriestorové zmeny elektrického poľa srdca. Pre záznam elektrokardiogramu EKG sú smerodajne napäťové rozdiely medzi dvojicami elektród. Miesta snímania elektrického signálu z povrchu tela a ich označenie sú v dnešnej dobe ustálené. Pri bežnom snímaní EKG sa využíva 12 zvodov, ktoré sa následne delia na [1], [2]:

- bipolárne zvody končatinové – I, II, III,
- unipolárne zvody končatinové – aVR, aVL, aVF,
- unipolárne zvody hrudné – V1, V2, V3, V4, V5, V6
- ortogonálne zvody – X, Y, Z.

1.1.1 Bipolárne zvody končatinové


Zachytávajú prejavy srdečného potenciálu vo frontálnej rovine, pričom sa meria rozdiel potenciálov medzi dvoma elektródami (Obr. 1.1). Výsledne potenciály sa teda vypočítajú nasledovne [1], [2]:

$$I = V_{LA} - V_{RA}, \quad (1.1)$$

$$II = V_{LL} - V_{RA}, \quad (1.2)$$

$$III = V_{LL} - V_{LA}. \quad (1.3)$$

Pričom V_{LA} udáva napätie zachytené na ľavej ruke, V_{RA} na pravej ruke a V_{LL} na ľavej nohe. I , II , III sú označenia zvodov.



Obr. 1.1: Bipolárne zvody končatinové – Einthovenov trojuholník (prevzaté z [1])

1.1.2 Unipolárne zvody končatinové


Tieto zvody sledujú taktiež elektrickú aktivitu srdca vo frontálnej rovine a využívajú rovnaké elektródy ako bipolárne končatinové zvody, avšak zapojenie zvodov (Obr. 1.2) a merané potenciály sú iné [1]:

$$aVR = V_{RA} - \frac{V_{LA} + V_{LL}}{2}, \quad (1.4)$$

$$aVL = V_{LA} - \frac{V_{RA} + V_{LL}}{2}, \quad (1.5)$$

$$aVF = V_{LL} - \frac{V_{RA} + V_{LA}}{2}, \quad (1.6)$$


kde aVR , aVL , aVF je označenie meracích zvodov. Ostatné premenné sú totožné ako v pri bipolárnych zvodoch končatinových.



Obr. 1.2: Unipolárne zvody končatinové (prevzaté z [1])

1.1.3 Unipolárne hrudné zvody podľa Wilsona

Zatiaľ čo končatinové zvody sledujú elektrickú aktivitu srdca vo frontálnej rovine, unipolárne hrudné zvody sledujú elektrickú aktivitu srdca v horizontálnej rovine. Referenčná elektróda sa vytvorí spojením troch končatinových elektród cez odpor $5k\Omega$ a aktívna elektróda je umiestnená v jednom zo šiestich špecifických miest (Obr. 1.3), označených V_1 až V_6 . [1]



Obr. 1.3: Umiestnenie unipolárnych hrudných zvodov (prevzaté z [1])


1.1.4 Ortogonálne zvody

Sústava ortogonálnych zvodov sa používa na záznam elektrickej aktivity srdca v 3D priestore, preto sú veľmi vhodné pri zostavovaní vektokardiogramu. Tento zvodový systém sa v klinickej praxi používa len málo, jeho hlavne uplatnenie je

v experimentálnej kardiológii, kde je možné zvody umiestniť presne podľa potreby napr. pri meraní na extrahovanom srdci (vid'. kapitola 4.1.1). Okrem toho je možné tieto zvody derivovať z dvanásť-zvodového merania [3].

1.2 Krivka EKG

Krivka EKG (Obr. 1.4) sa skladá z niekoľkých častí (vln, kmitov). Ako prvý popísal EKG krivku Willem Einthoven na začiatku dvadsiateho storočia. Kmity a vlny označil písmenami P, Q, R, S, T. Toto pomenovanie sa ustálilo a používa sa dodnes.



Obr. 1.4: Krivka EKG s označenými morfológickými časťami (prevzaté z [3])

Každá časť EKG krivky odpovedá určitému deju [1]:

- **P vlna** odráža sekvenčnú depolarizáciu pravej a ľavej srdečnej siene. Väčšinou ma kladnú polaritu, jej amplitúda by mala byť menej ako $300 \mu\text{V}$ a trvanie menej ako 120 ms ,
- **QRS komplex** odráža depolarizáciu pravej a ľavej srdečnej komory, ktorá za normálnych okolností trvá 70 až 110 ms a skladá sa z kmitov Q, S a R vlny. Kmit Q má negatívnu výchylku a trvá 30 ms , značí začiatok depolarizácie myokardu v oblasti septa. Vlna R predstavuje postup vzruchovej vlny naprieč stenou srdečných komôr a je vždy kladná. S kmit nasledujúci za vlnou S sa vždy nachádza pod izoelektrickou líniou a aktivuje poslednú časť komorového myokardu pri báze ľavej komory,
- **bod J** označuje miesto prechodu QRS komplexu do ST segmentu,
- **ST segment** v skutočnosti nie je vlna, ale odráža interval depolarizácie celého myokardu komôr. Je izoelektrický,

- **T vlna** odzrkadľuje repolarizáciu komôr a nachádza sa zhruba 300 ms po QRS komplexe. Niekedy po T vlne môžeme pozorovať vlnu U, ktorá má nízku amplitúdu a je ťažko rozpoznateľná, jej pôvod a funkcia sú stále nejasné,
- **RR interval** predstavuje dĺžku komorového srdečného cyklu. Meranie intervalu medzi dvoma po sebe idúcimi R vlnami slúži k určeniu komorového rytmu. RR interval je základný zdroj rytmu pre všetky druhy interpretácie EKG. Používa sa k charakterizovaniu rôznych druhov arytmií rovnako ako pri štúdiách variability srdečného rytmu,
- **PQ interval** udáva časový úsek od začiatku depolarizácie srdečných siení po vznik depolarizácie srdečných komôr, teda udáva čas, ktorý potrebuje elektrický impulz k ceste zo sinoatriálneho (SA) uzla do srdečných komôr. Dĺžka PQ intervalu silno závisí na srdečnom rytme,
- **QT interval** udáva časový úsek od začiatku depolarizácie srdečných komôr po dokončenie ich repolarizácie. Tento interval sa skracuje so stúpajúcim srdečným rytmom.

2 KLINICKÁ ELEKTROKARDIOGRAFIA

Klinická elektrokardiografia sa zoberá popisom kardiologických abnormalít na základe elektrokardiogramu meraného na povrchu tela [3]. Z distribúcie povrchových potenciálov, ale nie je vždy možné presne určiť zdroj problému, keďže danú zmenu EKG krivky môže v niektorých prípadoch vyvolať viacero faktorov. Preto sa pri náročnom hodnotení pristupuje k meraniu EKG invazívnou cestou, prípadne vo výskume k meraniu EKG na izolovanom srdci (animálne EKG).

2.1 Fyziologické zmeny srdečného rytmu

Srdečný rytmus je u normálneho srdca riadený elektrickými impulzmi tvorenými v sinoatriálnom (SA) uzle a v pokoji nadobúda hodnoty v rozmedzí 50 až 100 úderov za minútu – takzvaný **sínusový rytmus** (Obr. 2.1). Rytmus s frekvenciou nižšou ako 50 úderov za minútu sa nazýva sínusová bradykardia a sínusová tachykardia ak prekračuje hodnotu 100 úderov za minútu. V pokoji je srdečný rytmus v podstate pravidelný, nie však úplne a to aj pri absencii vonkajších faktorov ako fyzická námaha alebo stres. Elektrická aktivita SA uzla je modulovaná sympatickým a parasympatickým systémom, ktoré sú súčasťou autonómnej nervovej sústavy (vegetatívnej sústavy). Odchýlky v rytme alebo narušenie normálneho sínusového rytmu sa nazýva **arytmia**. Malé zmeny srdečného rytmu sú spôsobené neustálou zmenou rovnováhy medzi sympatickým a parasympatickým systémom [1], [2]:

- zvýšenie aktivity parasympatického systému vedie k zníženiu hodnoty srdečného rytmu
- zvýšenie aktivity sympatického systému vedie k zvýšeniu hodnoty srdečného rytmu




Obr. 2.1: Normálny sínusový rytmus (prevzaté z [3])

Respiračná arytmia (RSA – Respiratory sinus arrhythmia) súvisí u zdravého jedinca s fázou dýchania. A to tak, že frekvencia srdečného rytmu sa zvyšuje s nádychom a znižuje s výdychom (hlavne pri hlbokom dýchaní). Tento jav je bežný u mladších jedincov, u starších môže byť známkou neurózy [1].

2.2 Abnormálne zmeny srdečného rytmu


2.2.1 Ektopický srdečný sťah, tachykardia a fibrilácia

Jedna z príčin vzniku arytmie je ak dochádza k vzniku depolarizačného impulzu mimo SA uzol, v inej časti myokardu [3]. Tento jav vedie k **ektopickému srdečnému sťahu**. Ak sa ektopické ložisko nachádza v srdečných sieňach dochádza k tzv. **predčasnému sťahu siení** (APC – atrial premature contraction, Obr. 2.2).




Obr. 2.2: Predčasný sťah siení (APC, šípky označujú výskyt ektopie, prevzaté z [3])

Ak je toto ložisko v srdečných komorách dochádza k tzv. **predčasnému sťahu komôr** (VPC – ventricular premature contraction, Obr. 2.3).




Obr. 2.3: Predčasný sťah komôr (VPC, prevzaté z [3])

Obyčajne sa po výskyte ektopie srdce vráti do normálneho sínusového rytmu, zatiaľ čo príčina ektopie môže pretrvať. V niektorých prípadoch, ale prejavy ektopie pretrvávajú a dôjde k striedaniu sínusových a VPC cyklov, tento jav nazývame **bigeminia siení** (ventricular bigeminy). V prípade veľkého počtu ektopických cyklov dôjde k abnormálnemu zvýšeniu srdečného rytmu. Ak srdce zostane v takomto kvázi stabilnom stave, ide o nebezpečný jav. Dochádza k rýchlej cyklickej depolarizácii tkaniva srdca. Tento jav sa nazýva reentrantná arytmia, jej typickým príkladom je **tachykardia komôr** (VT – ventricular tachycardia). Tento stav je patologický a rýchlo smrteľný, pretože srdce nedokáže efektívne prečerpávať krv.




Obr. 2.4: Tachykardia komôr (VT, prevzaté z [3])

V niektorých prípadoch sa môže depolarizačná vlna rozložiť na mnoho menších vln, ktoré kvázi náhodne cirkulujú myokardom. To ma za následok úplné vysadenie koordinovaných sťahov a chvenia myokardu. Tento jav sa nazýva **fibrilácia**. Ak pri fibrilácii stále správne funguje atrioventrikulárny (AV) uzol, ktorý neprepustí kvázi náhodné vlnenie iba normálny QRS komplex, dochádza k tzv. **fibrilácii siení** (AF – atrial fibrillation, Obr. 2.5).



Obr. 2.5: Fibrilácia siení (AF, prevzaté z [3])

Tento jav je často tolerovaný. Naproti tomu, ak dôjde k prieniku cez AV uzol hovoríme o **fibrilácii komôr** (VF – ventricular fibrillation, Obr. 2.6), ktorá je behom sekúnd až minút smrteľná [3].




Obr. 2.6: Fibrilácia komôr (VF, prevzaté z [3])

Kmitanie srdečných siení (atrial flutter, AFL) a **kmitanie srdečných komôr** (ventricular flutter, VFL) sú arytmie, ktoré sa prejavujú ako rýchly pravidelný rytmus, na rozdiel od chaotického rytmu fibrilácii [1]. Oproti kmitaniu srdečných siení má kmitanie komôr značne vyššiu amplitúdu, ktorá v čase kolíše.

2.2.2 Bloky vedenia, bradykardia a oneskorené rytmy

Tento typ arytmií je spojený s príliš pomalým srdečným rytmom – **bradykardiou**, a abnormálnymi blokmi vedenia stimulačného impulzu myokardom [3]. Najjednoduchším prípadom je príliš pomalá stimulácia SA uzlom, riešením je implantácia umelého pacemakera. Ďalšou príčinou spomalenia srdečného rytmu môže byť tzv. **AV-blok** (Obr. 2.7), ktorý spomalí komorový rytmus. Podľa toho, či AV uzol chybné vedie len niektoré vlny (AV-blok druhého stupňa), alebo dochádza k chybnému vedeniu všetkých vln (AV-blok tretieho stupňa), delíme AV-blok do niekoľkých stupňov. AV-blok prvého stupňa nespomaľuje komorový rytmus.




Obr. 2.7: AV-blok druhého stupňa (šípky poukazujú na variantnosť PQ intervalu, prevzaté z [3])

Blok vedenia ktorý nastáva v oblasti Tawarových ramienok sa všeobecne rozdeľuje na **pravý a ľavý blok Tawarových ramienok**. Zatiaľ čo táto abnormalita ma obyčajne len minimálny vplyv na srdečný rytmus, zasadne ovplyvní zmenu trajektórie srdečného vektoru. To môže maskovať iné závažnejšie patológie (napr. ischémiu).

Téma bradykardie a blokov vedenia vedie k problematike **oneskorených úderov** (escape beats). Oneskorené údery sú podobné ektopickým v tom, že depolarizácia nastáva mimo SA uzol. Rozdiel je, že oneskorené údery sú spôsobené normálnou kompenzačnou reakciou funkcie srdca proti zlyhaniu. Dôležitým rozdielom je aj to, že ektopický srdečný sťah je obyčajne predčasný, zatiaľ čo oneskorené údery RR interval predlžujú.

2.2.3 Ischémia, iné metabolické narušenia a abnormality štruktúry

EKG môže odhaliť aj metabolické abnormality myokardu. K najvýznamnejším abnormalitám patrí **ischémia**, tá nastáva ak niektorá časť myokardu nie je dostatočne prekrvená. Obyčajne sa v EKG prejavuje zmenou T vlny a ST intervalu spôsobenou alternáciou hlavného srdečného vektoru. Špecifické vzory sa vyskytujú len v minoritnom počte ischemických cyklov, obyčajne sa tieto cykly vyznačujú nešpecifickými zmenami, ktoré môžu a nemusia byť spôsobené ischémiou. Dá sa povedať, že EKG je citlivé hlavne na veľkoplošné (akútne) srdečné ischémie. Táto informácia je v praxi využívaná napr. pri výbere spôsobu liečby. [3]

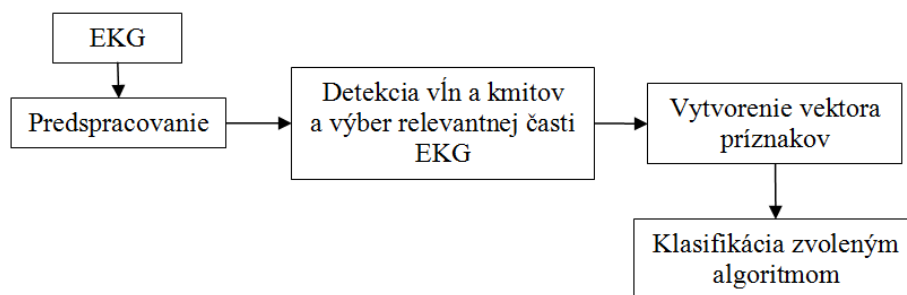


Obr. 2.8: Akútny infarkt myokardu, veľké plochy ischemického predného myokardu – elevácia ST segmentu vo viacerých zvodoch (prevzaté z [3])

Ďalšou z metabolických abnormalít, ktorá spôsobuje charakteristické zmeny EKG je hyperkaliémia (hyperkalemia), ktorá indikuje zvýšenú hladinu draslíka. Prejavuje sa vysokými špicatými T vlnami, stratou vln P a narušením QRS komplexu. Hypokaliémia (hypokalemia) spôsobuje vlnenie po vlne T tzv. U vlny. Okrem týchto faktorov majú vplyv na zmenu štruktúry EKG aj iné, ako napr. hladina kalcia a magnézia, extrémne nízka telesná teplota, použitie niektorých liekov atď. [3]

3 KLASIFIKÁCIA SRDEČNÉHO CYKLU

Automatická klasifikácia srdečného cyklu je komplexný proces (Obr. 3.1), ktorý nezahŕňa len návrh samotného klasifikátora, ale celkové spracovanie vstupného signálu vrátane jeho výberu (prípadne získania), ako aj dodatočné spracovanie a zhodnotenie výstupu klasifikátora. Táto kapitola popisuje jednotlivé kroky tohto procesu pri vytváraní klasifikácie s učiteľom (supervised classification, determinuje rozloženie klasifikačných tried), ako aj vybrané metódy v každom z krokov. Podstata klasifikácie s učiteľom spočíva v tom, že pre časť signálu poznáme klasifikačný výsledok určený klinickým expertom. Podľa tejto časti signálu učíme klasifikátor podávať na výstupe správnu odozvu.



Obr. 3.1: Štruktúra procesu klasifikácie srdečného cyklu

3.1 Výber a spracovanie vstupných dát

Správny výber vstupných dát a ich následné kvalitné spracovanie má veľký vplyv na relevantnosť samotnej klasifikácie. Výber cieľovej skupiny vstupných dát určuje ako a na čo konkrétne môžu byť výsledky klasifikácie určené, zatiaľ čo kvalita spracovania a ich selekcia môže mať veľký vplyv na chybu klasifikácie.

3.1.1 Zdroje vstupných dát

Obvykle sa ako zdroj vstupných dát využíva signál EKG meraný na ľuďoch alebo zvieratách (experimentálne invazívne procedúry). Prípadne je možné využiť niektorú z databáz EKG cyklov, kde sú k dispozícii nami požadované patologické i nepatologické srdečné cykly.

Pri výbere subjektov, ktorých EKG chceme využiť musíme dbať na **populačné faktory** ako je vek, pohlavie, užívané lieky, medicínska a rodinná anamnéza a aktivity jednotlivých osôb (napr. aktívny šport môže viesť k zníženiu srdečného rytmu). Z týchto parametrov logicky vyplýva, že merané subjekty musíme kategorizovať čo vedie k ďalšiemu parametru a to počet subjektov v každej kategórii.

Iným dôležitým faktorom je **miesto a dĺžka záznamu EKG**. Pri voľbe miesta musíme dbať na to, že hospitalizovaní pacienti budú ľahšie tolerovať viac zvodové meranie, ale na druhej strane nezachytíme pri tom ich bežné aktivity. Z pohľadu doby záznamu je veľmi atraktívna predstava krátkodobého (rýchleho) merania, ktorá umožňuje vytvoriť a udržať špecifické podmienky vhodné pre danú analýzu. Všeobecne sa uvádza, že na klinicky užitočné údaje je potrebný aspoň 60 minútový záznam. Niekedy je však potrebné dlhodobejšie meranie, k tomu je obvykle využívaný Holterov monitor.

Výber vhodných elektród (málo kedy je možné použiť kompletný 12 zvodový systém) **a ich vyhotovenia** (povrchové, implantované) úzko súvisí s cieľom klasifikácie (napr. pri monitorovaní ST segmentu sa odporúča využiť zvody III a V3, ktoré majú najlepšie morfológické vlastnosti v tejto oblasti [3]).

Zo záznamu EKG je všeobecne možné odvodiť **súvisiace fyziologické signály**, kde patria signály dýchania, krvného tlaku a činnosti (fyzickej aj mentálnej).

S experimentálnym meraním a zberom dát sa viaže aj mnoho hardwarových obmedzení a faktorov, ktoré musíme zohľadniť (všetky tieto faktory sa odzrkadlia okrem iného aj na cene daného experimentu). Preto sa väčšinou pred samotným experimentálnym meraním dát pristupuje k vývoju klasifikačnej metódy za pomoci databáz signálov.

Databázy signálov môžu byť vhodným vstupným signálom pri overení teoretického podkladu danej klasifikácie. Ich rozsah a variabilita je však často limitovaná, a preto nemusia vyhovovať všetkým experimentom, prípadne nemusia byť dostatočne popísané alebo kompatibilné. Pre klasické využitie v klinickej medicíne sú používané tieto formáty [3]:

- rozšírený Európsky formát dát (EDF+, European Data Format), obvyčajne využívaný v elektroencefalografii,
- HL7 formát založený na XML, využívaný hlavne na prenos dát medzi nemocničnými zariadeniami,

- databáza vlnení (WFDB), set knižnic vyvinutý na MIT (Massachusetts Institute of Technology).

S ohľadom na kompatibilitu a rozsah dát sa pri klasifikácii najčastejšie vyžíva formát WFDB, konkrétne voľne dostupná databáza EKG (PhysioNet). Okrem toho všetky zariadenia, ktoré slúžia k detekcii arytmií a QRS by mali byť testované vstupnými signálmi z databázy MIT-BIH. Tento test slúži k porovnaniu úspešnosti klasifikácie daného algoritmu voči už vyvinutým algoritmom.

3.1.2 Spracovanie vstupného signálu

Pod spracovaním vstupného signálu rozumieme úpravu jeho vlastností pre dosiahnutie čo najlepšieho výsledku klasifikácie (napr. zvýšenie SNR, odstránenie artefaktov, atď.). Jedným zo základných typov spracovania signálu u EKG je jeho **filtrácia**. Zvlášť pri neinvazívnom meraní je obvykle získaný signál zašumený. Medzi základné šумы, ktoré sa v EKG signáli vyskytujú patrí:

- šum spôsobený pohybmi pacienta, je spôsobený elektrickou aktivitou kostrového svalstva pri pohybe (EMG), nachádza sa v oblasti do 5 Hz v prípade záťažového EKG do 20 Hz, odstránenie tohto šumu je najzložitejšie vzhľadom na zachovanie dôležitej informácie v signáli,
- drift, ide o šum, ktorý spôsobuje kolísanie nulovej línie, vzniká pri zlej kvalite alebo umiestnení elektród, alebo inými biomechanickými vplyvmi ako je dýchanie, tento šum sa nachádza na frekvenciách do 1Hz preto je jeho odstránenie pomerne jednoduché,
- sieťový brum, jedná sa o úzkopásmový šum len s malým kolísaním frekvencie (50 Hz), je spôsobený napájaním snímacieho zariadenia z elektrickej siete (jeho zlým uzemnením alebo tienením), pri odstránení tohto šumu je možné efektívne využiť adaptívne filtre,
- medzi ďalšie šумы patrí impulzné rušenie, šum elektrických obvodov zariadenia, vplyv EMC (elektromagnetického poľa), vzájomné biologické rušenie orgánov atď.

Ďalším typom spracovania vstupného signálu je jeho **normalizácia**. Tá slúži k zamedzeniu vplyvu parazitnej variantnosti vstupného signálu, ktorá môže spôsobiť chybnú funkciu klasifikačného algoritmu. Medzi najjednoduchšie spôsoby normalizácie patrí normalizovanie rozsahu minima a maxima (napr. k hodnotám [-1, 1]).

Z dôvodu následnej archivácie alebo obmedzenia rozsahu vstupných dát vzhľadom na výkon klasifikačného zariadenia, je ďalším krokom **kompresia** vstupného signálu. Medzi dnes prezentované kompresné metódy patrí:

- kompresia pomocou vlnkovej transformácie, napr. využite modifikovaného algoritmu SPIHT (Set Partitioning in Hierarchical Trees) [4],
- kompresia na princípe analýzy syntézy kódovania (analysis by synthesis coding), pričom sa používa ASEC (Analysis by Synthesis ECG Compressor) algoritmus [5],
- kompresia s použitím štatistickej techniky analýzy primárnych komponentov (PCA – Principal Component Analysis), prípadne Karhunen-Loeveho transformácia (KLT, Karhunen-Loeve Transform), ktorá počíta tzv. vlastné čísla a

vektory vstupnej matice [6].

3.1.3 Selekcia signálu

Proces selekcie signálu EKG spočíva v nájdení jednotlivých srdečných cyklov (napr. R vlna $\pm n$ vzorkov), čo je založené na detekcii QRS komplexu. Následne podľa potrieb príznakového vektoru spracovania, tento cyklus môžeme využiť celý (PQRST), alebo obmedziť len na potrebnú časť (QRS, QRST, atď.).

3.2 Vytváranie príznakového vektora

Tento proces sa dá charakterizovať ako úprava vstupného signálu (EKG) do podoby vektorov príznakov, ktoré neskôr vstupujú do klasifikátora. U daných vektorov požadujeme čo najväčšiu rozlíšiteľnosť klasifikačných tried.

3.2.1 Metódy vytvárania príznakového vektora

Táto kapitola popisuje niekoľko vybraných metód vytvárania príznakového vektora z EKG signálu. Všetky využívané metódy sa dajú všeobecne rozdeliť do dvoch kategórií:

- metódy založené na morfológických parametroch odvodených z časových priebehov EKG, tie sú okrem iného silne závislé na kvalite detekcie jednotlivých štruktúr v EKG,
- metódy nesúvisiace priamo s morfológiou EKG, ktoré využívajú zmeny EKG v inej ako časovej oblasti (napr. frekvenčnej), tieto metódy sú menej náročné na kvalitu vstupného signálu a obyčajne postačuje rozdelenie EKG do srdečných cyklov (napr. odvodením polohy R - piku).

Štandardné klinické parametre EKG

V klinickej praxi je stále do veľkej miery využívané spracovanie EKG signálu jeho rozmeraním v časovej oblasti. To znamená využitie hodnôt medzi úderových intervalov a amplitúd vln.

Obyčajne nás pri tomto type spracovania zaujímajú tieto hodnoty (výber závisí na konkrétnej klasifikácii) [3]: dĺžka PR segmentu a jeho záporný sklon, nárast výšky vlny P, negativita vlny Q, pokles šírky QRS komplexu, pokles amplitúdy R vlny, negativita vlny S, depresia bodu J, zmeny úrovne (elevácia/depresia) ST, nárast amplitúdy vlny T, dĺžka QT intervalu, výskyt vlny U a rýchlosť poklesu RR intervalu.

Jednou z metód môže byť klasifikácia založená na morfológii QRS komplexu, pričom klasifikované boli 4 typy cyklov z MIT-BIH [7].

Ďalšou klasifikačnou metódou, ktorá využíva spracovanie EKG v časovej oblasti je klasifikácia laterálneho a nižšieho infarktu myokardu pomocou analýzy elevácie ST vo zvode aVR [8].

Zaujímavá metóda používaná na rozmeranie EKG signálu, určenie polohy QRS a nábehu spádu vln P a T je metóda založená na multirezolúčnej vlnkovej transformácii [9].

Nemorfológické parametre EKG


Vzhľadom na to, že morfológické analýzy EKG sú obyčajne pomerne náročné na kvalitu signálu a spracovanie, dochádza k výskumu a použitiu nemorfológických parametrov. Príznaky odvodené týmito parametrami môžu byť odolné voči šumu, a tým kladú menšie nároky na vstupný signál.

Jednou z často používaných možností vytvorenia príznakového vektoru zo vstupného signálu je **analýza srdečného rytmu** (HRV – Heart Rate Analysis, vid' [1], [3]), ktorá poskytuje štatistické a grafické výstupy z časovej, frekvenčnej a nelineárnej oblasti spracovania EKG signálu. Tieto metódy sú založené na fluktuácii RR intervalu v čase, takže môžu byť užitočné pri klasifikácii arytmií.

Ďalšou zo zmienovaných metód je využitie vlnkovej transformácie (WT – wavelet transform), ktorá reprezentuje spracovanie EKG signálu v časovo-frekvenčnej oblasti. Napr. využitie vlnkovej transformácie pri extrakcii príznakového vektora z rôznych druhov biologických signálov [10], [11].

Analýza spektrálnej oblasti EKG nie je bežne využívaná. Poskytuje však zaujímavú možnosť spracovania vstupných dát, pretože je menej citlivá na kvalite vstupného signálu ako metódy založené na analýze v časovej oblasti.

Najčastejšie sa pri spracovaní signálu do frekvenčnej oblasti využíva výpočet **výkonového spektra signálu** (P, PSD – Power Spectral Density), ktorého rozloženie výkonu je len málo závislé na použítom zvode. Rozloženie výkonu je v PSD u zdravého srdca dané rozložením spektrálneho výkonu vln P a T a komplexu QRS. Zatiaľ čo pri fyziologickej zmene srdečného rytmu sa morfológia PSD mení len málo, zmeny pri výskyte závažnejších arytmií sú výrazné (Obr. 3.2) [3], [12].




Obr. 3.2: Vplyv arytmií na tvar PSD, sinus – sínusový rytmus, VT – tachykardia komôr, VFL – kmitanie komôr, VF – fibrilácia komôr (prevzaté z [3])

Pri výpočte podobnosti spektier z dvoch rôznych zvodov alebo časových úsekov je možné použiť výpočet **vzájomnej koherencie spektier** (C_{xy} , CSC - Cross Spectral Coherence, Obr. 3.3). Táto metóda sa zatiaľ v praxi nevyužíva, ale poskytuje zaujímavé možnosti (viď. kapitola 4). Vypočítame ju ako

$$C_{xy} = |P_{x,y}|^2 / (P_x P_y), \quad (3.1)$$

kde P_x je výkonové spektrum signálu x , P_y výkonové spektrum signálu y , a $P_{x,y}$ je vzájomné výkonové spektrum x a y . Výstupná hodnota reprezentuje mieru podobnosti signálu na jednotlivých frekvenciách a nadobúda hodnoty od 0 do 1 (dá sa považovať za normalizovaný výstup). Zmena CSC medzi dvomi zvodmi môže slúžiť k detekcii patológií, ktoré majú vplyv na zmenu hlavného srdečného vektoru (napr. ischemia).



Obr. 3.3: Vzájomná spektrálna koherencia, C1xy – CSC medzi zvodmi I a II, C2xy – CSC medzi 10 sekundovými úsekmi zo zvodu I (prevzaté z [3])

3.2.2 Výber relevantných príznakov

Výber relevantných príznakov spočíva v obmedzení veľkosti výstupného príznakového vektora bez straty relevantnej informácie. To je možné riešiť v zásade tromi spôsobmi: intuitívne - podľa tvaru výstupného signálu zhodnotíme, čo je pre nás podstatné, testovaním - znižujeme veľkosť vstupného vektora klasifikátora kým je jeho úspešnosť klasifikácie v nami určených medziach, alebo využitím niektorej z výpočetných metód. Medzi často používané štatistické metódy radíme napr. analýzu primárnych komponent (PCA) a z nej odvodený singulárny rozklad (SVD).

Analýza primárnych komponent – PCA

Pri výbere relevantného príznaku sa javí ako zaujímavá možnosť využitie PCA, ktorá dokáže zo vstupných príznakov derivovať tie s najväčšou informačnou hodnotou. Zároveň táto metóda dokáže odstrániť prípadný šum a artefakty v signáli [13].

Pri aplikácii PCA na EKG signál chápeme príznakový vektor \mathbf{x} každého srdečného cyklu ako vektor pozorovania náhodného procesu o dĺžke N . Tým na vstup PCA predkladáme maticu \mathbf{X} o rozmeroch $N \times M$ kde M je počet pozorovaní náhodného procesu (počet srdečných cyklov)

$$\mathbf{x} = \begin{bmatrix} x(1) \\ x(2) \\ \vdots \\ x(N) \end{bmatrix}, \quad \mathbf{X} = [x_1 \quad x_2 \quad \cdots \quad x_M]. \quad (3.2)$$

Následná derivácia primárnych komponentov je založená na predpoklade, že signál \mathbf{x} je náhodný proces s nulovou strednou hodnotou charakterizovaný korelačnou maticou

$$\mathbf{R}_x = E[\mathbf{x}\mathbf{x}^T]. \quad (3.3)$$

Primárne komponenty \mathbf{x} sú výsledkom aplikácie ortonormálnej lineárnej transformácie Ψ na \mathbf{x} ,

$$\mathbf{w} = \Psi^T \mathbf{x}, \quad (3.4)$$

kde \mathbf{w} je vektor primárnych komponentov. Prvý komponent w_1 je produkt $\psi_1^T \mathbf{x}$ kde ψ_1 je vybraný tak, aby variantnosť w_1 bola

$$E[w_1^2] = E[\psi_1^T \mathbf{x}\mathbf{x}^T \psi_1] = \psi_1^T \mathbf{R}_x \psi_1. \quad (3.5)$$

pričom $\psi_1^T \psi_1 = 1$. Maximálnu variantnosť dosiahneme vtedy, ak je ψ_1 vybrané ako normalizovaný vlastný vektor odpovedajúci najväčšiemu vlastnému číslu z \mathbf{R}_x označeného ako λ_1 , výsledná variantnosť teda je rovná

$$E[w_1^2] = \psi_1^T \mathbf{R}_x \psi_1 = \lambda_1 \psi_1^T \psi_1 = \lambda_1. \quad (3.6)$$

Podobným spôsobom vypočítame variantnosť w_2 , kde použijeme druhé najväčšie vlastné číslo λ_2 . Ak chceme získať všetkých N rôznych primárnych komponentov, musíme vypočítať vlastný vektor \mathbf{R}_x

$$\mathbf{R}_x \Psi = \Psi \Lambda, \quad (3.7)$$

kde Λ je diagonálna matica obsahujúca vlastné čísla $\lambda_1, \dots, \lambda_N$. V praxi obyčajne hodnotu \mathbf{R}_x nepoznáme, preto korelačnú maticu o veľkosti $N \times N$ definujeme pri výpočte vlastného vektora ako

$$\hat{\mathbf{R}}_x = \frac{1}{M} \mathbf{X}\mathbf{X}^T. \quad (3.8)$$

Singulárny rozklad - SVD

Vlastný vektor používaný u PCA je možné určiť priamo z matice \mathbf{X} použitím SVD (singular value decomposition). Pri SVD využívame rozklad matice \mathbf{X} o veľkosti $N \times M$ na [13]:

$$\mathbf{X} = \mathbf{U}\mathbf{\Sigma}\mathbf{V}^T, \quad (3.9)$$

kde \mathbf{U} je $N \times N$ ortonormálna matica ľavých singulárnych vektorov a \mathbf{V} je $M \times M$ ortonormálna matica pravých singulárnych vektorov. $\mathbf{\Sigma}$ o veľkosti $N \times M$ je nezáporná diagonálna matica obsahujúca singulárne čísla $\sigma_1, \dots, \sigma_N$, za predpokladu $N < M$.

Použitím SVD môže byť korelačná matica $\hat{\mathbf{R}}_x$ (viď 3.8) vyjadrená pomocou \mathbf{U} a diagonálnej matice Λ , ktorej položky sú normalizované singulárne čísla umocnené na druhú $\sigma_1^2/M, \dots, \sigma_N^2/M$ [13],

$$\hat{\mathbf{R}}_x = \frac{1}{M} \mathbf{X}\mathbf{X}^T = \frac{1}{M} \mathbf{U}\mathbf{\Sigma}\mathbf{V}^T \mathbf{V}\mathbf{\Sigma}^T \mathbf{U}^T = \mathbf{U}\mathbf{\Lambda}\mathbf{U}^T. \quad (3.10)$$

Porovnaním s vzťahom 3.7 je jasné že vlastný vektor u PCA získame ako ľavý singulárny vektor \mathbf{U} , teda $\mathbf{\Psi} = \mathbf{U}$ a vlastné čísla λ_k ako σ_k^2/M . Podobne pravý singulárny vektor \mathbf{V} obsahuje informáciu o vnútrocyklových koreláciách, pretože tie sú spojené s vzorkami korelácie $\hat{\mathbf{R}}_x$.

Prístupy spracovania EKG pomocou PCA

Je známych niekoľko prístupov k využitiu PCA na spracovanie EKG signálu. V tejto časti si stručne popíšeme tri z nich.

1. Transformácia viac zvodového EKG

Pri tomto prístupe predpokladáme viac zvodové meranie EKG. A teda v čase n je signál \mathbf{x}_i reprezentovaný vektorom

$$\mathbf{x}_i(n) = \begin{bmatrix} x_{i,1}(n) \\ x_{i,2}(n) \\ \vdots \\ x_{i,L}(n) \end{bmatrix}, \quad (3.11)$$

kde L je počet zvodov. Aplikáciou SVD na takto zostavený signál získame rozklad na ľavý singulárny vektor matice \mathbf{U} , obsahujúci časové informácie a pravý singulárny vektor matice \mathbf{V} obsahujúci informáciu o medzizvodových koreláciách. Na základe týchto znalostí môžeme koncentrovať informačnú hodnotu signálu do menšieho počtu zvodov pomocou transformácie

$$\mathbf{w}_i(n) = \mathbf{V}^T \mathbf{x}_i(n), \quad n = 1, \dots, N. \quad (3.12)$$

Následne vyberieme N' prvých transformovaných zvodov \mathbf{w}_i , napr. zobrazením a zhodnotením informačnej dôležitosti transformovaných zvodov [13].

2. Kompresia EKG v časovej oblasti

V tomto prípade chápeme signál EKG ako maticu $N \times M$, kde N je počet vzoriek jedného cyklu a M je počet cyklov. Cieľom kompresie v čase je výber tzv. reprezentantov, teda obmedzenie rozmeru M matice EKG na M_I tak, aby transformovaná matica $N \times M_I$ obsahovala všetky morfológické typy cyklov (pri zvolenej citlivosti) obsiahnuté v celkom signáli. To môžeme dosiahnuť podobne ako v predchádzajúcom prípade využitím rozkladu SVD. Kde jeho aplikáciou (viď 3.9) získame ľavý singulárny vektor matice \mathbf{U} , obsahujúci informáciu o koreláciách vzoriek v rámci jedného cyklu a singulárny vektor matice \mathbf{V} , obsahujúci informáciu o medzicyklových koreláciách. Následne stanovíme nami zvolenú mieru odlišnosti rekonštruovaného signálu, ktorú môžeme vypočítať napr. ako percentuálnu normalizovanú strednú kvadratickú odlišnosť signálov (PRDN% - normalized percentage root-mean-square difference) [14]:

$$PRDN\% = 100 \sqrt{\frac{\sum_{n=1}^N (x(n) - \tilde{x}(n))^2}{\sum_{n=1}^N (x(n) - \bar{x})^2}}, \quad (3.13)$$

kde $x(n)$ je pôvodný signál, $\tilde{x}(n)$ je signál rekonštruovaný a \bar{x} je stredná hodnota pôvodného signálu. Postupne obmedzujeme veľkosť matice \mathbf{V} z $N \times N$ na $N \times M_I$ pri ktorom ešte platí nami určená podmienka odlišnosti signálu rekonštruovaného z takto

zmenšenej matice V . Výsledná matica V_I obsahuje M_I typov cyklov, ich porovnaním s cyklami v pôvodnom signáli je možné tento signál, na základe najvyššej podobnosti k jednému z M_I typov cyklov, rozdeliť na úseky, ktoré môžeme nahradiť jedným cyklom (reprezentantom) a tým zabezpečiť kompresiu v čase.

3. Kompresia dĺžky príznakového vektora EKG

Pri kompresii EKG signálu v oblasti dĺžky príznakového vektora chceme docieľiť výber len tých podstatných častí v jednom srdečnom cykle vzhľadom na ich variantnosť v čase, a tým ich menšiu dátovú náročnosť a taktiež zabezpečíme vysoké rozlíšenie v čase, ktoré je pri kompresii v časovej oblasti nižšie.

Pri riešení tohto problému sa môžeme inšpirovať kompresiou obrazu pomocou PCA, ktorá je pri chápaní EKG signálu ako matice M cyklov o N vzorkách ľahko implementovateľná. Postup takejto kompresie je veľmi podobný kompresii v časovej oblasti. Znovu vypočítame ortonormálne matice U a V pomocou metódy SVD a následne obmedzíme veľkosť matice V tak, aby vyhovovala podmienke (viď. 3.13) dostávame maticu V_I . Potom vypočítame projekciu signálu na primárne komponenty

$$Y = V_I^T X, \quad (3.14)$$

tým získavame maticu primárnych komponentov Y o veľkosti $M_I \times N$. Táto matica priamo odzrkadľuje najpodstatnejšie zmeny v časovej oblasti pri nezmenenej časovej rozlišovacej schopnosti, ale menšou dátovou náročnosťou keďže $M_I < M$ [15].

3.2.3 **Dodatočné spracovanie vektora príznakov**

Cieľom dodatočného spracovania príznakového vektora je jeho normalizácia alebo štandardizácia a kompresia. V tomto kroku je možné použiť podobné metódy ako pri spracovaní vstupného signálu.

Ďalším z krokov dodatočného spracovania vektora príznakov pri klasifikácii s učiteľom je extrakcia tréningovej a validačnej (testovacej) množiny. Oba tieto množiny musia mať klinickým expertom určený klasifikačný výstup na základe klasifikačných tried (viď kapitola 3.3.1). Tréningová množina slúži na samotné učenie klasifikátora a mala by v ideálnom prípade obsahovať všetky typy príznakových vektorov vyskytujúce sa v signáli. Taktiež zastúpenie patologických a nepatologických vektorov by malo byť rovnaké. Dobré je túto množinu usporiadať náhodne, aby nedošlo k zhľukovaniu nepatologických a patologických príznakov do blokov. Čo sa týka validačnej množiny, tá slúži k overeniu výsledku učenia klasifikátora, ak dosahuje klasifikácia na tejto množine podobnú úspešnosť ako tréningová, pravdepodobne nedošlo k preučeniu. Mala by byť zostavená podobne ako tréningová, pri dostatočne dlhom vstupnom signáli ideálne z inej časti signálu. U tejto množiny už nie je nutné náhodné usporiadanie.

3.3 **Klasifikácia**

Úlohou klasifikácie samotnej je na základe vstupného vektora, vygenerovať výstupný vektor, ktorý zaradí aktuálny vstup do jednej zo zvolených klasifikačných tried. V najjednoduchšom prípade ide o lineárne prahovanie spracovaného vstupného signálu.

3.3.1 Klasifikačné triedy

Klasifikačná trieda určuje jeden z možných výstupov klasifikátora. Každá trieda je obvykle kódovaná binárne (0 - 1), prípadne nadobúda číselné hodnoty (0, 1, 2, 3, ...) výskyt hľadaného problému (napr. abnormálne vlny v EKG, prípadne arytmie) v aktuálnom vstupnom úseku signálu. Počet klasifikačných tried môžeme zvýšiť napr. jednoduchým pridaním neurčitého stavu. Obyčajne počet a variantnosť výstupných klasifikačných tried priamo úmerne súvisí so zložitou klasifikátora a požiadavkami na kvalitu vstupného signálu. Predpokladané rozloženie klasifikačných tried sa niekedy, s ohľadom na možnosti danej klasifikačnej metódy, behom experimentu mení. Počet stavov klasifikačnej triedy, pri využití binárneho kódovania, zároveň determinuje počet výstupom potrebných na popis stavu (napr. 2 stavy – 1 výstup, 3 a 4 stavy – 2 výstupy, atď.)


3.3.2 Typ klasifikátora

V dnešnej dobe existuje viacero typov klasifikátorov využívaných v problematike klasifikácie EKG ako napríklad [3]: umelé neurónové siete (artificial neural network - ANN, rôzneho typu), algoritmy podporných vektorov (support vector machine - SVM). V tejto kapitole sa zameriame hlavne na možnosti sieťových klasifikátorov kde patria ANN a SVM.

Umelé neurónové siete

Neurónové siete patria medzi populárne riešenie v oblasti klasifikácie. Všeobecne ide o adaptívny systém, ktorý sa principiálne snaží napodobniť ľudský mozog (sieť biologických neurónov), hlavne proces učenia a získavanie skúseností, ktorý podmieniajú odozvu na daný vstup. V dnešnej dobe existuje viacero typov architektúr týchto sietí a rôzne sú aj prístupy k učeniu siete (s učiteľom – podmienené, bez učiteľa). Čo sa týka problému klasifikácie najčastejšie sa využívajú viacvrstvé dopredné siete (bez spätnej väzby), pričom proces učenia je podmieneného typu. Vlastnosti všeobecnej neurónovej siete môžeme popísať v niekoľkých bodoch [16].

1. Umelý neurón a jeho vlastnosti – k popisu vlastnosti umelého neurónu (Obr. 3.4) slúžia váhy w_0, w_1, \dots, w_N vstupov „1“, x_1, x_2, \dots, x_N , prah ϑ a prevodová funkcia $f(\alpha)$, ktorej argument je tzv. aktivácia α .




Obr. 3.4: Umelý neurón (prevzaté z [16])

Váhy jednotlivých vstupov určujú to, s akou mierou daný vstup ovplyvní výstup y . Prenosová funkcia determinuje rýchlosť prechodu medzi jednotlivými výstupnými

stavmi a taktiež formu výstupu – podľa použitia funkcie môže byť výstup neurónu logický (0, 1), spojitý ($-\infty$ až ∞) alebo normalizovaný (0 až 1, -1 až 1) so skokovým, prípadne lineárnym či nelineárnym prechodom. A prah určuje sumu hodnôt váhami upravených vstupov, pri ktorej reaguje neurón zmenou výstupu. Výstupný stav neurónu môžeme popísať ako:

$$y = f\left(\sum_{i=1}^N w_i x_i - \vartheta\right). \quad (3.15)$$

2. Sieť následne tvorí súbor neurónov usporiadaných do vrstevnatej štruktúry (Obr. 3.5). Každý z neurónov v sieti je popísaný prahmi a prechodovými funkciami a váhami vstupov napr. ${}^2_1 w_3$ je váha tretieho vstupu prvého neurónu druhej vrstvy.




Obr. 3.5: Viacvrstvá neurónová sieť (prevzaté z [16])

Pričom na prvej vrstve sa spravidla používa prenosová funkcia zabezpečujúca normalizáciu hodnôt (napr. tansig -1 až 1). Topológia siete (počet vrstiev a počet neurónov na jednotlivých vrstvách) sa obyčajne určuje empiricky, na základe predchádzajúcich skúseností, prípadne testovaním rôznych variant. Obyčajne platí, že zložitejšia sieť je robustnejšia voči variantnému vstupu, ale pri predložení jednoduchšej klasifikácie môže dôjsť k preučeniu. Pevne daný je len počet vstupov na základe dĺžky príznakového vektora a počet neurónov na výstupnej vrstve, ten determinuje počet množných stavov na výstupe zakódovaný binárne (napr. pre 4 stavy potrebujeme 2 neuróny pre 8 3 neuróny atď.).

3. Pri procese učenia sa pre aktuálny výstup \hat{y}_i siete počíta stredná kvadratická odchýlka (MSE – mean square error) voči predpokladanému odborne klasifikovanému výstupu y_i

$$MSE = \frac{1}{n} \sum_{i=1}^n (\hat{y}_i - y_i)^2, \quad (3.16)$$

kde n je celkový počet predikcii správneho výstupu y . Na základe priebehu MSE (Obr. 3.6) postupne meníme hodnoty váh a prahov jednotlivých neurónov podľa pravidla spätného šírenia chyby – váhy a prahy sú postupne upravované od najvyššej vrstvy k nižšej s uplatnením váhovania spätne sa šíriacej chyby.



Obr. 3.6: Priebeh MSE v procese učenia siete

Celý proces učenia je ešte ovplyvnený zvoleným učiacim algoritmom (gradientný adaptívny, atď., vid' kapitola 4.3.2), počtom epoch učenia, rýchlosťou učenia (learning rate) – obyčajne je kontrolovaná použitým učiacim algoritmom a najväčšou prípustnou hodnotou MSE. Samotný proces učenia je následne zastavený najjednoduchšie buď dosiahnutím maximálneho počtu epoch učenia, alebo najväčšou prípustnou hodnotou MSE. V týchto prípadoch však hrozí tzv. preučenie kedy výsledná sieť reaguje s dobrými výsledkami len na konkrétnu tréningovú množinu a na reálnom signáli vykazuje značnú chybovosť. Problém preučenia je možné riešiť využitím automatického zastavenia procesu učenia, napríklad využitím pokročilých tréningových algoritmov, ktoré vďaka dodatočnému rozdeleniu tréningovej množiny sú schopné pomerne presne nájsť minimum funkcie MSE (Obr. 3.6).

Medzi základne a stále využívané siete patrí viacvrstvový perceptron (MLP – Multilayer Perceptron). Ide o viacvrstvý doprednú sieť s podmieneným učením a tzv. spätným šírením chyby. Aktivačné funkcie neurónov môžu byť rôzneho typu (logická, sigmoidová, lineárna, hyperbolicky tangens atď.). Pri procese učenia takejto siete je dôležité si vstupné dáta rozdeliť na tzv. tréningové (sieť k nim má prístup v celom procese učenia), validačné (dáta, na ktorých sieť simuluje aktuálnu mieru správnosti klasifikácie bez toho aby sa za ich pomoci učila) a testovacie dáta (podobne ako validačné dáta, ale mali by byť z viac nezávislej množiny voči množine tréningových dát). Proces učenia v tomto type siete prebieha nasledovne [16]:

- inicializácia počiatkových váh w a prahov v každého neurónu (náhodné),
- zavedenie dátového vektora x na vstup siete,
- porovnanie vzniknutého výstupu siete s predpokladaným (podmienené učenie), výpočet chyby δ výstupnej vrstvy,
- mechanizmom spätného šírenia chyby sa δ s príslušnou váhou postupne prenesie z výstupnej na vstupnú vrstvu siete,
- úprava váh každého neurónu od výstupnej vrstvy smerom k poslednej skrytej vrstve, uplatnenie tzv. **δ pravidla** – miera zmeny tej ktorej váhy závisí na prenesenej chybe δ , hodnote aktuálneho vstupného vektora x , rýchlosti učenia μ a aktuálnom výstupe y , na nižších vrstvách je toto pravidlo modifikované na základe chybovej funkcie ϵ

$${}^n_j w_i(t+1) = {}^n_j w_i(t) - \mu_i \frac{\partial \varepsilon}{\partial {}^n_j w_i}(t), \quad (3.17)$$

- tento proces sa opakuje buď podľa počtu epoch (jedna epocha = sieťou prejde celý vstupný vektor tréningovej sady), alebo do daného minima MSE zisťovaného obvykle gradientnou metódou (proti smeru gradientu).

Pri vhodne zvolenej metóde vytvárania príznakového vektora a učebnej množine majú tieto siete v praxi účinné využitie. Samozrejme dnes už existujú rôzne modifikácie ANN architektúry ako napr. hybridné fuzzy siete (adaptívne neuro-fuzzy systémy - ANFIS, vid' [17]), siete s radiálnou bázou (radial basis function neural networks - RBFNN, vid' [18]), Takagi-Sugeno-Kane neuro-fuzzy systémy [3] atď.

Algoritmy pomocných vektorov

Princíp klasifikátora pomocou algoritmov pomocných vektorov (SVM – Support Vector Machine) je založený na základe doprednej všeobecnej siete. Základný rozdiel je v tom, že zatiaľ čo ANN sa snaží v N - dimenzionálnom priestore aplikovať nelineárne deliace funkcie jednotlivých tried, SVM zvýši počet dimenzií na K a deliace funkcie linearizuje. Táto vlastnosť je v problematike klasifikácie veľmi užitočná (vid' [19]), a preto je táto metóda často používaná (aj napriek tomu, že ANN už dosahujú zrovnateľných výsledkov úspešnosti klasifikácie) [3].

3.3.3 Výber najlepšieho klasifikátora

Pri testovaní viacerých klasifikátorov v rámci jedného problému klasifikácie je dôležité na záver porovnať ich výsledky. Pri zhotovovaní týchto výsledkov musia byť použité rovnaké vstupné podmienky pre každý klasifikátor. K porovnaniu sa obvyčajne používajú rôzne štatistické metódy.

Jednou z často používaných metód je výpočet *špecificity* a *senzitivity* klasifikačnej metódy

$$\text{senzitivita} = \frac{TP}{TP + FN} (\%), \quad (3.18)$$

$$\text{špecificita} = \frac{TN}{FP + TN} (\%), \quad (3.19)$$

kde TP (true positive) počet vstupov, v ktorých je detekovaná patológia klasifikátorom aj klinickým expertom, TN (true negative) počet vstupov, v ktoré sú detekované ako nepatologické klasifikátorom aj klinickým expertom, FP (false positive) počet vstupov, v ktorých je detekovaná patológia klasifikátorom, ale boli označené za nepatologické klinickým expertom a FN (false negative) počet vstupov, ktoré sú detekované ako nepatologické klasifikátorom, ale boli označené ako patologické klinickým expertom. Ďalšie parametre, ktorými je možné hodnotiť sieť sú miera TP (TP_{rate}), miera FP (FP_{rate}), *presnosť*, *F-meranie* (F-measure) a pozitívna *prediktivita* (+P) [20]

$$FP_{rate} = \frac{FP}{FP + TN}, \quad (3.20)$$

$$TP_{rate} = \frac{TP}{TP + FN}, \quad (3.21)$$

$$presnosť = \frac{TP + TN}{TP + FN + FP + TN}, \quad (3.20)$$

$$F - meranie = \frac{2}{1/špecificita + 1/senzitivita}, \quad (3.21)$$

$$+P = \frac{TP}{TP + FP}. \quad (3.22)$$

Miera TP popisuje pomer TP označených vstupov k celkovému počtu pozitívnych vstupov, miera FP vyjadruje pomer FP k celkovému počtu negatívnych vstupov. Presnosť vyjadruje pomer medzi správne označenými vstupmi a celkovým počtom vstupov. F-meranie priemeruje hodnotu senzitivity a špecificity, čím je to jedna zo smerodajných hodnôt v procese hodnotenia klasifikátora. Často používaný parameter je aj prediktivita, ktorá hovorí o pomere TP a všetkých pozitívne označených vstupov.

3.3.4 Zrovnanie metód detekcie ischémie

Táto podkapitola poskytuje stručný prehľad o výsledkoch dosahovaných pri klasifikácii (Tabuľka 3.1) pomocou rôznych metód (viď. [21]). Ako hodnotiace parametre boli použité senzitivita (*Se*) a pozitívna prediktivita (*+P*).

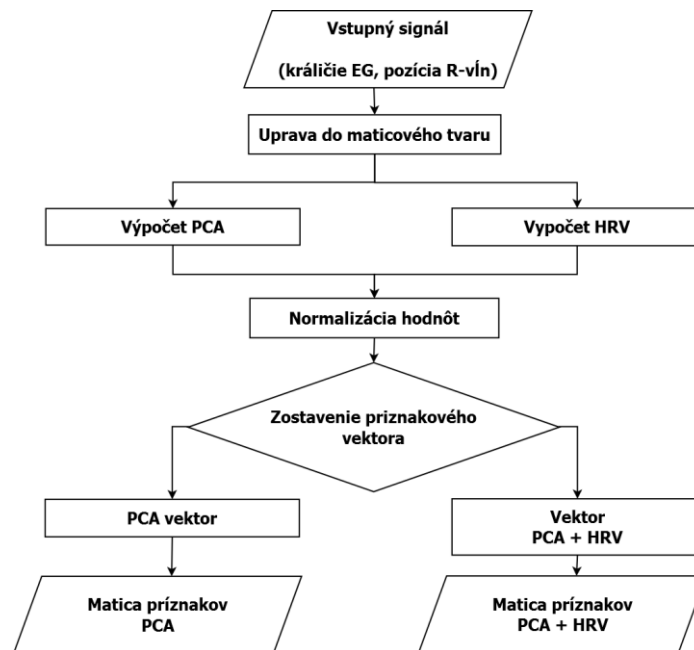
Tabuľka 3.1 Prehľad výsledkov detekcie ischémie (prevzaté z [21])

Metóda	Se [%]	+P [%]
RMS metóda	85	86
geometrická metóda	84	81
PCA	87	88
vlnková transformácia	92	86
adaptívna logická sieť	72	66
sieť so spätným šírením chyby	89	78
adaptívna sieť	89	100
metóda diskriminantov	62	66
fazzy logika	83	75
HMM	89	85
GA a viackritériová analýza rozhodovania	91	91
parametrické modelovanie	81	84
PCA a ANN	90	93
súbor pravidiel	70	63
výber pravidiel (rule mining)	87	93
SOM	75	74
SOM a sieť s radiálnou bázou	80	78
SOM a SVM	83	82
HySMID	91	93
rozhodovací strom	90	70
opakujúce sa ANN	77	85
znalosti sa učiaci ANN	71	66

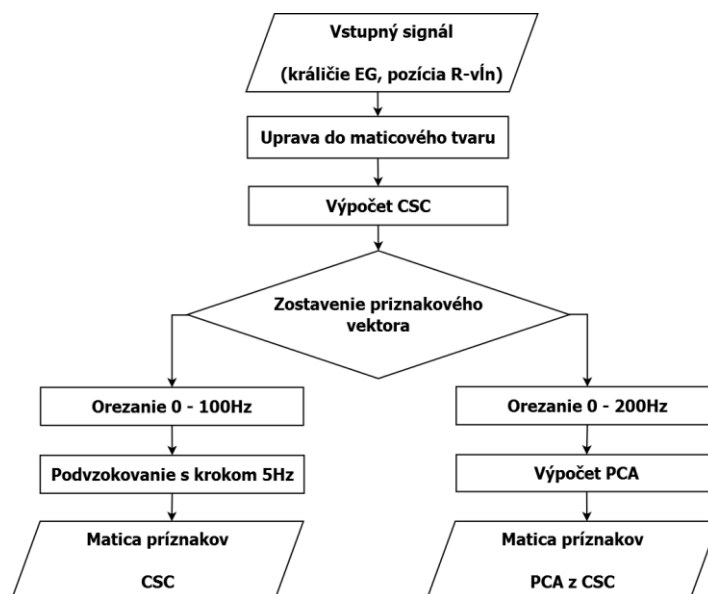
4 NÁVRH METÓDY DETEKČIE ISCHÉMIE

Cieľom diplomovej práce bolo vytvoriť a otestovať klasifikačný algoritmus, ktorý dokáže v predložnom animálnom EG signáli detekovať ischemické srdečné cykly. Táto kapitola popisuje jednotlivé časti algoritmu, ich testovanie a výsledky, ktoré boli pri práci dosiahnuté.

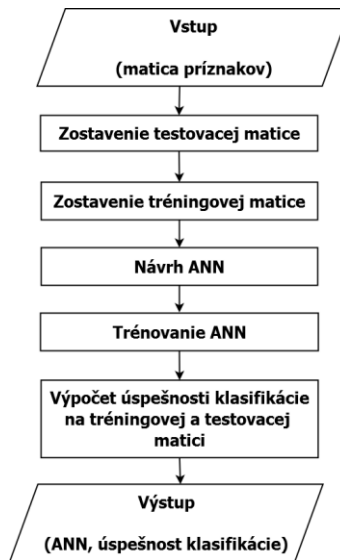
V tejto práci boli otestované štyri postupy výpočtu príznakového vektora pre detekciu ischemie. Využitie kompresie pomocou PCA a PCA kompresia s prídavnými HRV parametrami (Obr. 4.1). Využitie CSC a CSC s kompresiou pomocou PCA (Obr. 4.2). U všetkých metód bol použitý postup klasifikácie s ANN (Obr. 4.3).



Obr. 4.1: Vývojový diagram vytvárania PCA a PCA + HRV príznakovej matice



Obr. 4.2: Vývojový diagram vytvárania CSC a PCA z CSC príznakovej matice



Obr. 4.3: Vývojový diagram klasifikácie pomocou ANN


V priebehu práce došlo ku komplikáciám vo forme nedostupnosti odborne klasifikovaných dát, preto sú dosiahnuté výsledky zamerané skôr na použiteľnosť a funkčnosť využitých metód.

4.1 Vstupné experimentálne dáta

Všetky použité vstupné dáta pochádzajú z experimentálneho merania EG (elektrogram) na izolovanom srdci kráľika, prípadne potkana. V závere experimentu boli prevažne využívané filtrované dáta z nedávnych meraní (marec – apríl 2013).

4.1.1 Experimentálne meranie EG na izolovanom srdci

Tento experiment vznikol na základe spolupráce Vysokého učení technického v Brně, Ústav biomedicínskeho inžénrství a Masarykovej univerzity, Lékařská fakulta, Fyziologický ústav. Priebeh experimentu pozostával z chirurgickej extrakcii srdca meraného subjektu (králik, potkan) v sedácií. Pretože extrahované srdce dokáže ešte niekoľko desiatok minút po extrakcii fungovať, bolo následné srdce umiestnené do meracieho zariadenia a napojené na umelý obeh fyziologickým roztokom (Obr. 4.4). Toto zariadenie kontinuálne meralo EG z **ortogonálnych zvodov I, II a III** a monofázické akčné potenciály srdca (MAP) merané na povrchu srdca pomocou optického merania využívajúceho fluorescencie. Podrobnejšie informácie o priebehu experimentu je možné zistiť z [22], [23], [24], [25], [26].



Obr. 4.4: Prístroj na meranie EG, rozloženie ortogonálnych zvodov v priestore a protokol experimentu (prevzaté z [26])

Vplyvom viacerých typov stimulácií boli v rôznych fázach experimentu vyvolávané abnormálne a patologické príznaky. V našom prípade bola vyvolávaná srdečná ischemia odpojením perfúzie srdca fyziologickým roztokom – srdce nedostáva kyslík ani potrebné látky a nastupuje ischemia. Použitá sada vstupných dát z troch vybraných experimentov pozostáva zo signálu **EG** rozdeleného do jednotlivých fáz experimentu:

- **sc** – kontrolná fáza po štarte experimentu (žiadne vonkajšie stimulácie srdca),


- **dc** – kontrolná fáza po nafarbení srdca napäťovo citlivým farbivom pre meranie akčného potenciálu (bezprostredne pred ischemickou fázou i1),
- **i1** – ischemia 1 – zastavenie perfúzie fyziologického roztoku srdcom (po tejto fáze nastáva fáza reperfúzie r1),
- **i2** – ischemia 2 – ischemická fáza vyvolaná po r1 (nasleduje fáza reperfúzie r2),
- **i3** – ischemia 3 – posledná ischemická fáza vyvolaná po r2.

V najnovších dátach boli k dispozícii tri kontinuálne záznamy trojzvodového EG s vzorkovacou frekvenciou $f_{vz} = 2000 \text{ Hz}$ počas celého experimentu s detekovanou pozíciou R-vln a zadaným indexom jednotlivých fáz. U týchto súborov nebola prítomná fáza **dc**. Dáta v tejto forme boli následne prevedené do maticového tvaru a to vo forme matice $M \times N$, kde M je dĺžka jedného EG cyklu vo vzorkách a N počet cyklov daného merania. Dĺžka cyklu bola empiricky zvolená na 600 vzoriek ($R - 199$ až $R + 400$) tak, aby cyklus obsahoval celý P-QRS-T úsek (Obr. 4.5). Takto sme v programovacom prostredí Matlab 2007 zostavili tri súbory vo formáte .mat uložené vo forme štruktúry:

- *signal_20130327* – 9755 cyklov, 1013 cyklov fáza sc, 1289 cyklov fáza i1, 1313 cyklov fáza i2 a 1372 cyklov fáza i3,
- *signal_20130328* – 8820 cyklov, 706 cyklov fáza sc, 1342 cyklov fáza i1, 1371 cyklov fáza i2 a 1257 cyklov fáza i3,
- *signal_20130402* – 9122 cyklov, 707 cyklov fáza sc, 1313 cyklov fáza i1, 1223 cyklov fáza i2 a 1221 cyklov fáza i3,

každá z týchto štruktúr obsahuje kontinuálne EG pre každý zvod, vektor indexov R-vln, a maticovú podobu EG pre každý zvod.

Staršie signály obsahovali EG (snímané pri vzorkovacej frekvencii $f_{vz} = 2000 \text{ Hz}$) rozdelené na jednotlivé cykly v matici o rozmeroch 800 vzoriek x počet meraných cyklov, delenie EG na jednotlivé cykly prebiehalo pomocou detekcie R-vln a následným výberom úseku $R + 500$ vzoriek a $R - 299$ vzoriek. Rozdielna dĺžka cyklu však nemá žiaden vplyv na výsledný klasifikačný algoritmus, pretože cykly samotné nie sú priamo predkladané ako vstup klasifikačnej jednotky.



Obr. 4.5: Ukážka vstupného signálu EG z troch zvodov: a) I – neischemický, b) I – ischemický, c) II – neischemický, d) II – ischemický, e) III – neischemický, f) III – ischemický –signal_20130402

4.1.2 Selekcia vstupných dát

V predchádzajúcich pokusoch bola získaná EG ešte skrátaná. Za predpokladu, že ischemia len málo alebo vôbec neovplyvní vlnu P a masívne sa prejaví na vlnu T, proces selekcie dát spočíval v odstránení vlny P zo signálu jeho jednoduchým orezaním. Taktiež tým došlo k odstráneniu nepotrebného vplyvu vlny P v spektrálnej oblasti (vlna P a T sú energeticky rozložené na podobnom frekvenčnom rozsahu).

Vo finálnej forme však algoritmus túto selekciu neobsahuje. Keďže testovaním sa zistilo že zvolené príznakové vektory sú dostatočne robustné na to, aby vplyv vlny P na spektrum a morfológiu bol minimálny. A teda v súčasnej podobe algoritmus detekcie pracuje z celým cyklom P-QRS-T. V prípade potreby, napr. menšej dátovej náročnosti vstupnej matice, je možné selekciu zaradiť bez potreby zmeny ďalšej časti algoritmu.

4.2 Vytváranie príznakového vektora

Klasickým prístupom k vytvoreniu príznakového vektora je v praxi rozmeranie signálu na jednotlivé úseky a vlny, ich následná analýza a výber relevantného príznaku (napr. elevácia úseku ST pri ischémii). Táto metóda je však pomerne náročná na kvalitu vstupného signálu, a taktiež je málo odolná na prípadne artefakty. Preto sme zvolili v tejto časti nekonvenčný prístup nevytvárať príznakový vektor z morfológie jednotlivých cyklov, ale z parametrov, ktoré nepriamo na zmenu morfológie poukazujú. Medzi zvolené metódy patrí metóda PCA a z nej odvodený singulárny rozklad, výstupom tejto metódy je vektor primárnych komponentov. Ďalšou je analýza CSC, kde pri ischémii predpokladáme zmenu pozície hlavného srdečného vektora, a tým aj zmenu vzájomnej koherencie spektier u dvoch ortogonálnych zvodov. Oba tieto metódy sa vyznačujú dobrou odolnosťou voči šumu. Dodatočne boli pridané dva parametre metódy HRV, u ktorých je predpoklad zabezpečiť lepšiu detekciu prípadných rytmických zmien.

Všetky tieto metódy boli otestované a vzájomne skombinované do štyroch typov príznakového vektora

- vektor kompresnej metódy PCA zvodu I a zvodu II
- vektor kompresnej metódy PCA zvodu II a zvodu II s pridanými parametrami HRV,
- vektor CSC medzi zvodom I a II,
- vektor CSC medzi zvodom I a II s pridanou kompresnou metódou PCA.

Zvod III sme vzhľadom na jeho predpokladaný výpadok snímania v niektorých častiach experimentu nepoužili. Štruktúry algoritmu sú stručne popísané vývojovými diagramami (Obr. 4.1 až Obr. 4.3)

4.2.1 Kompresná metóda PCA

Pri vytváraní príznakového vektora pomocou PCA sme pristúpili k metóde kompresie dĺžky cyklu EG (600 vzoriek) len na niekoľko najvýznamnejších primárnych komponentov. K tomu bola využitá metóda SVD v programovacom rozhraní Matlab.

Bolo vytvorených celkovo šesť príznakových matíc, obsahujúcich príznakové vektory pre každý z cyklov predložených signálov s využitím zvodov I a II. Postup zostavenia takejto matice príznakových vektorov v prostredí Matlab môžeme popísať v niekoľkých krokoch.

1. Predloženie matice EG a odstránenie jednosmernej zložky – ako vstup slúži matica cyklov EG o veľkosti $M \times N$, kde M je počet vzoriek jedného cyklu a N je počet cyklov zvoleného signálu. Následne bola vypočítaná stredná hodnota každého z riadkov matice. Odstránenie jednosmernej zložky spočívalo v odčítaní týchto stredných hodnôt

od matice EG. Výstupom je matica EG cyklov X o rovnakej veľkosti.

2. Výpočet kovariančnej matice Z_c o veľkosti $M \times M$ ako.


$$Z_c = ZZ^T, \quad (4.1)$$

$$Z = \frac{X^T}{\sqrt{N-1}}. \quad (4.2)$$

3. SVD z matice Z_c – Výstupom sú ortonormálne matice U a V a diagonálna matica primárnych komponent S . Následne vypočítame variantnosť primárnych komponent (Obr. 4.6).

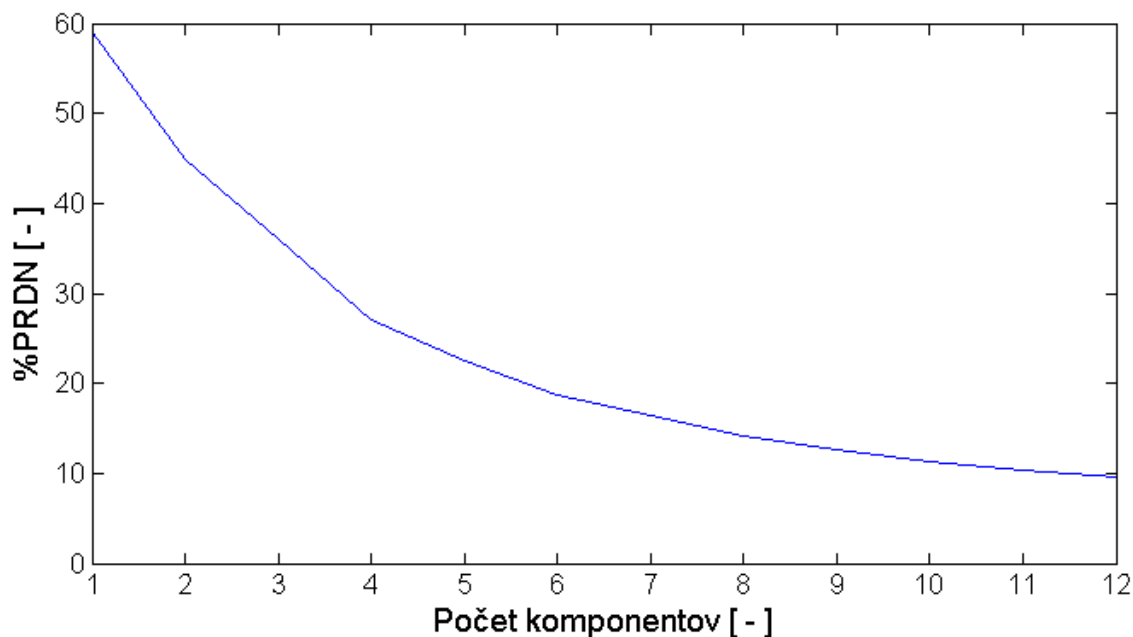
$$\text{variantnosť} = \text{diag}(S) * \text{diag}(S). \quad (4.3)$$

Pri pohľade na závislosť variantnosti na počte konkrétnom komponente je možné pozorovať, že hlavná informačná hodnota je obsiahnutá v prvých štyroch komponentoch.



Obr. 4.6: Variantnosť primárnych komponentov – zvod I, signal_20130402

4. Spätná rekonštrukcia signálu X s variantnou veľkosťou matice V – slúži na určenie dĺžky príznakového vektora (počet použitých primárnych komponent) pri stanovení podmienky, že %PRDN (Obr. 4.7) rekonštruovaného signálu musí byť menej ako 10%. Tento proces je riešený pomocou cyklu *while* kde je premenná veľkosť matice V_1 v zmysle $M \times (1 \text{ až } K)$, K je počet primárnych komponentov pri ktorých využítí splníme podmienku rekonštrukcie. Pre vybrané signály bola maximálna dĺžka vektora 14 komponentov, čo zabezpečí dobrý kompresný pomer a zachovanie informačnej hodnoty.

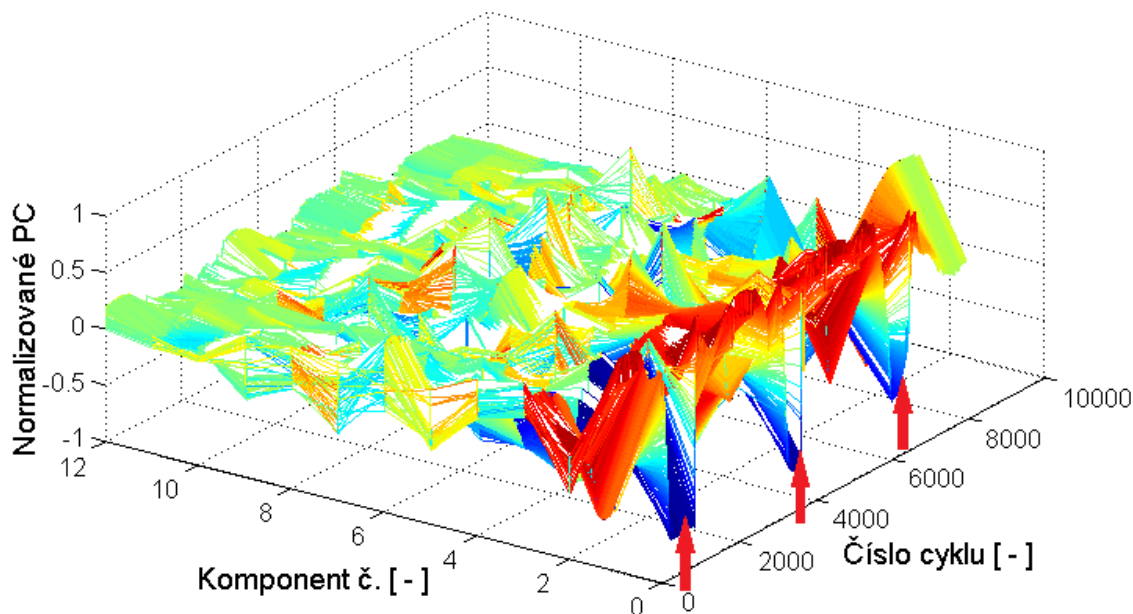


Obr. 4.7: %PRDN rekonštruovaného signálu – zvod I, signal_20130402


5. Vytvorenie výstupnej matice príznakových vektorov Y – matica je priebežne vytváraná a prepisovaná pri testovaní podmienky rekonštrukcie ako

$$Y = V_1^T X, \quad (4.4)$$

a jeho následná normalizácia pomocou funkcie *normc*. Táto normalizácia slúži hlavne k následnej možnosti pridania HRV parametrov, ktoré majú o niekoľko rádov nižší rozsah. Výsledná matica Y (Obr. 4.8, Obr. 4.9) má veľkosť $K \times N$ a amplitúda primárnych komponentov (PC) nadobúda hodnoty -1 až +1.



Obr. 4.8: Normalizovaná matice príznakov PCA – zvod I, signal_20130402 s vyznačenými ischemickými fázami



Obr. 4.9: Príznakový vektor PCA – zvod I, signal_20130402

U vyššie uvedených priebehov je možné pozorovať vysoké kolísanie PC pri ischemickom a neischemickom stave a to hlavne u prvých troch komponentov. To by malo zabezpečiť dobrú klasifikačnú hodnotu takto zostavenej matice.

Takto zostavená matica príznakových vektorov by podľa teoretických predpokladov mala byť odolná voči šumu a ojedinelým artefaktom. Posledným krokom úpravy bolo pričítanie matice Y k nulovej matici PCA o veľkosti $20 \times N-1$ (posledný cyklus sa nevyužíva), kde obsadila prvých K riadkov, pričom posledné dva riadky boli vyhradené pre parametre HRV analýzy.


Zostavenie prídavných parametrov HRV analýzy

Keďže nás v tomto prípade zaujímal srdečný rytmus zaujímal len okrajovo a slúži skôr ako rozšírenie metódy pre iné patológie ako je ischemia, využili sme len jednoduché parametre srdečného rytmu HR a pomer susedných RR intervalov RR -pomer (Obr. 4.10)

$$HR_i = \frac{f_{vz}}{RR_{i+1} - RR_i}, \quad (4.5)$$

$$RR - pomer_i = \frac{RR_{i+1} - RR_i}{RR_i - RR_{i-1}}, \quad (4.6)$$

kde RR_i je i -ty RR interval vyjadrený vo vzorkách f_{vz} je vzorkovacia frekvencia signálu a i nadobúda hodnôt 1 až $N-1$. Pri parametri RR -pomer bol pevné určený RR -pomer₁ = 1, keďže veľkosť predchádzajúceho RR nepoznáme. Aj tieto parametre boli následne normalizované do rozmedzia -1 až 1 a pridané do matice PCA .



Obr. 4.10: Príznakový vektor HR a RR-pomer – signal_20130327

Ako vidíme na obr. 4.10 pri nástupe ischemickej fázy sa zníži hodnota HR a zvýši variantnosť RR -pomer, následne v reperfúznej fáze dôjde opačnému dej. Tento jav je ale špecifický pre daný experiment a v klinických štúdiách ischemie sa nevyskytuje. Ďalej si môžeme všimnúť ojedinelé zákmity v neoznačených častiach signálu, tie mohli byť spôsobené chybnou detekciou R-vlny, prípadne výskytom ojedinelých arytmií.

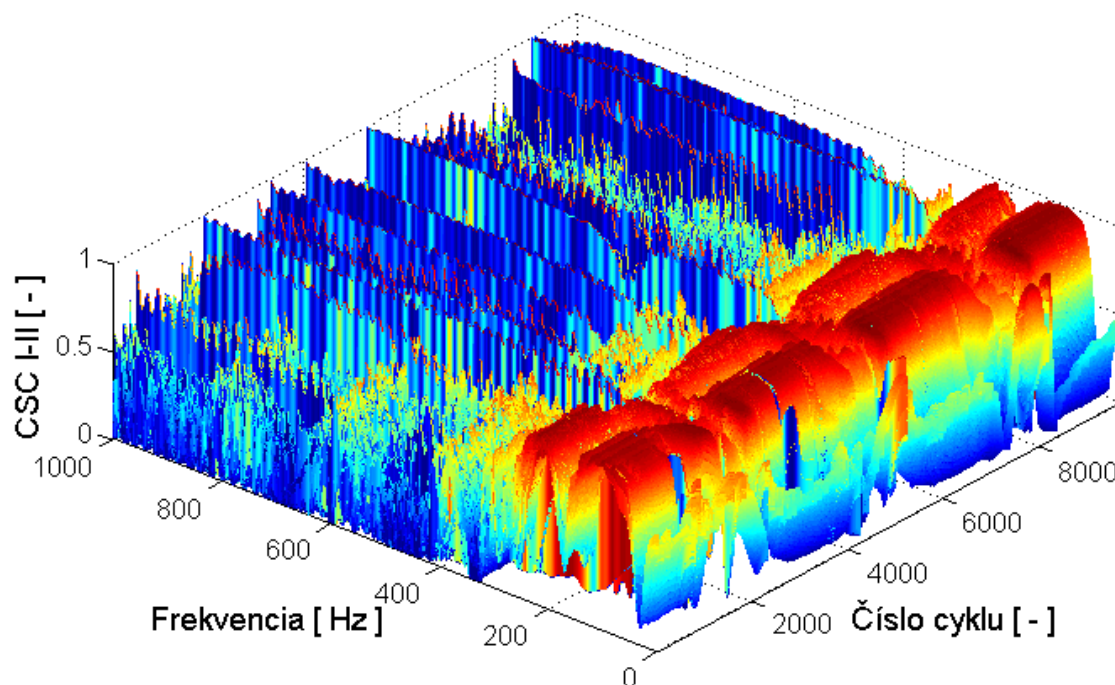
Kombináciou HRV parametrov a PCA bolo vytvorených šesť príznakových matic $mat_PCA_I_20130327$, $mat_PCA_II_20130327$, $mat_PCA_I_20130328$, $mat_PCA_II_20130328$, $mat_PCA_I_20130402$ a $mat_PCA_II_20130402$ uložených vo formáte .mat.

4.2.2 Analýza EG v spektrálnej oblasti

Realizácia analýzy CSC prebehla v programovacom prostredí Matlab, pomocou funkcie *mscohere*, ktorej vstupy sú:

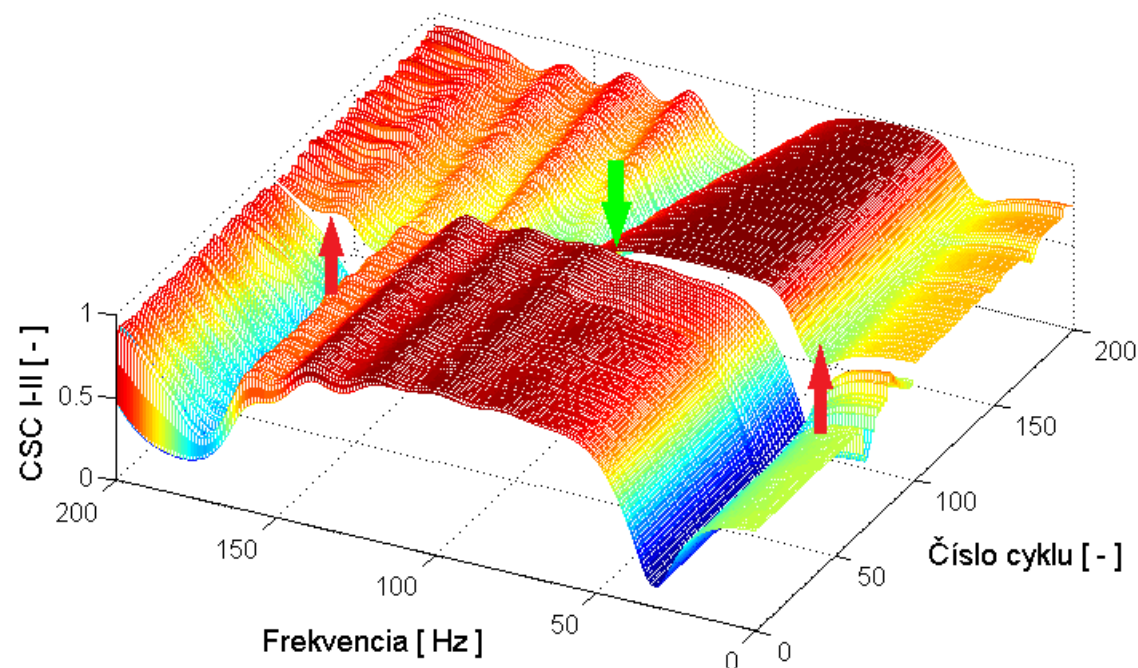
- EG signály zo zvodov I a II uložené v maticovej forme o veľkosti $M \times N$, kde M je počet cyklov daného signálu a N je dĺžka cyklu vo vzorkách,
- typ použitého kľzavého okna pri výpočte spektra vstupných signálov, jeho dĺžka a prekrytie – v našom prípade okno typu *Hamming* s dĺžkou 100 vzoriek a prekrytím 90 vzoriek,
- dĺžka spektra vo vzorkách, ktorá vzhľadom k vzorkovacej frekvencii určuje frekvenčnú citlivosť – u nás 2000 vzoriek,
- vzorkovacia frekvencia f_{vz} – u zvolených signálov 2000Hz dĺžka CSC vektora je potom do $f_{vz}/2$

Výstup tejto funkcie tvorí matica analýzy CSC $CSCI_{II}$ (Obr. 4.11) o veľkosti $1001 \times N$ (berie sa do úvahy aj frekvencia 0Hz) a vektor popisu frekvenčnej osi F o veľkosti 1001 vzoriek. Matica CSC zároveň nadobúda hodnoty v rozmedzí 0 – 1, takže ju nie je potrebné dodatočne normalizovať.



Obr. 4.11: CSC medzi zvodmi I a II – signal_20130327

Pri bližšom pohľade na príznakovú maticu (Obr. 4.12) je vidieť jasné rozdiely medzi ischemickými a neischemickými cyklami (označené na obrázku).



Obr. 4.12: CSC medzi zvodmi I a II 1 až 200Hz: cykly 1 – 100 fáza sc, cykly 101 – 200 fáza i1 – signal_20130327

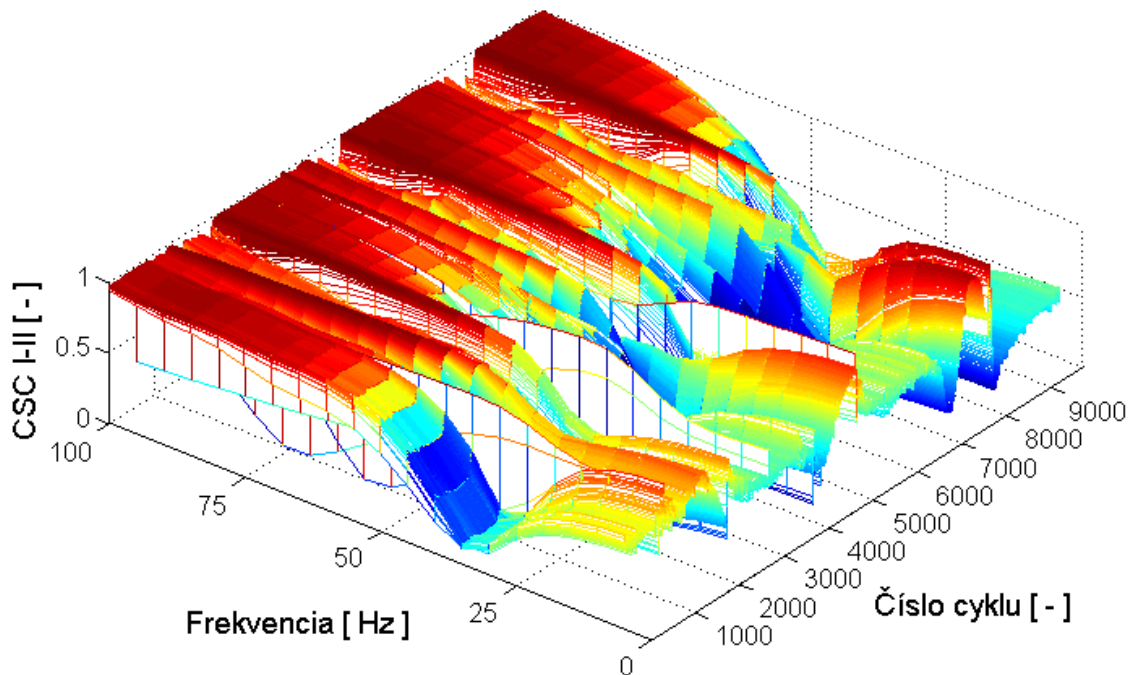
Najčastejšie vyskytujúca sa zmena v matici CSC je nárast vzájomnej koherencie v oblasti nízkych frekvencií (cca 0 až 40 Hz) čo môže byť spôsobené rozšírením vlny T pri ischémii. Ďalšou výraznou zmenou je naklonenie roviny vlny v (v oblasti 100 až 175 Hz).

Výber a úprava matice CSC

Z dôvodu kompresie príznakového vektora (1001 vzoriek) a použitia len užitočných informácií sme zostavenú maticu následne upravili dvoma spôsobmi.

1. Orezanie a podvzorkovanie vo frekvenčnej oblasti

Najjednoduchšou metódou obmedzenia veľkosti vektora je jeho orezanie a podvzorkovanie tak, aby sme nenarušili jeho informačnú hodnotu. Pri tomto prístupe sme najskôr obmedzili frekvenčný rozsah matice CSC len na 1 až 100 Hz a potom sme frekvenčný rozsah podvzorkovali s krokom 5Hz. Výsledkom je upravená matica príznakových vektorov (Obr. 4.13), kde je dĺžka príznakového vektora 20 znakov. Takto zostavená matica je stále dostatočne citlivá hlavne na nárast koherencie v oblasti nízkych frekvencií (viď Obr. 4.11 pre porovnanie).




Obr. 4.13: Upravená matica CSC medzi zvodmi I a II – signal_20130327

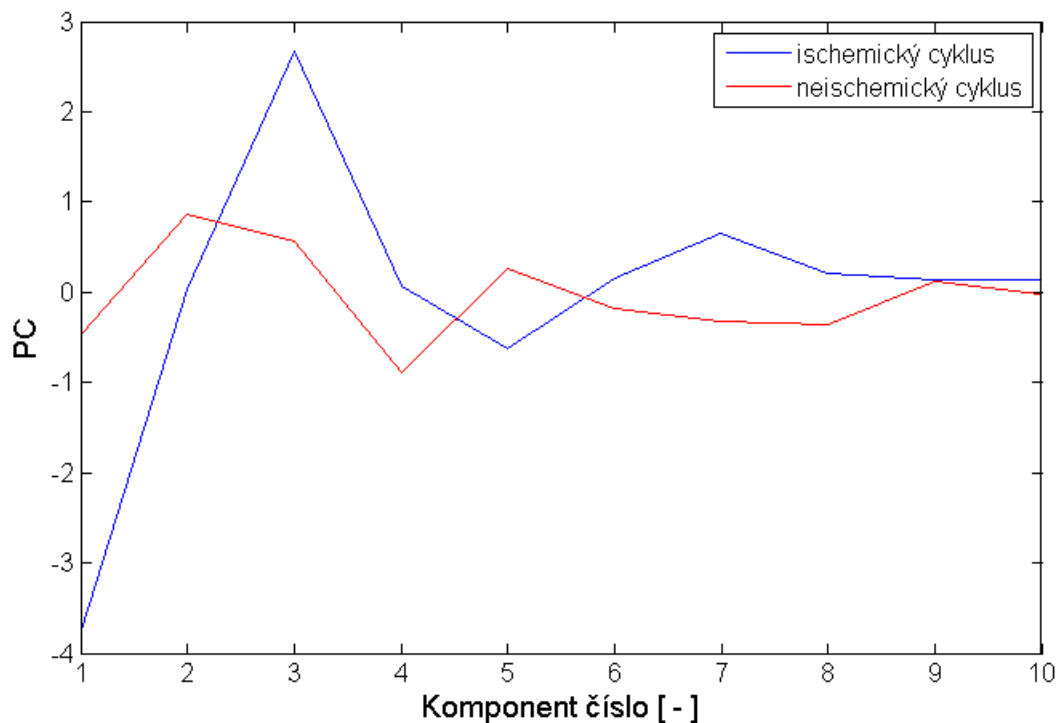
2. Kompresia vo frekvenčnej oblasti pomocou PCA

V druhom prístupe ku kompresii veľkosti matice príznakových vektorov sme využili rovnaký prístup ako v kapitole 4.2.1 s tým rozdielom, že vstupnú maticu CSC bolo potrebné z dôvodu pamäťovej náročnosti zmenšiť na rozsah 0 až 200 Hz a rozdeliť. Aby po rozdelení matice bola zachovaná informačná rovnováha nových matic, rozdelenie prebiehalo na maticu obsahujúcu párne cykly a maticu obsahujúcu nepárne cykly. Preto sa pri signáloch s nepárnym počtom cyklov posledný cyklus zanedbal. Nakoniec boli transformované matice primárnych komponentov znova spojené a vytvorená matica primárnych komponentov analýzy CSC *PCA_CSC* (Obr. 4.14, Obr. 4.15) o veľkosti $K \times N$ (prípadne $N-1$), kde K je počet primárnych komponentov a N je počet srdečných

cyklov. Keďže hodnoty obsiahnuté v matici PCA CSC sa nepohybujú v príliš veľkom rozsahu a nie je potreba ich kombinovať s HRV parametrami, nebola dodatočná normalizácia potrebná.



Obr. 4.14: Matica PCA CSC medzi zvodmi I a II – signal_20130327 s vyznačenými ischemickými fázami



Obr. 4.15: Príznakový vektor PCA CSC medzi zvodmi I a II – signal_20130402

Vyššie uvedeným postupom vzniklo šesť matic *mat_CSC_20130327*, *mat_CSC_20130328*, *mat_CSC_20130402*, *mat_PCA_CSC_20130327*,


mat_PCA_CSC_20130328 a mat_PCA_CSC_20130402 vo formáte .mat.

4.3 Klasifikácia

Pri výbere klasifikačnej metódy bola zvolená klasifikácia pomocou umelej neurónovej siete (ANN). V našom prípade konkrétne použitie viacvrstvej doprednej neurónovej siete so spätným šírením chyby. Na vytvorenie takého typu siete poskytuje Matlab veľmi efektívny prostriedok Neural Network Toolbox, v ktorom je možné ANN nastaviť. Zvolený typ siete funguje na princípe podmieneného učenia. Preto bolo potrebné najskôr vytvoriť tréningovú a testovaciu sadu a jej predpokladaný anotačný výsledok.

4.3.1 Vytvorenie vstupnej sady klasifikátora

K vytvoreniu vstupnej sady bol koncom roka 2011 vytvorený anotačný software (Obr. 4.16) pre medicínsky personál, ktorý mal takúto sadu klasifikovať manuálne, a tým vytvoriť profesionálnu vstupnú sadu, ktorá je pri procese učenia a objektívnom prezentovaní výsledkov potrebná. [27]



Obr. 4.16: Uživateľské rozhranie softwaru na anotáciu srdečných cyklov (prevzaté z [27])


K manuálnej klasifikácii klinickým expertom, zatiaľ nadošlo, preto bol zvolený intuitívny postup pri tvorbe vstupnej sady. Použitý postup spočíval v ručnom výbere cyklov na základe toho, v ktorej fáze experimentu sa nachádzali a na základe posúdenia ich morfológie, pretože u ischemických fáz i1, i2 a i3 sa ešte predpokladá krátky neischemický úsek na počiatku.

Týmto spôsobom bola z troch využívaných signálov vytvorená najskôr testovacia matica obsahujúca:

- neischemické cykly z celej **sc** fázy u všetkých troch signálov – 1013 cyklov **signal_20130327**, 706 cyklov **signal_20130328** a 707 cyklov **signal_20130402**,
- ischemické cykly z vybraných častí fázy **i1**, **i2** a **i3** u všetkých troch signálov – **signal_20130327** fáza **i1** 1289 cyklov (využitie 200 : 1289), **i2** 1313 cyklov (využitie 400 : 1313), **i3** 1372 cyklov (využitie 300 : 1372), **signal_20130378** fáza **i1** 1342 cyklov (využitie 600 : 1342), **i2** 1371 cyklov (využitie 650 : 1371), **i3** 1257 cyklov (využitie 650 : 1257), **signal_20130402** fáza **i1** 1313 cyklov (využitie 600 : 1313), **i2** 1223 cyklov (využitie 500 : 1223), **i3** 1221 cyklov (využitie 600 : 1221),

čím vznikla matica **9636** cyklov kde je na počiatku 2425 neischemických cyklov. K tejto matici bol vytvorený logický anotačný vektor o dĺžke 9636 znakov označujúci neischemické cykly **1** a ischemické cykly **0** (Obr. 4.17, hore).

Následne bola z tejto matice vytvorená tréningová matica 2000 cyklov kde bolo najskôr náhodne vybraných **1000** z 2425 neischemických cyklov a potom **1000** z 7211. Aby nedošlo k zhlukovaniu neischemických a ischemických cyklov do blokov bola celá tréningová matica premiešaná pomocou funkcie *randperm*. Súčasne bol rovnakým spôsobom vytváraný aj tréningový anotačný vektor (Obr. 4.17 dole).



Obr. 4.17: Anotačný vektor testovacej (modrý) a tréningovej (červený) sady

Matice boli vytvorené pre všetky z typov príznakových vektorov a uložené ako štruktúra *TestTrain* vo formáte *.mat*, obsahujúca tréningovú a testovaciu maticu a tréningový a testovací vektor.

4.3.2 Návrh klasifikátora

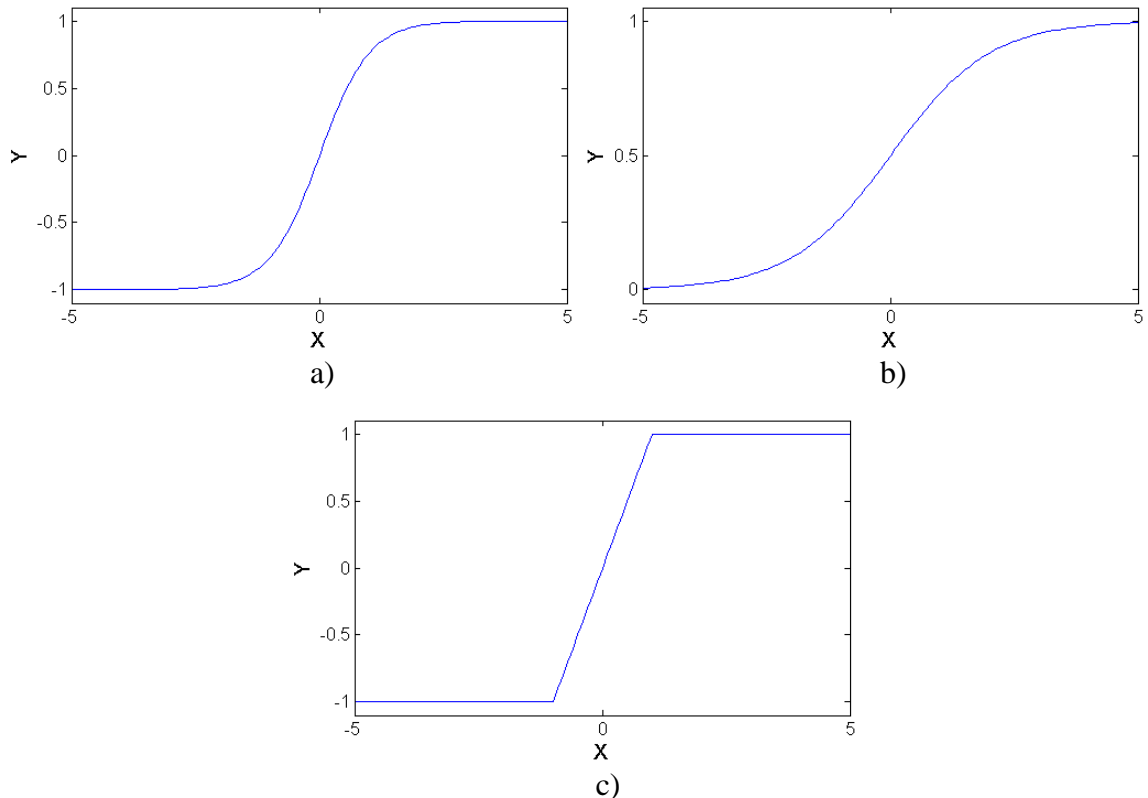
Pri procese učenia klasifikačnej ANN sme využili algoritmus učenia s učiteľom na pripravenej tréningovej matici. Najskôr bolo potrebné ANN zostaviť. K tomuto účelu slúži v Matlabe veľmi efektívna funkcia *newff* v tvare:

```
net = newff(P, T, HiddLay, TransFnc, TrainFnc, LearnFnc, PerfFnc);
```

kde *P* je vstupná príznaková matica, *T* je anotačný vektor, *HiddLay* je vektor počtu neurónov na jednotlivých skrytých vrstvách, *TransFnc* je množina prechodových funkcií na skrytých vrstvách a výstupnej vrstve, *TrainFnc* tréningová funkcia siete, *LearnFnc* je učiacia funkcia váh a prahov jednotlivých neurónov a *PerfFnc* je funkcia výpočtu výkonu siete.

Počet neurónov na jednotlivých vrstvách nejavil veľký vplyv na kvalitu klasifikácie. Z dôvodu lepšej odolnosti a robustnosti siete sme sa rozhodli pre architektúru obsahujúcu 10 neurónov a na prvej skrytej vrstve a 5 neurónov na druhej skrytej vrstve. Veľkosť vstupnej vrstvy je determinovaná dĺžkou príznakového vektora, to iste platí aj pre výstupnú vrstvu a veľkosť anotačného vektora.

Prechodové funkcie (Obr. 4.18) boli na vrstvách nastavené nasledovne. Na prvej skrytej vrstve bola ponechaná pôvodná funkcia tangensová sigmoida (*tansig*), ktorá danému vstupnému vektoru so strednou hodnotou blízkou nule najviac vyhovovala. Na druhej vrstve bola použitá funkcia logická sigmoida (*logsig*), ktorá je menej strmá ako pôvodná (*tansig*) a tým zjemní prechod medzi dvoma klasifikačnými triedami. Na výstupnú vrstvu bola zaradená funkcia lineárna saturovaná (*satlins*), ktorá linearizuje prechod medzi klasifikačnými triedami.

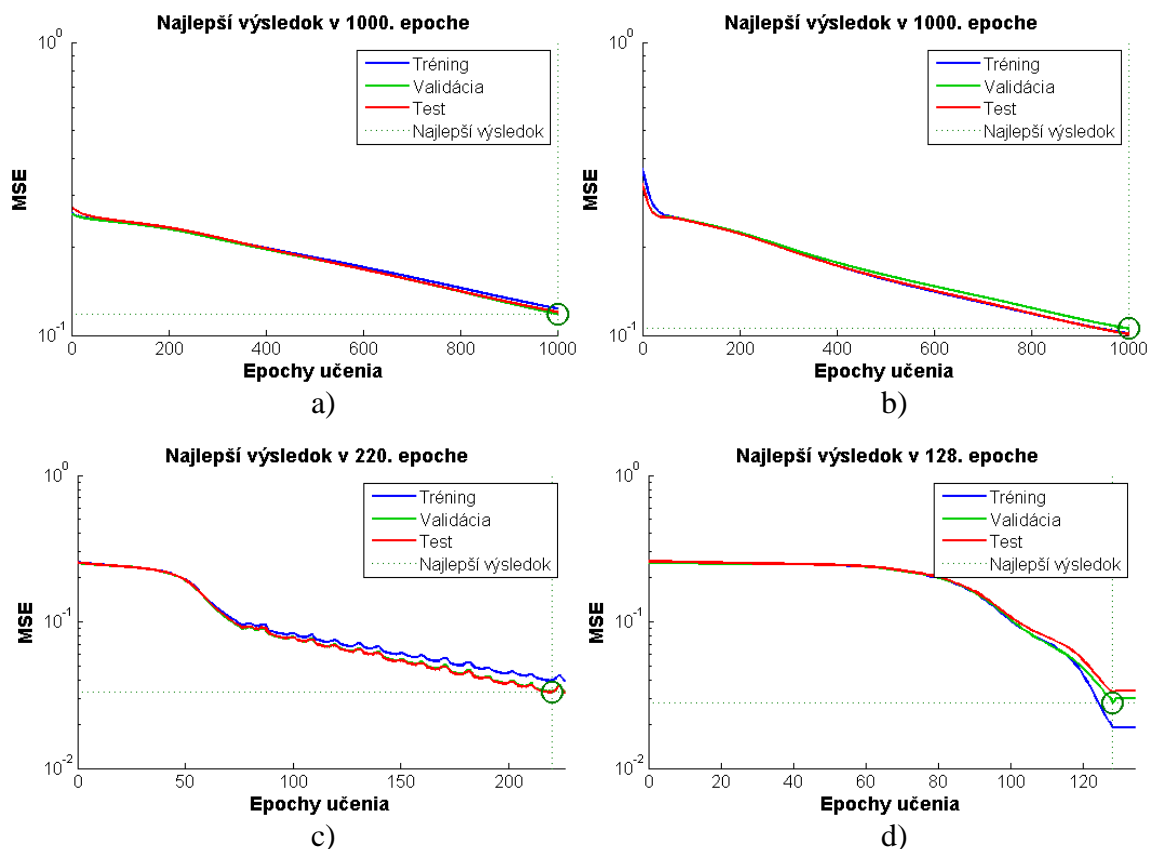


Obr. 4.18: Prechodové funkcie na vrstvách ANN a) tansig, b) logsig, c) satlins

Ako učiacia funkcia siete bola použitá základná metóda *learngd* – gradientný zostup váh a prahov pri procese učenia. Táto funkcia je pomerne často využívaná pri tréningu ANN.

Pre výpočet výkonu siete sme použili metódu *MSE*, ktorá meria výkon siete v závislosti na strednej kvadratickej chybe.

Pri výbere tréningovej funkcie sme testovali štyri prístupy (Obr. 4.19). Najjednoduchší z nich je funkcia *traingd* – funkcia, ktorá mení hodnoty váh a prahov na základe gradientného zostupu. Mierne pokročilejší prístup je pri funkcii *traingdm*, ktorá využíva gradientného zostupu s hybnosťou. Oba tieto funkcie vždy využijú maximálny počet epoch učenia, a preto môže dôjsť veľmi jednoducho k preučeniu siete. Pokročilejšie metódy, ktoré by mali tento problém odstrániť sú adaptívne metódy tréningovania, ktoré samy zastavia tréningovanie tak, aby nedošlo k preučeniu siete. V našom prípade sme testovali dve adaptívne metódy a to *traingda* – využívajúca gradientný zostup s adaptívnou rýchlosťou učenia a *traingdx* – využívajúca gradientného zostupu s hybnosťou a adaptívnou rýchlosťou učenia. Vo finálnych sieťach sme sa na základe testov rozhodli pre metódu *traingdx*.



Obr. 4.19: Tréningové funkcie a) *traingd*, b) *traingdm*, c) *traingda*, d) *traingdx*

Ako je možné vidieť na Obr. 4.19 tréningový algoritmus siete si sám rozdelí vstupnú tréningovú množinu na vlastnú tréningovú, testovaciu a validačnú v pomere 60%, 20% a 20%. To slúži práve k tomu, aby sa už behom tréningovania siete overovala jej funkcia podobným výsledkom vo všetkých množinách. Okrem toho u adaptívnych metód toto rozdelenie zabezpečuje zastavenie tréningovania siete pred pretrénovaním. Na hodnotenie

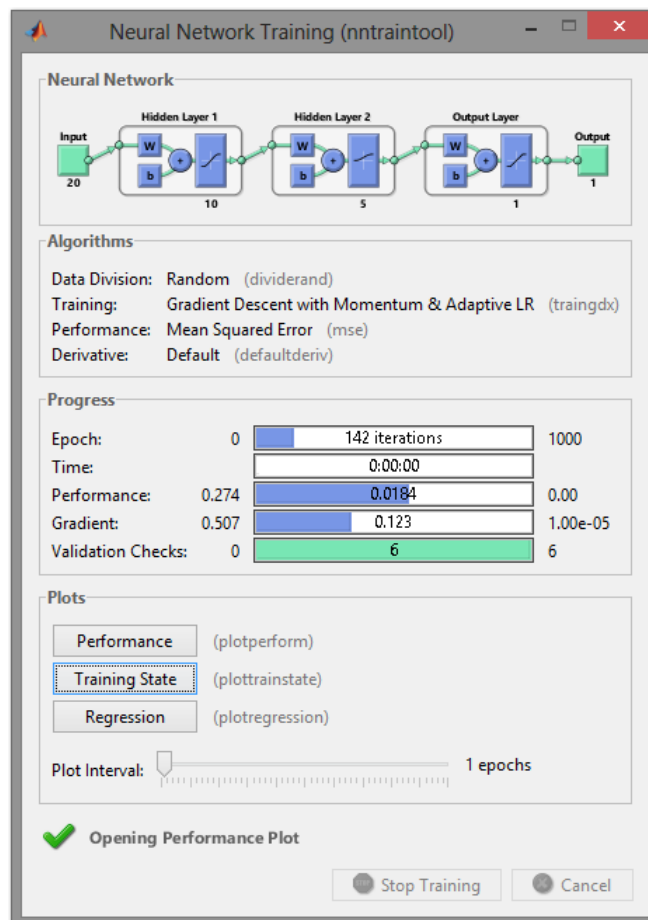
výsledného MSE potom slúži výsledok z validačnej množiny. Pri bližšom pohľade je vidieť, že najrýchlejšia je metóda *traingdx* a dosahuje aj najnižšej hodnoty *MSE*.

Po procese zostavenia siete nasleduje jej inicializácia. K nastaveniu inicializácie v Matlabe slúžia tieto parametre:

- *net.initFcn* nastavenie inicializačnej funkcie siete, *initlay* nastaví túto funkciu na inicializáciu vrstvy po vrstve,
- *net.layers{1}.initFcn* inicializácia vrstiev siete, *initwb* nastaví inicializáciu podľa váh a prahov,
- *net.biases{1,1}.initFcn* inicializácia prahov, *initzero* nastaví inicilaizačnú hodnotu na nulu,
- *net.inputWeights{1}.initFcn* inicializácia váh vstupnej vrstvy, *initzero* nastaví inicilaizačnú hodnotu na nulu,
- *net.layerWeights{1}.initFcn* inicializácia váh prvej vrstvy, *initzero* nastaví inicilaizačnú hodnotu na nulu – podobne pre druhú vrstvu,

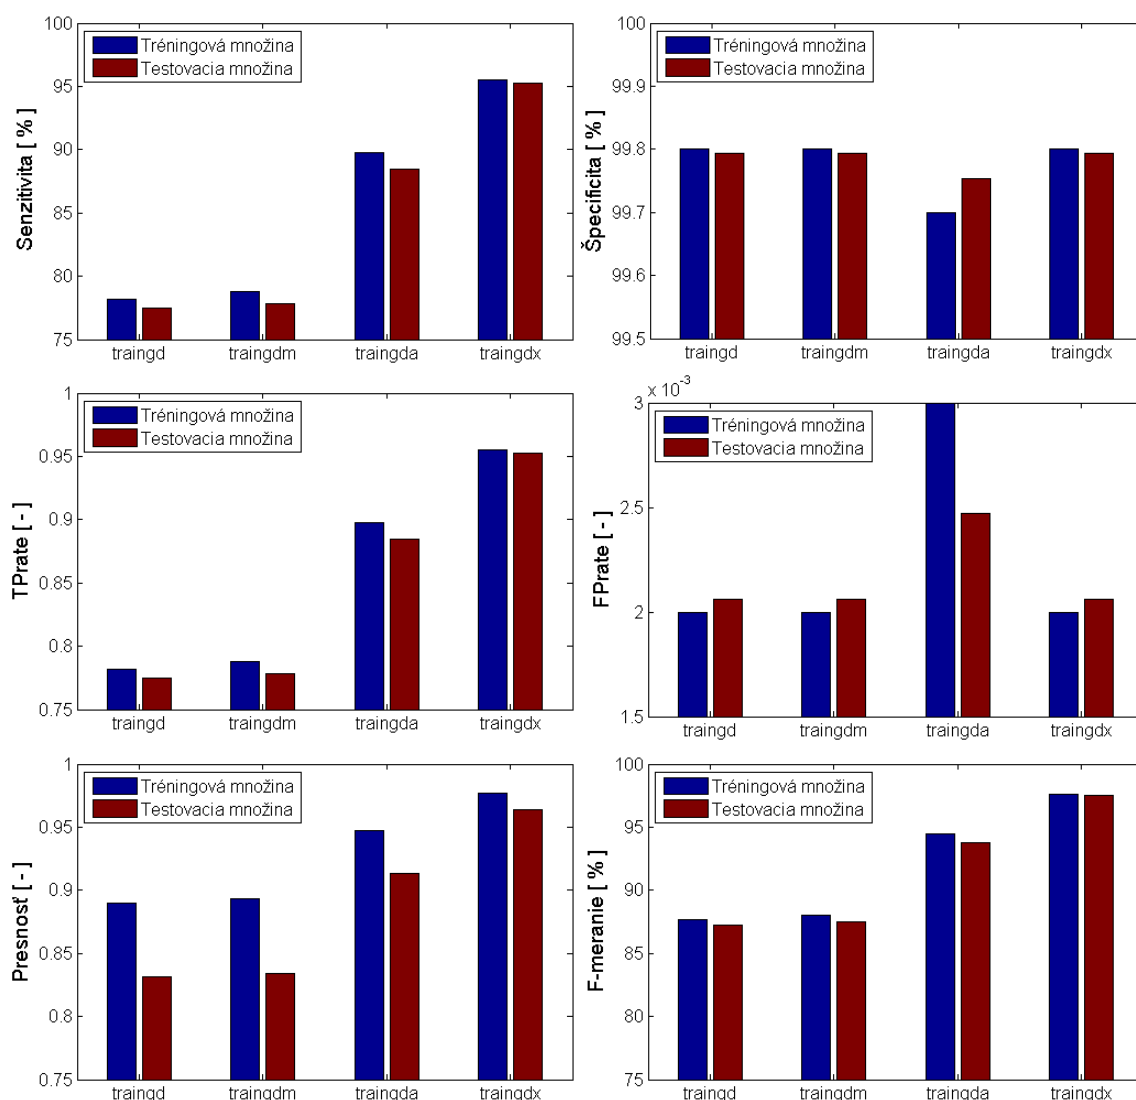
takúto sieť inicializujeme pomocou funkcie *init*.

Pri samotnom tréovaní siete (Obr. 4.20) ako prvé nastavíme pomocou parametru *net.trainParam.epochs* maximálny počet epoch učenia. V našom prípade bola táto hodnota pevne nastavená na *1000*. Samotný proces tréovania spustíme príkazom *train*, ktorého vstupom je nastavenie siete *net*, vstupná matica príznakov *P* a anotačný vektor *T*. Výstup tvorí nová natréovaná sieť *net*.



Obr. 4.20: Grafické zobrazenie priebehu tréovania siete v Neural Network Tollbox

Po procese tréningovania sme pristúpili k testovaniu samotnej siete. To je možné pomocou funkcie *sim*, ktorej vstupom je príznaková testovacia matica a sieť a výstup tvorí anotačný vektor T_2 , ten najskôr zaokrúhlime do najbližších hodnôt a potom porovnáme s predpokladaným výstupom T . Úspešnosť klasifikácie sme overovali na základe parametrov *senzitivita*, *špecificita*, TP_{rate} , FP_{rate} , *presnosť* a *F-meranie* (vid'. kapitola 3.3.3) a to ako na tréningovej, tak na testovacej množine. Tieto testy boli vyhotovené na porovnanie jednotlivých tréningových funkcií (Obr. 4.21) ako aj rôznych prístupov k tvorbe príznakového vektora, a tým aj siete (Tabuľka 4.1).



Obr. 4.21: Testovanie tréningových funkcií siete s príznakovým vektorom CSC

Na Obr. 4.21 si môžeme všimnúť, že najlepších výsledkov dosahuje tréningová metóda *traingdx* a to nie len pri využití príznakového vektora analýzy CSC, ktorý slúži ako prehľadná ukážka. Všetky výsledky testovania sú zhrnuté v tabuľke 4.1.


Tabuľka 4.1: Výsledky hodnotenia všetkých typov klasifikačných algoritmov

Množina	Priznakový vektor	Zvod	Trén. metóda	Senzitivita	Špecificita	TP _{rate}	FP _{rate}	Presnosť	F-meranie
				[%]	[%]	[-]	[-]	[-]	[%]
Tréningová	PCA	I	traingd	76,5	99,8	0,765	0,002	0,882	86,6
			traingdm	77,2	99,7	0,772	0,003	0,885	87,0
			traingda	83,4	95,4	0,834	0,046	0,894	89,0
			traingdx	97,2	98,9	0,972	0,011	0,981	98,0
		II	traingd	68,7	81,0	0,687	0,190	0,749	74,3
			traingdm	68,3	81,0	0,683	0,190	0,747	74,1
			traingda	77,7	86,7	0,777	0,133	0,822	82,0
			traingdx	89,1	84,7	0,891	0,153	0,869	86,8
	PCA+ HRV	I	traingd	82,9	100	0,829	0	0,915	90,7
			traingdm	84,2	100	0,842	0	0,921	91,4
			traingda	99,9	100	0,999	0	0,999	99,9
			traingdx	100	100	1	0	1	100
		II	traingd	92,2	94,9	0,922	0,051	0,936	93,5
			traingdm	91,0	96,4	0,910	0,036	0,937	93,6
			traingda	99,9	100	0,999	0	1	100
			traingdx	99,9	100	0,999	0	1	100
	CSC	I-II	traingd	78,2	99,8	0,782	0,002	0,890	87,7
			traingdm	78,8	99,8	0,788	0,002	0,893	88,1
			traingda	89,8	99,7	0,898	0,003	0,948	94,5
			traingdx	95,5	99,8	0,955	0,002	0,977	97,6
PCA-CSC	I-II	traingd	82,1	89,4	0,821	0,106	0,858	85,6	
		traingdm	80,6	89,7	0,806	0,103	0,852	84,9	
		traingda	98,9	99,3	0,989	0,007	0,991	99,1	
		traingdx	99,7	99,5	0,997	0,005	0,996	99,6	
Testovacia	PCA	I	traingd	76,6	99,7	0,766	0,003	0,824	86,6
			traingdm	77,7	99,7	0,777	0,003	0,832	87,3
			traingda	84,2	95,2	0,842	0,048	0,870	89,3
			traingdx	97,1	98,4	0,971	0,016	0,974	97,7
		II	traingd	70,3	80,4	0,703	0,196	0,728	75,0
			traingdm	69,6	80,7	0,695	0,193	0,724	74,7
			traingda	80,0	86,5	0,800	0,135	0,816	83,1
			traingdx	89,3	85,2	0,893	0,148	0,883	87,2
	PCA+ HRV	I	traingd	83,0	100	0,830	4,12e-4	0,873	90,7
			traingdm	84,4	100	0,844	4,12e-4	0,883	91,5
			traingda	99,8	99,8	0,998	1,60e-3	0,998	99,8
			traingdx	100	99,8	1	1,60e-3	1	99,9
		II	traingd	92,9	94,9	0,929	0,051	0,934	93,9
			traingdm	91,7	96,2	0,917	0,038	0,928	93,9
			traingda	99,9	100	0,999	0	0,999	99,9
			traingdx	99,8	100	0,998	0	0,999	99,9
	CSC	I-II	traingd	77,5	99,8	0,775	0,002	0,831	87,2
			traingdm	77,8	99,8	0,778	0,002	0,833	87,5
			traingda	88,5	99,8	0,884	0,003	0,913	93,8
			traingdx	95,3	99,8	0,953	0,002	0,964	97,5
PCA-CSC	I-II	traingd	81,8	89,6	0,818	0,104	0,838	85,5	
		traingdm	80,8	90,0	0,809	0,100	0,832	85,2	
		traingda	98,3	98,9	0,983	0,011	0,985	98,6	
		traingdx	99,0	99,0	0,990	0,010	0,990	99,0	

4.3.3 Diskusia výsledkov klasifikácie

Zo zrovnania výsledkov dosiahnutých pri klasifikácii (hlavne parametru F-meranie) rôznymi metódami (viď. Tabuľka 4.1) vyplýva, že najlepší výsledok dosiahla metóda kombinovaného príznakového vektora PCA s HRV príznakmi pri tréningovej funkcii *trainidx* a to až 100%. Túto úspešnosť môžeme prisúdiť práve pozitívym HRV príznakom, ktoré počas experimentu výrazne kolíšu. Keďže tento jav nie je pri ischemii obvyklý, táto metóda je vhodná skôr na lokálne použitie pri konkrétnom experimente. Pri porovnaní ostatných výsledkov dosahujú všetky metódy, s výnimkou PCA príznakového vektora zo zvodu II, zrovnateľné výsledky v rozmedzí 97,5 až 99,6 % (F-meranie). Menšiu úspešnosť klasifikácie u vektora PCA zvodu II je možné pričítať nedostupnosti odborne zostavenej tréningovej množiny alebo samotnej morfológii signálu tohto zvodu, z ktorej daný príznakový vektor vychádza. K tomu sa prikláňa aj fakt, že hodnoty dosahované na tréningovej a testovacej množine sú zrovnateľné a teda k preučeniu alebo zlému zostaveniu množiny pravdepodobne nedošlo.

Pri ďalšom testovaní vytvorených klasifikátorov na reálnych signáloch tvorených celými fázami experimentu, bolo zistený pokles efektivity všetkých metód s výnimkou metódy s príznakovým vektorom CSC (Obr. 4.22) a PCA s prídavnými príznakmi HRV. Tento pokles môžeme pričítať neodborne zostavenej tréningovej množine, prípadne pretrénovaním siete aj napriek použitiu adaptívnych tréningových funkcií.



Obr. 4.22: Odozva siete na ischemickú fázu i1 signal_20130402 – elipsa označuje miesto hysterézie

Bližším pohľadom na anotačný výstup siete využívajúcej CSC príznakový vektor zistíme miernu hysteréziu medzi 1 a 0. Tá je pravdepodobne spôsobená intuitívnym zostavením tréningovej sady, ktorá tým pádom nemusí obsahovať presnú hranicu prechodu medzi ischemickým a neischemickým cyklom. Výskyt neischemických cyklov na počiatku ischemickej fázy (prvých 470 cyklov) je predpokladaný, a preto sa dá považovať táto odozva za správnu.

5 ZÁVER

Diplomová práca sa venuje experimentálnym metódam detekcie srdečnej ischémie na animálnom EG, získanom meraním na extrahovanom srdci kráľika. Úvod práce tvorí teoretický popis signálu EKG a jeho patologických prejavov, nasleduje popis jednotlivých etáp procesu klasifikácie a ich stručný prehľad. Hlavná časť práce je praktický výskum použiteľnosti príznakových vektorov analýzy vzájomnej koherencie spektier (CSC), analýzy primárnych komponentov (PCA) a analýzy variability srdečného rytmu (HRV) na problematiku ischemických prejavov v kombinácii s klasifikáciou pomocou umelej neurónovej siete. Práca je priebežne dokumentovaná výsledkami daných častí.

Celkovo boli využité štyri prístupy ku klasifikácii ischémie v EG signáli. Prvým s prístupov je využitie analýzy primárnych komponentov na kompresiu morfológie jednotlivých cyklov signálu EG. Pri tomto prístupe bolo dosiahnutých zaujímavých výsledkov v znížení dátovej náročnosti vstupného vektoru na klasifikátor, ako aj odolnosti tejto metódy prípadne artefakty v signáli. Ďalším prieskumom tejto by podľa môjho názoru mohla byť aplikovaná.

Druhým prístupom bola kombinácia využitia analýzy primárnych komponentov a dvoch príznakov analýzy variability srdečného rytmu. Aj táto metóda vykazovala dobré klasifikačné výsledky. Pre daný experiment merania ischémie na izolovanom srdci je však typická srdečná arytmia v jeho priebehu, preto využitie tejto metódy vidím skôr na lokálnu problematiku daného experimentu.

Najľubnejším z prístupov je tretí, a teda využitie vzájomnej koherencie spektier dvoch zvodov. Táto metóda vzhľadom na jej výpočet v spektrálnej oblasti vykazuje veľkú odolnosť voči šumu, ktorý je často problém pri klasifikáciách založených na morfológii. Taktiež je tu možné dosiahnuť úsporu dátového priestoru tým, že signál z dvoch zvodov je nahradený jednorozmerným signálom, ktorý si aj po jeho podvzorkovaní a orezaní zachová informačnú hodnotu. Preto si myslím, že po ďalšom testovaní a zdokonalení kompresie je možné túto metódu úspešne aplikovať.

Posledným z testovaných prístupov bola kompresia vektoru vzájomnej koherencie spektier pomocou analýzy primárnych komponentov. Táto metóda taktiež dosiahla dobrých výsledkov, ako v oblasti klasifikačnej, tak v oblasti kompresnej. Na jej ďalšie využitie je podľa môjho názoru ešte potrebné túto metódu zdokonaľiť.

Celkový prínos tejto práce vidím hlavne v preskúmaní doteraz nevyužívaných alebo len málo využívaných metód tvorby príznakového vektoru. Ich klasifikačné výsledky sú totiž v kombinácii s umelou neurónovou sieťou nezanedbateľné. Prípadný pokrok v tejto oblasti vidím hlavne v testovaní a trénovaní algoritmov na klinicky klasifikovaných dátach. Ďalšou možnosťou zlepšenia je využitie algoritmu pomocných vektorov (SVM), tá je dnes často používaná a vykazuje dobré výsledky v oblasti klasifikácie. Z testovaných metód má najväčší potenciál práve analýza vzájomnej koherencie spektier, ktorej aplikácia vôbec nie je náročná a aj napriek tomu dosahuje dobré výsledky.

LITERATÚRA

- [1] SÖRNMO, L., LAGUNA, P.: *Bioelectrical signal Processing in cardiac and neurological applications*, Academic Press Series in Biomedical Engineering, Elsevier, Amsterdam, 2005, 688 s.
- [2] KOZUMPLÍK, J.: *Analýza biologických signálů [online]*, [cit. 2012-5-1], Dostupné z: <<http://www.dbme.feec.vutbr.cz/>>
- [3] CLIFFORD, G. D., AZUAJE, F., MCSHARRY, P. E.: *Advanced Methods and Tools for ECG Data Analysis*, Artech House Publishing, Boston/London, 2006, 384 s.
- [4] POOYAN, M., TAHERI, A., MOAZMI-GOUDARZI, M., SABOORI, I.: *Wavelet Compression of ECG Signals Using SPIHT Algorithm*, World Academy of Science, Engineering and Technology 2, 2005, 4 s.
- [5] ZIGEL, Y., COHEN, A., KATZ, A.: *ECG Signal Compression Using Analysis by Synthesis Coding*, IEEE Transaction on Biomedical Engineering, Vol. 47, No. 10, 2000, 9 s.
- [6] CASTELLS, F., LAGUNA, P., SÖRNMO, L., BOLLMANN, A., ROIG, J., M.: *Principal Component Analysis in ECG Signal Processing*, EURASIP Journal on Advances in Signal Processing, Volume 2007, 2006, 21 s.
- [7] 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.
- [8] MENOWN, I. B. A., ADGEY, A. A. J.: *Improving the ECG classification of inferior and lateral myocardial infarction by inversion of lead aVR*, Heart, 83(6), 2000, 4 s.
- [9] MAHMOODABADI, S. Z., AHMADIAN, A., ABOLHASANI, M. D., ESLAMI, M., BIDGOLI, J. H.: *ECG Feature Extraction Based on Multiresolution Wavelet Transform*, Engineering in Medicine and Biology Society, 2005, 4 s.
- [10] CVETKOVIC, D., ŮBEYLI, D. E., COSIC, I.: *Wavelet transform feature extraction from human PPG, ECG, and EEG signal responses to ELF PEMF exposures: A pilot study*, Digital Signal Processing 18, 2008, 14 s.
- [11] ZHAO, Q., ZHANG, L.: *ECG Feature and Classification Using Wavelet Transform and Support Vector Machine*, Neural Networks and Brain, 2005, 3 s.
- [12] 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.
- [13] CASTELLS, F., LAGUNA, P., SÖRNMO, L., BOLLMANN, A., ROIG, J., M.: *Principal component analysis in ECG signal processing*, EURASIP Journal on Applied Signal Processing, 2007, 21 s.
- [14] FIRA, C., M., GORAS, L.: *An ECG Signals Compression and Its Validation Using NNs*, IEEE Transactions on Biomedical Engineering, 2008, 8s.
- [15] RICHARDSON, M.: *Principal component analysis*, [cit. 2013-5-3], University of Oxford, 2009, URL: <http://people.maths.ox.ac.uk/richardsonm/SignalProcPCA.pdf>
- [16] JAN, J.: *Číslicová filtrace, analýza a restaurace signálů*, VUTIUM, Brno, 2002, 427 s.
- [17] NAZMY, T. M., EL-MESSIRY, H., AL-BOKHITY, B.: *Adaptive Neuro-Fuzzy Interface System for Classification of ECG Signals*, Journal of Theoretical and Applied Information Technology, 2005-2009, 6 s.
- [18] HUSAIN, H., FATT, L. L.: *Efficient ECG Signal Classification Using Sparsely Connected Radial Basis Function Neural Network*, 6th WSEAS International Conference on Circuits,

- Systems, Electronics, Control & Signal Processing, Egypt, 2007, 5 s.
- [19] MELGANI, F., BAZI, Y.: *Classification of Electrocardiogram Signals With Support Vector Machines and Particle Swarm Optimization*, IEEE Transaction on Biomedical Engineering Technology in Biomedicine, Vol. 12, No. 5, 2008, 11 s.
- [20] POLAT, K., GÜNEŞ, S.: *Detection of ECG Arrhythmia using differential expert system approach based on principal component analysis and least square support vector machine*, Applied Mathematics and Computation 186, 2007, 9s.
- [21] MANOCHA, A. K., MANDEEP S.: *An Overview of Ischemia Detection Technique*, International Journal of Scientific & Engineering Research, 2011, 5 s.
- [22] KOLÁŘOVÁ, J., FIALOVÁ, K., JANOUŠEK, O., NOVÁKOVÁ, M., PROVAZNÍK, I.: *Experimental Methods for Simultaneous Measurement of Action Potentials and Electrograms in Isolated Heart*, Physiol. Res. 59 (Suppl. 1), 2010, 10 s.
- [23] 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.
- [24] KOLÁŘOVÁ, J., JANOUŠEK, RONZHINA, M., PROVAZNÍK, I., NOVÁKOVÁ, M.: *Effects of voltage-sensitive dye di-4-ANEPPS on isolated rat heart electrogram*, Computing in Cardiology, 2011, 4 s.
- [25] BARDŇOVÁ, J., PROVAZNÍK, I., NOVÁKOVÁ, M., BLAHA M.: *Analysis of Voltage-Sensitive Dye Influence on ECG Segment Variability*, Computers in Cardiology, 2006, 4 s.
- [26] JANOUŠEK, O., KOLÁŘOVÁ, J., NOVÁKOVÁ, M., PROVAZNÍK, I.: *Three-Dimensional Electrogram in Spherical Coordinates: Application to Ischemia Analysis*, Physiol. Res. 59 (Suppl. 1), 2010, 8 s.
- [27] RONZHINA, M., POTOČŇÁK, T., KOLÁŘOVÁ, J., PROVAZNÍK, I.: *ANEG; Software for annotation of heart beats ANEG*, Ústav biomedicínského inženýrství, FEKT VUT v Brně, Kolejní 4 61200 Brno, URL: <http://www.ubmi.feec.vutbr.cz/vyzkum-a-vyvoj/> produkty. (software) <http://www.ubmi.feec.vutbr.cz/vyzkum-a-vyvoj/> produkty

ZOZNAM SKRATIEK

AF	Atrial Fibrillation, fibrilácia siení
AFL	Atrial Flutter, kmitanie srdečných siení
ANFIS	Adaptive Neuro Fuzzy Inference System, hybridná fuzzy sieť
ANN	Artificial Neural Network, umelá neurónová sieť
APC	Atrial Premature Contraction, predčasný sťah siení
ASEC	Analysis by Synthesis ECG Compressor, algoritmus kompresie na princípe analýzy syntézy kódovania
AV	atrioventricular, atrioventrikulárny (uzol)
CSC	Cross Spectral Coherence, vzájomná koherencia spektier
EG	elektrogram
EKG	elektrokardiografia
EMC	elektromagnetické pole
EMG	elektromyografia
HRV	Heart Rate Variability, variabilita srdečného rytmu
KLT	Karhunen-Loeve Transform, Karhunen-Loeveho transformácia
MAP	monofázické akčné potenciály srdca
MLP	Multilayer Perceptron, viacvrstvý perceptron
PCA	Principal Component Analysis, analýza primárnych komponentov
PSD	Power Spectral Density, výkonové spektrum
RBFNN	Radial Basis Function Neural Network, neurónová sieť s radiálnou bázou
RSA	Respiratory Sinus Arrhythmia, respiračná arytmia
SA	sinoatrial, sinoatriálny (uzol)
SNR	signal-to-noise ratio, pomer signál-šum
SPIHT	Set Partitioning in Hierarchical Trees, kompresný algoritmus založený na vlnkovej transformácii
SVD	Singular Value Decomposition, singulárny rozklad
SVM	Support Vector Machine, algoritmus podporných vektorov
VF	Ventricular Fibrillation, fibrilácia komôr
VFL	Ventricular Flutter, kmitanie srdečných komôr
VPC	Ventricular Premature Contraction, predčasný sťah komôr
VT	Ventricular Tachycardia, tachykardia komôr
WFDB	WaveForm DataBase, databáza vlnení
WT	Wavelet Transform, vlnková transformácia

ZOZNAM PRÍLOH

- A. CD
 - A.1. Algoritmy/
 - A.1.1. Funkcie/
 - A.1.2. Výstupné ANN/
 - A.1.3. README.txt
 - A.2. Vstupné signály/
 - A.3. Elektronická verzia diplomovej práce/