

TECHNICKÁ UNIVERZITA V LIBERCI

Fakulta mechatroniky a mezioborových inženýrských studií

Aplikace metod pro slepou separaci dat ve zpracování EKG záznamů

Diplomová práce

Vedoucí práce:

Ing. Zbyněk Koldovský, Ph.D.

Filip Žížka

Liberec 2007

Originální zadání práce

Je mou příjemnou povinností poděkovat na tomto místě vedoucímu této diplomové práce panu Zbyňku Koldovskému, za jeho bezmeznou trpělivost a ochotu. Nesmím zapomenout poděkovat také za podporu, které se mi dostávalo ze strany rodiny po celou dobu studia. V neposlední řadě děkuji mé přítelkyni, která mě k práci motivovala a spolupracovala se mnou při experimentech.

Prohlášení

Byl(a) jsem seznámen(a) s tím, že na mou diplomovou práci se plně vztahuje zákon č. 121/2000 o právu autorském, zejména § 60 (školní dílo).

Beru na vědomí, že TUL má právo na uzavření licenční smlouvy o užití mé DP a prohlašuji, že **s o u h l a s í m** s případným užitím mé diplomové práce (prodej, zapůjčení apod.).

Jsem si vědom(a) toho, že užít své diplomové práce či poskytnout licenci k jejímu využití mohu jen se souhlasem TUL, která má právo ode mne požadovat přiměřený příspěvek na úhradu nákladů, vynaložených univerzitou na vytvoření díla (až do jejich skutečné výše).

Diplomovou práci jsem vypracoval(a) samostatně s použitím uvedené literatury a na základě konzultací s vedoucím diplomové práce a konzultantem.

Datum

Podpis

Abstract

Žižka, F. Application of methods for Blind Source Separation in ECG data processing. Diploma thesis. Liberec, 2007

The thesis briefly informs about the origin of ECG signals, about possibilities and ways how they can be acquired, but it mainly focuses on working with already imported ECG data into the Matlab environment. The thesis suggests a way on how to import and visualize the measured data, and also how to preprocess the data before the application of algorithms for the blind separation. Next, the thesis provides an introduction to the Blind Source Separation (BSS) and a survey of BSS methods (EFICA, WASOBI, MULTICOMBI), that are applied to real ECG data. The main goal is to refer to the application of methods for blind separation when applying to real ECG records. The tasks described in the thesis, e.g. tremble removing, may be very useful for practice in medicine.

Abstrakt

Žižka, F. Aplikace metod pro slepou separaci dat ve zpracování EKG záznamů. Diplomová práce. Liberec, 2007

Diplomová práce stručně informuje o vzniku EKG, o možnostech a způsobu jeho pořízení, ale hlavně se zaměřuje na práci s již importovanými EKG daty do prostředí Matlabu. DP navrhuje způsob, jakým naměřená data importovat, zobrazovat a jak je předzpracovat před samotnou aplikací algoritmů pro slepou separaci dat. Dále je obsažen úvod do slepé separace signálů (BSS) a přehled BSS metod (EFICA, WASOBI, MULTICOMBI), které jsou aplikovány na konkrétní EKG data. Hlavním cílem je poukázat na využití metod pro slepou separaci při aplikaci na reálné EKG záznamy. Úlohy popsané v DP jako např. odstranění třesu, mohou být užitečné pro lékařskou praxi.

Obsah

1	Slovník znaků, symbolů, zkratk, akronymů, jednotek, termínů	8
2	Úvod	9
3	Seznámení se základními vlastnostmi EKG záznamů	11
3.1	Vznik a průběh EKG záznamu	11
3.2	Normální vs poruchové EKG	13
3.2.1	Popis křivky normálního EKG	13
3.2.2	Poruchové EKG	14
4	Slepá separace signálů	16
4.1	Přehled BSS metod	17
4.1.1	ICA	17
4.1.2	SOS BSS algoritmy	18
4.1.3	Hybridní algoritmy	18
4.2	Použití algoritmů BSS v Matlabu	19
4.2.1	EFICA	19
4.2.2	WASOBI	19
4.2.3	MULTICOMBI	20
5	Manipulace s EKG daty v Matlabu	21
5.1	Import dat, vizualizace	21
5.2	Předzpracování dat	23
6	Aplikace algoritmů pro slepou separaci dat	25
6.1	Symbolický zápis aplikace algoritmů pro BSS	26
6.2	Uměle vytvořená data	27
6.3	Zjištění nežádoucích komponent na základě rozložení energie mixovací matice	29

6.4	Odstraňování šumu z reálných EKG záznamů	30
6.4.1	Filtr vs BSS	33
6.5	Odstraňování třesu z reálných EKG záznamů	34
6.5.1	Pokus první - třes horních končetin	35
6.5.2	Pokus druhý - třes všech končetin	39
6.5.3	Pokus třetí - zatínání svalů	42
6.6	Problémy aplikace algoritmů pro BSS na reálné EKG záznamy	46
7	Závěr	47
8	Reference	48
	Přílohy	49
A	Funkce import_EKG_dat	50
B	Funkce zobraz	51
C	Funkce filtr_isolinie	52
D	Funkce DPfiltr	53

1 Slovník znaků, symbolů, zkratk, akronymů, jednotek, termínů

Slovo	Popis
elektrokardiografie	lékařská vyšetřovací metoda zachycující a zaznamenávající akční elektrické srdeční potenciály z různých míst povrchu těla
elektrokardiograf	přístroj, který elektrickou aktivitu srdce zaznamenává
elektrokardiogram	záznam elektrické srdeční činnosti v závislosti na čase
EKG	elektrokardiograf, elektrokardiogram
BSS	Blind Source Separation - Slepá separace signálů
ICA	Independent Component Analysis - Analýza nezávislých komponent
A	matice
x	vektor
isolinie	vodorovná čára, kterou zapisuje elektrokardiograf běžící naprázdno nebo v době mezi jednotlivými srdečními revolucemi
drift isolinie	jev, kdy data opisují jinou křivku, než je isolinie

2 Úvod

Je to již více než 100 let, co holandský fyziolog Willem Einthoven (1860-1927) položil základy elektrokardiografie a umožnil tak zkoumání srdeční činnosti. S vývojem techniky se jeho strunový galvanometr změnil na drobný přístroj s dotykovým displejem, jehož ovládání zvládne i proškolená zdravotní sestra, tedy člověk bez technického i vyššího lékařského vzdělání. Úloha lékaře je však stále nenahraditelná. Přestože je dnes elektrokardiogram velice podrobně popsán i s jeho poruchami a arytmiemi, stále jen odborník, lékař, dokáže na základě svých znalostí a zkušeností, určit správnou diagnózu. Někdy je ale i odborník v koncích. To, když je obrázek jemu předložený nečitelný.

Vlivů způsobujících ztrátu informace a tím znesnadnění čtení z elektrokardiogramu může být celá řada. Často je obrázek zarušen frekvencí elektrické sítě, kterou je EKG napájeno, nebo je na vině samotný pacient, který není schopen být při měření EKG v klidu (např. kvůli nemoci). Smyslem této práce je, pokusit se v takovýchto případech o možné zlepšení čitelnosti dat, a to na základě aplikace metod pro slepou separaci dat na naměřená, nečitelná data.

Slepou separaci signálů (BSS), jakožto obor ve zpracování signálů, řeší celá řada nejrůznějších metod, jmenujme pouze několik nejznámějších: ICA(EFICA, FastICA, JADE, Infomax), SOS(SOBI, WASOBI), MULTICOMBI.

Analýza nezávislých komponent (ICA) je asi vůbec nejznámější a nejpoužívanější z těchto metod. Její historie začíná brzy v 80. letech 20. století. První články s tímto tématem souvisí zejména se studiem neuronových sítí, ale záhy se objevují především v kontextu matematické statistiky a analýzy signálů. V polovině 90. let jsou již vytvořeny první dostatečně účinné algoritmy, využívající myšlenky ICA, od několika vědeckých týmů z celého světa.

Typickou motivační aplikací BSS, potažmo ICA, je tzv. *cocktail party* problém. Cocktail party problém je úloha založená na představě večírku, kde se současně baví několik lidí mezi sebou a mluví jeden přes druhého, zvuk v místnosti je snímán


soustavou mikrofónů a cílem je oddělení řečových signálů jednotlivých řečníků z dané směsi. Podobná úloha je při analýze signálu z elektroencefalogramu (EEG), kdy je cílem rozložit signál nahraný soustavou elektrod na hlavě pacienta na složky odpovídající aktivitě různých nervových center v mozku. ICA lze tedy použít v mnoha oblastech lidské činnosti.

Tato práce si klade za cíl ozřejmit, zda-li je možné využít algoritmů slepé separace pro řešení daných úloh na reálných EKG datech. V práci je aplikován především algoritmus EFICA, dále pak algoritmy WASOBI a MULTICOMBI. Před samotnou aplikací zmiňovaných algoritmů jsou v úvodních kapitolách stručně popsány základní vlastnosti EKG záznamů a teoretický základ slepé separace signálů. Je to nezbytné k porozumění samotné aplikaci algoritmů pro slepou separaci dat na reálné EKG záznamy.

3 Seznámení se základními vlastnostmi EKG záznamů

3.1 Vznik a průběh EKG záznamu

Co je to EKG? Elektrokardiogram (EKG) je velmi jednoduché, nenáročné a nebolestivé vyšetření, díky kterému má lékař přehled o elektrické aktivitě srdce. Každý stah srdečního svalu je doprovázen vznikem slabého elektrického napětí, které se šíří až na povrch těla. Pokud někde v srdci dojde ke změně elektrické aktivity, může se lékař domnívat, že je srdce nemocné.



Obrázek 1: Převodní systém srdce


Srdce má schopnost vytvářet vzruchy, tzv. srdeční automacie. Výsledkem vzruchové aktivity je sled pravidelných rytmických srdečních stahů i bez vnějšího podráždění. Normálně je zdrojem depolarizací (vzruchů) SA uzel, vzruch se šíří myokardem síní do AV uzlu. V AV uzlu dochází ke zpoždění 120-200 ms a dále se vzruch šíří Tawarovými raménky a prostřednictvím Purkyňových vláken se depolarizace šíří po celém myokardu. U zdravého srdce je směr šíření vzruchů v určitém okamžiku vždy stejný. Výsledné vektory vzruchu můžeme snímat pomocí EKG.

Elektrickou aktivitu srdce zaznamenáváme elektrokardiografem (rovněž EKG). Tento přístroj zaznamenává průběhy potenciálů v jednotlivých svodech (svod jsou dvě místa, mezi kterými měříme biopotenciály) a vykresluje je v závislosti na čase.


V dnešní době je nejvíce používaný 12-ti svodový systém EKG. Na končetinách a hrudníku jsou přesně umístěny elektrody. 12-ti svodové EKG zahrnuje:

- 3 bipolární končetinové svody podle Einthovena (I, II, III)
- 3 unipolární zvětšené končetinové svody podle Goldberga (aVL, aVR, aVF)
- 6 unipolárních hrudních svodů podle Wilsona (V1 - V6)


To jakým způsobem se umísťují elektrody na lidské tělo a jak se měří napětí ve svodech ukazují následující tři obrázky.



Obrázek 2: Bipolární svody podle Einthovena - $I=L-R$, $II=F-R$, $III=F-F$.



Obrázek 3: Unipolární svody podle Goldberga - $aVR=R-(L+F)/2$, $aVL=L-(R+F)/2$, $aVF=F-(R+L)/2$.




Obrázek 4: Unipolární svody podle Wilsona - $V_n=V_n-W$, $W=(R+L+F)/3$.

⁰Obrázky vypůjčeny z (Dostál, 2006)

3.2 Normální vs poruchové EKG

3.2.1 Popis křivky normálního EKG

Při obvyklé klinické praxi se zapisuje křivka EKG na speciální papír s grafickým rastrem, připomínající rastr milimetrového papíru. Nejčastěji se užívá posuv papíru 25 mm/s, což znamená, že při vertikálním členění rastru 1 mm, odpovídá vzdálenost mezi dvěma sousedními slabými linkami časovému intervalu 0,04 s. Horizontální rozčlenění umožňuje hodnotit EKG křivku co do její výšky či hloubky.



Obrázek 5: Normální elektrokardiogram

Normální EKG je složeno z opakujících se period, odpovídajících jednotlivým tepům srdce. Na periodě se rozlišuje několik dílčích vln, označovaných písmeny P, Q, R, S, T a U. (Poznámka: V signálu nemusí být nutně všechny přítomné). Dále je pro podrobný popis křivka EKG rozdělena na intervaly a segmenty (viz obrázek 5). Doby trvání jednotlivých vln, hlavně prvních P, Q, R, jsou přibližně konstantní a určené fyziologickými parametry srdce. Případné kolísání tepu se projevuje nejvíce nerovnoměrným spouštěním srdce, tedy změnou délky prodlevy před začátkem stahu. Vlna P, začátek periody, se na záznamu objevuje jako malý hrbolek před

⁰Obrázky vypůjčeny z (Dostál, 2006)

nejvýraznější dílčí vlnou periody (označenou jako R). Vlna P bývá mnohdy téměř ztracená v šumu. Nejlépe, a proto i nejčastěji, se proto detekuje vlna R, maximální špička signálu, kterou lze snadno najít. Z hlediska medicínské diagnostiky má ale nejmenší význam, protože se v ní neprojevují vady srdce. Mnohem důležitější bývají úseky po ní. Vzdálenost dvou R vln, odpovídá tedy době jednoho tepu. Tep kolísá s dechem a i u zdravého člověka občas jedna perioda vynechá.

3.2.2 Poruchové EKG

Poruchy elektrokardiogramu, tzn. odlišnosti od normálního EKG, rozdělíme do dvou skupin:


1. Poruchy související se srdeční činností
2. Poruchy nesouvisející se srdeční činností

Poruch EKG signálu souvisejících se srdeční činností existuje velké množství. Mezi lékaři je známo několik stovek různých druhů EKG signálů a každý znamená předzvěst jiného problému srdce. Do této skupiny se řadí nejrozumnější typy arytmií, hypertrofie srdečních komor a zánětlivá onemocnění srdce. V současné době je elektrokardiogram téměř suverénní metodou v diagnostice arytmií. Jako arytmie se označují všechny poruchy tvorby vzruchu, tzn. rytmy s atypickým místem vzniku vzruchu, nefyziologické frekvence apod., a dále veškeré poruchy vedení vzruchu.

Do druhé skupiny poruch patří např. mimosrdeční nemoci nebo abnormální svalové pohyby. Stah jakéhokoliv svalu je zahájen depolarizací svalových buněk a ačkoliv přístroje na EKG jsou zvláště citlivé na podněty ze srdečního svalu, zaznamenávají také kontrakce svalů kosterních. Většina „poruch“ EKG s vysokou frekvencí kmitů je způsobena celkovým svalovým napětím u pacienta, který není řádně relaxován. Je to nápadné u osob, kterým je zima a třesou se. Dalšími příklady, způsobujícími poruchy a tím špatnou čitelnost elektrokardiogramu, mohou být rušení signálu síťovým šumem, nesprávné přiložení elektrod a další vlivy, související s nesprávným měřením EKG. V takovýchto případech vznikají na EKG artefakty, které nesouvisí

se srdečním onemocněním a je důležité je rozpoznat a nemyslet si, že pacient má nemocné srdce prostě proto, že EKG je abnormální.

Po konzultaci s jedním z předních kardiologů Krajské nemocnice Liberec je tato práce zaměřena na odstraňování poruch nesouvisejících se srdeční činností, zejména na úlohy odstraňování šumu a třesu. Důvody jsou zřejmé. Poruchy EKG související se srdeční činností jsou pro lékaře užitečné a nezbytné při určování diagnózy a jejich odstranění není žádoucí. Naopak artefakty na EKG, vzniklé nějakou mimosrdeční činností, jsou nežádoucí a jejich odstranění může vést ke zvýšení užitečné informace v elektrokardiogramu.



Obrázek 6: Příklad EKG obsahujícího třes


4 Slepá separace signálů

Základní úlohou slepé separace signálů (BSS) je získat původní signály (originální signály) z nějaké jejich směsi, jestliže máme k dispozici pouze tuto směs. Původní signály budeme značit písmenem s , jejich směsí, tj. měřená data (mixované signály), označíme x . Obecně lze chápat každý signál jako libovolný náhodný proces a vztah, který platí mezi původními a měřenými signály, by byl vyjádřen zobrazením, navíc závislým na čase. Takovýto matematický model můžeme zapsat následovně

$$x(t) = f(s(t), t). \quad (1)$$

Vzhledem k nejednoznačnosti řešení takovéto úlohy, je nutné model konkréti-
zovat. Základním a nejjednodušším modelem je model lineární. V tomto případě je
zobrazení f lineární a je reprezentováno maticí $\mathbf{A}$. V této práci budeme prvky ma-
tice $\mathbf{A}$ uvažovat na čase nezávislé, bude tedy používán **stacionární lineární model**
(Obrázek 7). Vztah mezi původními a mixovanými signály lze tedy zapsat jako

$$x(t) = \mathbf{A}s(t). \quad (2)$$



Obrázek 7: Lineární model

Rovnici (2) můžeme pro N původních signálů v jednom časovém okamžiku
zapsat pro názornost ve tvaru

$$\begin{pmatrix} a_{11} & \cdots & a_{1N} \\ \vdots & \ddots & \vdots \\ a_{N1} & \cdots & a_{NN} \end{pmatrix} \begin{pmatrix} s_1(t) \\ \vdots \\ s_N(t) \end{pmatrix} = \begin{pmatrix} x_1(t) \\ \vdots \\ x_N(t) \end{pmatrix}. \quad (3)$$

Úpravou (3) získáme vztah pro původní signály. Ty lze tedy vypočítat jako

$$s(t) = \mathbf{A}^{-1}x(t). \quad (4)$$

4.1 Přehled BSS metod

4.1.1 ICA

Analýza nezávislých komponent (ICA) je jednou z nejznámějších a nejpoužívanějších metod pro slepou separaci signálů. Vychází z několika předpokladů týkajících se modelu problému:

- Použití lineárního modelu $x = \mathbf{A}s$, kde $\mathbf{A}$ je regulární matice $n \times n$. Mixovaných signálů bude tedy stejný počet jako původních signálů.
- Původní signály jsou statisticky nezávislé.
- Původní signály nejsou gaussovské. Přesněji pouze jeden ze signálů může být gaussovský.

Základní úloha analýzy nezávislých komponent spočívá v nalezení takové lineární transformace

$$\hat{s} = \mathbf{W}\mathbf{x}, \quad (5)$$

aby $\hat{s}_i$ měly co nejmenší míru závislosti (vzájemnou informaci).

Hledaná matice $\mathbf{W}$ je odhadem skutečné matice $\mathbf{A}^{-1}$ a nejčastěji je nazývána jako **demixovací matice** a z ní vypočtené signály $\hat{s}_i$ jsou označovány jako **komponenty**.

I nejjednodušší lineární model skýtá pro řešení ICA nejednoznačnosti v některých jeho vlastnostech. Pro posuzování kvality separace je třeba tento problém řešit. Nejednoznačnosti signálů získaných za pomoci lineárního modelu ICA jsou:

- Rozptyl a střední hodnota
- Pořadí signálů
- Znaménko každého signálu

Pro úplnou rekonstrukci by bylo tedy nutné znát nějakou apriorní informaci.

Hodně negaussovské signály jsou dobře odhadnutelné a naopak.

Algoritmy: JADE, Infomax, FastICA, EFICA

4.1.2 SOS BSS algoritmy

SOS je další známou a používanou skupinou algoritmů pro slepou separaci signálů. SOS BSS algoritmy využívají ve svém principu tzv. statistiky 2.řádu (vzájemné korelační matice).

Zatímco u ICA jsou původní signály uvažovány jako nezávislé realizace náhodných veličin (i. i. d.) a signály mají tedy pouze prostorovou strukturu, v případě SOS jsou původní signály pokládány za gaussovské stacionární náhodné procesy, které lze popsat pomocí modelu (AR, MA, ARMA). Signály takto modelované mají tedy časovou strukturu. Demixovací matice W je pak nalezena pomocí statistik druhého řádu, přes výpočet cross-korelační matice.

Algoritmy: SOBI, WASOBI

4.1.3 Hybridní algoritmy

Jedná se o algoritmy využívající prostorovou i časovou strukturu původních signálů. Na základě odhadu přesnosti je adaptivně vybírána vhodnější metoda (ICA, SOS).

Algoritmy: ThinICA, JADE^{TD}, COMBI, MULTICOMBI

4.2 Použití algoritmů BSS v Matlabu

Algoritmy pro slepou separaci dat jsou zpravidla volně ke stažení, pro Matlab ve formě funkčních m-filů. Existuje jich celá řada, tak jak byly jmenovány v sekci 4.1. Tato práce se omezuje pouze na algoritmy EFICA, WASOBI a MULTICOMBI. Jakým způsobem lze použít zmiňované algoritmy v prostředí Matlabu, by měly objasnit následující řádky.

4.2.1 EFICA

Syntaxe:

[We, ISRef, Wsymm, ISRsymm, status]=efica(X, ini, g, SaddleTest)

We		demixovací matice vytvořená algoritmem EFICA
ISRef		ISR matice, teoretický odhad
Wsymm, ISRsymm	...	demixovací matice a ISR odhad z první fáze EFICA (FastICA), We a ISRef jsou tím pádem zpřesněné
status		1, byl-li test sedlových bodů pozitivní
X		matice naměřených dat
ini		inicializační matice iteračního algoritmu
g		nonlinearita použitá k aproximaci entropií
SaddleTest		má-li být proveden test sedlových bodů

4.2.2 WASOBI

Syntaxe:

[Wwasobi, Wsobi, ISR, signals]=ewasobi(X, ARmax, rmax)

Wwasobi	demixovací matice vytvořená algoritmem WA-SOBI
Wsobi	demixovací matice vytvořená algoritmem SOBI
ISR	ISR matice, teoretický odhad
signals	odseparované signály
X	matice naměřených dat
ARmax	řád AR modelu
rmax	omezení pro pól v AR modelu, je-li 1, pak není žádné omezení, používáme 0.99 (kvůli stabilitě)

4.2.3 MULTICOMBI

Syntaxe:

Wmulticombi=multicombi(X, ARmax, rmax)


Wmulticombi	demixovací matice vytvořená algoritmem MULTICOMBI
X	matice naměřených dat
ARmax	řád AR modelu
rmax	omezení pro pól v AR modelu, je-li 1, pak není žádné omezení, používáme 0.99 (kvůli stabilitě)

5 Manipulace s EKG daty v Matlabu

5.1 Import dat, vizualizace

Pro manipulaci s EKG daty v Matlabu je potřeba naměřená data importovat do tohoto prostředí. Většina dat používaných v této práci je naměřena přístrojem BTL-08 MT Plus ECG, jehož výstupem jsou data ve formátu XML. Pro práci s tímto formátem v Matlabu je možné využít XML toolboxu, který je zdarma ke stažení na www.geodise.org. Pomocí něj byla vytvořena funkce „import_EKG_dat“ (příloha A), parametrem je název souboru s příponou XML. Tato funkce převede data naměřená jmenovaným přístrojem do Workspace Matlabu, kde je možné s nimi dále pracovat.


Jestliže importovaná data zobrazíme prostým použitím příkazu `plot`, lze očekávat, že takový obrázek nebude přehledný a jeho obrazová informace nebude mít pro lékaře hodnotu.



Obrázek 8: Zobrazení dat prostým příkazem `plot`


Je nutné tedy provést lepší vizualizaci naměřených dat tak, aby jejich obrazová informace byla co největší. Nejvýhodnější bude použít klasického zobrazení EKG,

které je běžně používáno v praxi, tzn. zobrazení signálů z jednotlivých svodů pod sebe.



Obrázek 9: Klasické zobrazení EKG dat v praxi


Pro tento účel je vytvořena funkce „zobraz“ (příloha B), jejímiž vstupními parametry jsou časový vektor, pole naměřených signálů, offset a vektory barev pro jednotlivé barevné složky. Parametr offset určuje míru posunutí signálů ve vertikálním směru. Funkce zobrazí obrázek. Pro identifikaci signálů je ještě nutné přidat legendu, případně ještě popis os. V praxi osy nebývají popsány, uvádí se pouze rychlost posuvu papíru a měřítko pro velikost napětí (standardně 25 mm/s a 10 mm/mV). V našem případě bude na ose x vždy číslo vzorku.



Obrázek 10: Zobrazení EKG dat pomocí funkce „zobraz“

5.2 Předzpracování dat

Jednou z častých vlastností naměřených reálných EKG dat je tzv. **napěťový drift isolinie**. Způsobují ho aditivní signály nízkých frekvencí, které nenesou žádnou užitečnou informaci. Tato nepříjemná vlastnost výrazně snižuje čitelnost EKG dat, je proto dobré tyto nízké frekvence potlačit. Odstranění napěťového driftu je ve své podstatě velmi jednoduché a je vhodné ho zařadit ještě před samotným zpracováním dat.




Obrázek 11: EKG signál z jednoho svodu - a) s driftem isolinie, b) s potlačeným driftem isolinie pomocí funkce „filtr_isolinie“

Jak vypadá napěťový drift isolinie reálných EKG dat ukazuje obrázek 11a. Pro potlačení tohoto jevu byla vytvořena funkce „filtr_isolinie“ (příloha C), která pracuje na principu hornopropustního filtru. Funkce má dva parametry, prvním je filtrovaný signál a druhým počet filtrovaných nejnižších frekvencí signálu. Ke zjišťování frekvenčního spektra je využita rychlá Fourierova transformace. Aplikací funkce s parametrem `Pocet=15` na data z obrázku 11a získáme data, která jsou zobrazena na obrázku 11b. Odstranění driftu isolinie je patrné.

Aplikace algoritmů pro slepou separaci dat na EKG data, která nemají odstraněn drift isolinie je samozřejmě možná, ale nevýhodná. V ideálním případě by se drift isolinie mohl objevit jako jedna z komponent při analýze nezávislých komponent, a pak by bylo snadné jej odstranit i bez předchozího použití filtru, ale ukazuje se, že takováto situace nenastává a drift isolinie je spíše obsažen ve větším množství komponent. Pro odstranění driftu je pak tedy potřeba upravit (filtrovat) všechny komponenty, které ho obsahují. Výhodnější je tedy před samotnou aplikací algoritmů pro slepou separaci využít předzpracování dat ve formě funkce pro potlačení driftu isolinie.

6 Aplikace algoritmů pro slepou separaci dat

Samotnou realizaci pokusů s aplikací algoritmů pro BSS v Matlabu lze rozdělit do několika kroků (viz obrázek 12).



Obrázek 12: Postup realizace pokusů

V první řadě je samozřejmě nezbytné načíst pořízená data do Matlabu a přehledně si je zobrazit. Jakým způsobem toho dosáhnout bylo popsáno v sekci 5.1. Nyní je užitečné připravit data před samotnou aplikací algoritmů. V sekci 5.2 bylo vysvětleno, proč je předzpracování EKG dat výhodné. Dalším a důležitým krokem, je vhodná volba oblastí dat, které budou zpracovávány. Dobré je vybrat oblasti tak, aby v jejich celé šíři byl obsažen odstraňovaný artefakt, nevznikne pak problém s napojením zrekonstruovaných dat. Pak je již možné na vybrané oblasti aplikovat nějaký konkrétní algoritmus pro slepou separaci dat. Dále je proveden výběr nežádoucích komponent získaných algoritmem pro BSS, jejich následná úprava a zpětná rekonstrukce dat. Princip zpětné rekonstrukce dat spočívá ve vynásobení upravených komponent inverzí demixovací matice, což je logické a vychází to ze struktury lineárního modelu BSS. Díky základní znalosti průběhu normálního EKG (viz 3.2.1),


lze porovnáním naměřených EKG dat s upravenými stanovit, zda došlo ke zlepšení čitelnosti, či nikoliv.

6.1 Symbolický zápis aplikace algoritmů pro BSS

1. **X** % *Naměřená data*
2. **zobraz(X)** % *Zobrazení dat*
3. **X=předzpracování(X)** % *Filtrace isolinie*
4. **oblastX=X(:,od:do)** % *Výběr oblasti*
5. **W=algoritmusBSS(oblastX)** % *Výpočet demixovací matice*
6. **S=W*oblastX** % *Signály získané BSS algoritmem (komponenty)*
7. **S(komponenta,:)=úprava(S(komponenta,:))** % *Nulování nebo filtrace nežádoucích komponent*
8. **X_new=inv(W)*S** % *Rekonstrukce oblasti dat po úpravách*
9. **zobraz(X_new)** % *Zobrazení výsledku*

6.2 Uměle vytvořená data

Popsaný postup je nejprve aplikován na ukázkovém příkladu, který deklaruje správnost metodiky. Nejprve byla v Matlabu vytvořena mixovaná data tak, aby odpovídala představě lineárního modelu BSS. Konkrétně bylo vytvořeno 8 sinusových průběhů s různými amplitudami a frekvencemi a do nich byl přimíchán bílý šum tak, aby ovlivňoval všechny vytvořené sinusové signály shodně. Takto vytvořené mixované signály jsou zobrazeny na obrázku 13.




Obrázek 13: Uměle vytvořená data

Krok předzpracování dat je v tomto případě vynechán, jelikož se nejedná o reálné EKG záznamy a k driftu isolinie nedochází.


Pro aplikaci algoritmů BSS (tj. EFICA, WASOBI, MULTICOMBI) je vybrána celá oblast dat, jelikož data jsou ovlivněna bílým šumem v jejich celé délce.

Jaké vzniknou komponenty (odhady původních signálů) aplikací algoritmů EFICA, WASOBI a MULTICOMBI ukazuje obrázek 14. Z obrázku je na první

pohled patrné¹, které komponenty obsahují bílý šum, a tudíž jsou nežádoucí. V tomto případě lze tyto komponenty jednoduše odstranit (vynulovat). Z komponent získaných algoritmem EFICA byla tedy odstraněna sedmá, z komponent získaných algoritmem WASOBI osmá a z komponent získaných algoritmem MULTICOMBI třetí a pátá komponenta. Tímto byla provedena úprava komponent, a jejich podoba po této akci je zachycena na obrázku 15.



Obrázek 14: Komponenty vypočtené pomocí algoritmů pro BSS




Obrázek 15: Komponenty po úpravě

V posledním kroku jsou data rekonstruována pomocí upravených komponent a zobrazena s poškozenými daty tak, aby bylo možné dobře porovnat dosažené

¹Jak postupovat v případě, kdy nežádoucí komponenty nejsou na první pohled patrné, bude popsáno v následující sekci (6.3).

výsledky. Jak dopadla slepá separace dat pomocí algoritmů EFICA, WASOBI a MULTICOMBI u uměle vytvořených dat je vidět na obrázku 16.



Obrázek 16: Aplikace algoritmů pro BSS na uměle vytvořená data

Ačkoliv byly použity tři rozdílné algoritmy pro slepou separaci uměle vytvořených dat, výsledky separace jsou prakticky totožné u všech aplikovaných algoritmů. Z výsledků je také jasně viditelné, že došlo k odstranění bílého šumu, jímž byly všechny použité signály ovlivněny, což dokazuje správnou funkci algoritmů a použitelnost na takováto data.


6.3 Zjištění nežádoucích komponent na základě rozložení energie mixovací matice

Ne vždy je v rozvaze nad komponentami jasné, které jsou nežádoucí, tak jak tomu bylo v minulém pokusu popsaném v sekci 6.2. V takových případech je nutné, k volbě nežádoucích komponent, použít jiné prostředky, které mohou být v této analýze

nápomocny. Jednou z variant je rozložení energie mixovací matice (matice inverzní k demixovací matici).

Jednotlivé prvky mixovací matice jsou umocněny na druhou a jejich pozice v matici poskytuje informaci, jak velkou energií přispívá která komponenta (sloupec) kterému signálu (řádek). Je výhodné, zobrazit si umocněnou mixovací matici v barevné škále, kde teplejší barva prvku matice značí větší energii. Pro takové zobrazení existuje v Matlabu funkce „imagesc“.

Konkrétní použití demonstruje obrázek 17, na kterém je zobrazeno rozložení energie mixovacích matic, získaných aplikací různých algoritmů pro BSS na uměle vytvořená data tak, jak byla tato úloha popsána v předešlé sekci (6.2). Na obrázku je vidět, že komponenty 7(u EFICA), 8(u WASOBI) a 3 a 5(u MULTICOMBI) přispívají rovnoměrně do všech signálů umělých dat a lze je tedy po právu považovat za nežádoucí komponenty, způsobující aditivní bílý šum.



Obrázek 17: Rozložení energie mixovací matice algoritmů pro BSS

Hlavně při řešení úloh na reálných EKG datech, je zjišťování nežádoucích komponent na základě rozložení energie mixovací matice důležitým vodítkem.

6.4 Odstraňování šumu z reálných EKG záznamů

Častou poruchou pořízených EKG dat je přítomnost síťového šumu (o frekvenci 50 Hz). Tento šum má poměrně nízkou energii, a tak znehodnocení užitečného signálu není velké, ale v kombinaci s dalšími poruchami už může být problémem. Jelikož

šum ovlivňuje všechny signály, je jeho odstranění snadné, podobně jako v případě pokusu s uměle vytvořenými daty.




Obrázek 18: EKG data s 50 Hz šumem


Naměřená EKG data poznamenaná šumem o frekvenci 50 Hz jsou zobrazena na obrázku 18². Algoritmy pro slepou separaci dat byly aplikovány na nepředzpracovaná data a na jejich celou (zobrazenou) šířku. Jak vypadají komponenty po aplikaci jednotlivých algoritmů je vidět na obrázku 19. Každý z aplikovaných algoritmů vykazuje v tomto případě dvě komponenty, které obsahují šum o frekvenci 50 Hz. U algoritmu EFICA jsou to komponenty 2 a 6, u WASOBI 2 a 5, u MULTICOMBI 6 a 7. Potvrdí toto tvrzení rozložení energie mixovací matice? Rozložení energie mixovacích matic od jednotlivých algoritmů je na obrázku 20. Je možné vidět, že příspěvek zmíněných komponent je do jednotlivých signálů poměrně rovnoměrný (v

²Pro lepší orientaci v obrázcích rozložení energie mixovací matice, budou signály EKG označovány číslicemi. Ve skutečnosti signál 1 odpovídá svodu II, 2 - III, 3 - V1, 4 - V2, 5 - V3, 6 - V4, 7 - V5, 8 - V6.

případě WASOBI a MULTICOMBI je o maličko větší do prvního a druhého signálu, s čímž měřená data korespondují) a jeho energie je velice malá, což bylo již na začátku očekáváno. Nicméně, rozložení energie mixovací matice se v tomto případě neukazuje jako příliš průkazné, a to právě vzhledem k nízké energii odstraňované poruchy (šumu).




Obrázek 19: Komponenty získané algoritmy pro BSS



Obrázek 20: Rozložení energie mixovací matice algoritmů pro BSS


Vzhledem k pravidelnosti špiček vyskytujících se v inkriminovaných komponentách, lze usuzovat, že nesou nějakou užitečnou informaci. Proto jsou komponenty pro zachování užitečné informace upraveny dolnoproustním filtrem³ (příloha D) a nejsou celé nulovány. Komponenty od jednotlivých algoritmů jsou po úpravě zobrazeny na obrázku 21.

³Pro DP filtr byla vytvořena funkce obdobná jako v sekci 5.2, parametr Pocet však udává počet odstraněných nejvyšších frekvencí



Obrázek 21: Komponenty po úpravě

Data rekonstruovaná novými komponentami (obrázek 22) jsou již téměř bez šumu, a to u všech tří aplikovaných algoritmů.




Obrázek 22: Aplikace algoritmů pro BSS na data se šumem

6.4.1 Filtr vs BSS

Na tomto místě vzniká otázka, proč použít metod BSS k odstranění šumu o známé frekvenci, jestliže můžeme použít filtr pro tuto frekvenci.

Samotný signál normálního EKG už obsahuje frekvence blízké 50 Hz, proto při prosté filtraci dochází i k potlačení užitečné informace. Tato skutečnost je vidět

v detailu na obrázku 23, který porovnává filtraci 50 Hz filtrem s filtrací pomocí algoritmu EFICA.



Obrázek 23: Filtr vs BSS


6.5 Odstraňování třesu z reálných EKG záznamů

Třes pacienta, ať už má jakoukoli příčinu, patří mezi nejčastější a nejvýraznější poruchy elektrokardiogramu a má velký vliv na jeho čitelnost.

V této sekci je popsáno pouze několik pokusů, jejichž cílem je odstranění tohoto problému, ale naměřeno jich bylo podstatně víc. Bohužel nebyla k dispozici EKG data od pacienta s nějakou nemocí, která má třes na svědomí, a tak všechna data jsou měřena na zdravém pacientovi, který třes předstírá. Je měřen poměrně pravidelný třes tak, aby bylo snadné určit oblast pro aplikaci algoritmů pro BSS. Navíc je uvažována „rozumná“ intenzita třesu, není možné si představovat, že má pacient na lůžku silný záchvat. Při velmi silné třesu již např. docházelo k odpadávání elektrod a přístroj ho nedokázal zaznamenat.

6.5.1 Pokus první - třes horních končetin


V tomto pokusu byl pacient instruován tak, aby na pokyn trásl oběma rukama. Jak vypadají naměřená data je vidět na obrázku 24a. Je jasné patrné, kterak je EKG signál třesem rukou ovlivněn. Třes vytváří signál s poměrně vysokou frekvencí i energií a v oblasti, ve které je měřen, je elektrokardiogram zcela nečitelný.



Obrázek 24: Třes horních končetin


Z pořízeného EKG je odfiltrován drift izoliny a vybrána oblast poškozených dat (viz obrázek 24b).

Následuje výpočet komponent pomocí algoritmů pro slepou separaci. Jednotlivé komponenty tak, jak byly získány aplikací algoritmů EFICA, WASOBI A MULTI-COMBI jsou zobrazeny na obrázku 25 a nyní je nutné vybrat nežádoucí komponenty a ty odstranit, případně upravit.



Obrázek 25: Komponenty získané algoritmy pro BSS


Při prvním pohledu je možné rozpoznat, které komponenty by s největší pravděpodobností mohly obsahovat užitečný signál, a které nikoli, nicméně, u některých to zřejmé není. K bližší studii je opět možné využít rozložení energie mixovací matice (obrázek 26) jednotlivých algoritmů.



Obrázek 26: Rozložení energie mixovací matice algoritmů pro BSS


Ukazuje se, že komponenta 1 získaná algoritmem EFICA (u WASOBI komponenta 8, u MULTICOMBI také 1) má největší energii a přispívá docela rovnoměrně do všech signálů a lze usuzovat, že se jedná o komponentu třesu horních končetin. Odstranění jenom této komponenty však ještě nevede k absolutnímu zlepšení čitelnosti dat. Je nutné ještě úplně odstranit komponenty 2 a 6 získané pomocí EFICA a dále provést filtraci vysokých frekvencí 7. komponenty. Tyto komponenty byly určeny pozorováním. Je totiž vidět, že mají charakter rušivého signálu a nulovou periodicitu (na první pohled neperiodické signály). Komponenta 7 byla filtrována z toho

důvodu, že nese částečně užitečnou informaci, což dokazují opakující se špičky signálu. U WASOBI a MULTICOMBI byly ze stejných důvodů provedeny obdobné úpravy, pouze s jinými komponentami. Komponenty po těchto úpravách je možné shlédnout na obrázku 27.



Obrázek 27: Komponenty po úpravě


Na obrázku 28 jsou již zobrazena zrekonstruovaná data, po výše popsáných úpravách komponent. Je vidět markantní rozdíl mezi vybranou oblastí naměřených EKG dat, a tou samou oblastí po úpravě pomocí jednotlivých algoritmů. V zrekonstruovaných datech je možné pohodlně pozorovat P vlny, QRS komplexy a T vlny elektrokardiogramu.



Obrázek 28: Aplikace algoritmů pro BSS na data pořízená při třesu horních končetin

6.5.2 Pokus druhý - třes všech končetin


V tomto pokusu jsou zpracovávána data, která byla pořízena při lehkém třesu obou rukou i nohou pacienta. Jelikož třes nebyl tak intenzivní jako v předešlém pokusu, byla očekávána nižší energie komponenty třesu. Jak vypadají naměřená data, je možné pozorovat na obrázku 29a.



Obrázek 29: Třes všech končetin


Třes pacienta poškodil data ve dvou oblastech. Úloha odstranění třesu je analogická pro každou z nich. Byla odstraněna plovoucí isolinie a pro podrobnější rozbor vybrána druhá oblast poškozených dat, tak jak jí zobrazuje obrázek 29b.

Na tuto oblast byly následovně aplikovány algoritmy pro BSS a na obrázku 30 jsou zobrazeny komponenty, které takto vznikly. Komponenty od různých algoritmů jsou si opět podobné, jen je proházeno pořadí. Jaké komponenty byly odstraněny




Obrázek 30: Komponenty získané algoritmy pro BSS

ukazuje obrázek 32. Důvody již není třeba obsáhle komentovat, výběr nežádoucích komponent již byl několikrát podrobně popsán. Lze jen opět konstatovat, že komponenty byly vybírány na základě rozložení energie mixovací matice (obrázek 31), poté případně pozorováním periodicity signálu a jeho charakteru.




Obrázek 31: Rozložení energie mixovací matice algoritmů pro BSS

Na zrekonstruovaných datech, která jsou zobrazena na obrázku 33, je vidět opět obrovský pokrok v čitelnosti dat. Vybraná oblast EKG dat byla zcela nečitelná, nyní lze s mnohonásobně větší jistotou stanovit pacientovu diagnózu. Problémem možná může být nižší přesnost nových dat, např. u WASOBI je vidět, že v případě prvního signálu (svod II) dochází k potlačení S-vlny, ale takové chyby je samozřejmostí očekávat. Snad tomu lze předejít právě např. kombinací více algoritmů, ale více v závěru (7).




Obrázek 32: Komponenty po úpravě



Obrázek 33: Aplikace algoritmů pro BSS na data pořízená při třesu všech končetin

6.5.3 Pokus třetí - zatínání svalů


Ve třetím pokusu jsou algoritmy pro BSS aplikovány na data, která byla poškozena vlivem zatínání svalstva. Pacient v určitém okamžiku měření EKG zpevnil celé tělo, což mělo za následek snížení čitelnosti dat. Taková naměřená data se třemi nečitelnými oblastmi, vhodnými pro aplikaci algoritmů slepé separace signálů, jsou zobrazena na obrázku 34a.



Obrázek 34: Zatínání svalů


Pro demonstraci algoritmů slepé separace na tento druh dat byla vybrána třetí oblast dat (obrázek 34b), samozřejmě po předchozím předzpracování, čili po odstranění napěťového driftu isolinie. Jedná se o relativně krátký úsek dat a při úpravě komponent se tedy nelze spoléhat na periodicitu signálu, tak jak bylo popsáno dříve.

Jak vlastně komponenty v této úloze pro jednotlivé druhy algoritmů vypadají ukazuje obrázek 35.



Obrázek 35: Komponenty získané algoritmy pro BSS


Pro výběr nežádoucích komponent jsou opět použity postupy totožné s těmi, které se objevovaly v předcházejících pokusech. Ve stručnosti bude popsán postup výběru nežádoucích komponent získaných algoritmem EFICA.



Obrázek 36: Rozložení energie mixovací matice algoritmů pro BSS

Z rozložení energie mixovací matice a i z pouhého pozorování (průběh této komponenty neznačí přítomnost užitečného signálu) lze v tomto případě říci, že 2.komponenta získaná pomocí EFICA je onou nežádoucí komponentou, která obsahuje největší energii a nejvíce ovlivňuje normální elektrokardiogram. Tato komponenta bude nulována. Určení dalších dvou komponent, tj. komponenty 1 a 6, které budou také nulovány (viz obrázek 37), není tak dobře odůvodnitelné, jelikož jejich energie je nízká a obrázek rozložení energie mixovací matice není tak průkazný. Každopádně


tyto komponenty narozdíl od ostatních nenesou tak zřejmě užitečnou informaci a experimentálně se potvrdilo, že jejich odstranění vede ke zlepšení čitelnosti EKG dat.



Obrázek 37: Komponenty po úpravě

Komponenty získané jednotlivými algoritmy, tj. pomocí EFICA, WASOBI a MULTICOMBI, si jsou opět podobné a postup při výběru těch nežádoucích je tožný.

Zrekonstruovaná data, po provedené rozvaze nad komponentami, jsou zobrazena na obrázku 38.



Obrázek 38: Aplikace algoritmů pro BSS na data pořízená při zatínání svalů

6.6 Problémy aplikace algoritmů pro BSS na reálné EKG záznamy

Pokusy, které byly popsány v této kapitole, jsou do jisté míry demonstrativní. Jejich metodika bude fungovat vždy, ale nemusí vést k tak vynikajícím výsledkům. Pro tuto práci bylo naměřeno množství dat a pro některá z nich se nepodařilo dosáhnout uspokojivých výsledků.

Jedním z problémů, je samotné předzpracování. V některých případech, když je třes pacienta obzvláště silný, dochází k prudkým změnám v isolinii a její drift se nedá bez ztráty užitečné informace odstranit, alespoň ne navrženým způsobem, protože by byly částečně filtrovány i užitečné frekvence.

Dalším problémem, snad největším, je vhodný výběr oblasti dat. Ukazuje se, že i drobná změna délky oblasti dat může mít významný vliv na výsledek slepé separace. Navíc data mohou obsahovat více poruch a někdy je velmi komplikované odhadnout, kdy jedna porucha končí a druhá začíná. Ve zmiňovaných demonstrativních pokusech bylo předem známo, že se projevuje pouze jedna z poruch, např. jenom třes, ale v praxi je to mnohem komplikovanější a třes se může mísit se zatínáním svalů i s dalším šumem. V takovém případě je pak mnoho komponent ovlivněno a výběr nežádoucích je podstatně složitější.

Dalším problémem je výběr komponent. Pro správnou volnu nežádoucích komponent je potřeba jistá dávka zkušeností, pokud budeme uvažovat triviální úlohy (popsané pokusy), nebo je nutné experimentovat v případě složitých úloh.

Všechny představené problémy jsou navzájem pevně spjaty. Exaktní způsob aplikace algoritmů pro BSS zatím neexistuje a bude nutné všechny problémy velice podrobně analyzovat, aby bylo jednou možné používat algoritmy pro BSS adaptivně i pro velmi složité úlohy. Nicméně na část úloh, popsanych detailně v této kapitole, je již nyní aplikace těchto algoritmů velmi výhodná.

7 Závěr

Hlavní náplní této práce byla aplikace algoritmů pro slepou separaci dat, konkrétně algoritmů EFICA, WASOBI a MULTICOMBI, na reálná EKG data. Práce seznamuje se základními vlastnostmi elektrokardiogramu, jejichž znalost je nezbytná pro pozdější aplikaci těchto algoritmů. Dále byl v teoretické části práce popsán základní princip slepé separace signálů a některých jejích metod.

V práci byla stanovena přesná metodika, jak postupovat při realizaci jednotlivých pokusů, jakým způsobem data importovat, zobrazovat, předzpracovávat a jak konkrétně aplikovat algoritmy.

Bylo navrženo využití algoritmů pro BSS pro řešení úloh odstraňování šumu a třesu. Aplikací algoritmů lze dosáhnout vynikajících výsledků v úlohách, které byly podrobně popsány. Zvýšení čitelnosti v úlohách odstraňování šumu a třesu dokazuje velký potenciál těchto algoritmů. Na druhou stranu je třeba mít na paměti, že jejich aplikace na reálná EKG data v praxi přináší řadu problémů, které byly také popsány.

Při porovnání aplikovaných algoritmů EFICA, WASOBI a MULTICOMBI lze konstatovat, že jejich využití na reálných EKG záznamech je možné a jednotlivé algoritmy dosahují obdobných výsledků. Pro zlepšení diagnostiky EKG záznamů je výhodné využít pozorování výsledků všech jmenovaných algoritmů.

Navržené postupy pro aplikaci algoritmů slepé separace je možné využít v offline zpracování EKG záznamů.

8 Reference

KOLÁŘ J., KAUTZNER J. a kol. *Základy elektrokardiografie*. Praha: Nakladatelství AKCENTA, 2002. 144 s. ISBN 80-86232-04-2.

DOSTÁL J. *EKG*. FEL ČVUT, 2006. 40 slidů. Prezentace ve formátu PPT.

URL: <http://gerstner.felk.cvut.cz/biolab/X33BMI/referaty/2005_2006_LS/1100/Dostal%20Jiri/prezentace_ekg.ppt>

KOLDOVSKÝ Z. *Analýza nezávislých komponent v EEG datech*. FJFI ČVUT, 2002. 48 s. Diplomová práce.

URL: <<http://itakura.kes.vslib.cz/zbynek/pubs/diplomka.ps.gz>>

HAMAN P. *Základy EKG*. Plzeň. Výukový web EKG MUDr. Petra Hamana.

URL: <<http://ekg.kvalitne.cz/>>

HYVÄRINEN A., OJA E. *Independent Component Analysis: A Tutorial*. Helsinki University of Technology, 1999. Odborný text..

URL: <http://www.cis.hut.fi/aapo/papers/IJCNN99_tutorialweb/>

NOUZA J. *Zpracování, přenos a identifikace signálů*. ITE, FM, TU v Liberci. Přednášky z předmětu SIG..

URL: <http://www.ite.tul.cz/pages/sig/ramce_main.html>

Přílohy

A Funkce import_EKG_dat

```
function X=import_EKG_dat(xml_soubor)
xml_pom=xml_load(xml_soubor,'off');
for i=1:8
    s=xml_pom.patient.examination.ekgSignal(1,i).ekgWave;
    X(i,:)=sscanf(s,'%d');
end;
```

B Funkce zobraz

```
function zobraz(t,X,Offset,r,g,b)
poc=size(X);
pocet_signalu=poc(1);
hold on;
for i=1:pocet_signalu
    plot(t,X(i,:)+pocet_signalu*Offset+Offset-i*Offset,...
        'Color',[r(i) g(i) b(i)]);
end;
```

C Funkce filtr_isolinie

```
function filtrovana_data=filtr_isolinie(signal,Pocet)
s=fft(signal);
N=length(signal);
for i=0:Pocet-1
    s([i+1 N-i])=0;
end;
s=real(ifft(s));
signal=s;
filtrovana_data=signal;
```

D Funkce DPfiltr

```
function filtovana_data=DPfiltr(signal,Pocet)
s=fft(signal);
N=length(signal);
for i=0:Pocet-1
    s([N/2+i+1 N/2-i])=0;
end;
s1=real(ifft(s));
filtovana_data=s1;
```