

**Vysoká škola báňská – Technická univerzita Ostrava
Fakulta elektrotechniky a informatiky
Katedra kybernetiky a biomedicínského inženýrství**

**Komparativní studie využití adaptivních metod jako
součásti hybridního systému pro extrakci plodového EKG
signálu**

**Comparative Study of Adaptive Methods as a Part of
Hybrid System for Fetal ECG Signal Extraction**

2020

Bc. Martina Mikolášová

Zadání diplomové práce

Student: **Bc. Martina Mikolášová**

Studijní program: N2649 Elektrotechnika

Studijní obor: 3901T009 Biomedicínské inženýrství

Téma: **Komparativní studie využití adaptivních metod jako součásti hybridního systému pro extrakci plodového EKG signálu**
Comparative Study of Adaptive Methods as a Part of Hybrid System for Fetal ECG Signal Extraction

Jazyk vypracování: čeština

Zásady pro vypracování:

Diplomová práce se zaměřuje na možnosti využití adaptivních metod jako součásti hybridního systému pro extrakci plodového EKG signálu výhradně z abdominálních signálů. Cílem práce je detailní rozbor metod extrakce mateřské komponenty z abdominálních signálů a její následné použití jako vstupu (reference) pro adaptivní metody za účelem extrakce plodové komponenty. Cílem diplomové práce je návrh a realizace systému pro extrakci plodového EKG z abdominálních signálů s využitím výhod jak adaptivních, tak neadaptivních metod, tj. hybridní přístup. Dalším krokem je ověření funkčnosti navrženého systému na reálných datech z klinické praxe.

Postup řešení

1. Literární rešerše současného stavu problematiky využití výhod koncepce adaptivní filtrace na signálech zaznamenaných neinvazivně pouze v abdominální oblasti. Detailní rozbor metod extrakce mateřské komponenty mEKG z abdominálních záznamů aEKG (např. metody PCA, ICA apod.). Podrobný popis adaptivních metod extrakce fEKG, kde bude jako vstupní (referenční) signál využit mEKG signál odhadnutý z aEKG, který bude představovat vstupní (primární) signál (např. ADALINE, ANFIS, LMS, RLS apod.).
2. Návrh a softwarová realizace systému pro testování extrakce plodového elektrokardiogramu z transabdominálního záznamu s využitím hybridních metod. Budou implantovány vybrané metody na základě literární rešerše.
3. Ověření funkčnosti navrženého systému na reálných záznamech z klinické praxe z pohledu stanovení tepové frekvence plodu a morfologické analýzy.
4. Porovnání vlastností vybraných metod extrakce fEKG.
5. Diskuze dosažených výsledků

Seznam doporučené odborné literatury:

- [1] JAROŠ, René, Radek MARTINEK a Radana KAHÁNKOVÁ. Non-adaptive methods for fetal ECG signal processing: A review and appraisal [online]. 2018 [cit. 2019-10-18]. *Sensors*, 18(11), 3648. DOI: 10.3390/s18113648. ISSN 1424-8220.
- [2] MARTINEK, Radek, Radana KAHANKOVA, Janusz JEZEWSKI, Rene JAROS, Jitka MOHYLOVA, Marcel FAJKUS, Jan NEDOMA, Petr JANKŮ a Homer NAZERAN. Comparative Effectiveness of ICA and PCA in Extraction of Fetal ECG From Abdominal Signals: Toward Non-invasive Fetal Monitoring. *Frontiers in Physiology*, Lausanne: Frontiers Media, 2018, roč. 9, č. 648, s. 1-25. ISSN 1664-042X. doi: 10.3389/fphys.2018.00648.

- [3] SAMENI, Reza a Gary D. CLIFFORD. A review of fetal ECG signal processing; issues and promising directions. *The open pacing, electrophysiology & therapy journal*. 2010. 3(1), 4-20. ISSN 1876-536X. doi: 10.2174/1876536X01003010004.
- [4] CLIFFORD, Gary D., Ikaro SILVA, Joachim BEHAR a George B. MOODY. Non-invasive fetal ECG analysis. *Physiological measurement*. 2014, 35(8), 1521-1536. ISSN 0967-3334. doi: 10.1088/0967-3334/35/8/1521.
- [5] JAROS, Rene, Radek MARTINEK, Radana KAHANKOVA a Jiri KOZIOREK. Novel Hybrid Extraction Systems for Fetal Heart Rate Variability Monitoring Based on Non-Invasive Fetal Electrocardiogram. *IEEE Access*. 2019, vol.7, 131758-131784. ISSN 2169-3536. DOI: 10.1109/ACCESS.2019.2933717.
- [6] KAHANKOVA, R., R. MARTINEK, R. JAROS, K. BEHBEHANI, A. MATONIA, M. JEZEWSKI a J.A. BEHAR. A Review of Signal Processing Techniques for Non-Invasive Fetal Electrocardiography. *IEEE Reviews in Biomedical Engineering* 2019. ISSN 1937-3333. doi: 10.1109/RBME.2019.2938061.

Formální náležitosti a rozsah diplomové práce stanoví pokyny pro vypracování zveřejněné na webových stránkách fakulty.

Vedoucí diplomové práce: **doc. Ing. Radek Martinek, Ph.D.**

Konzultant diplomové práce: Ing. Radana Kahánková

Datum zadání: 01.09.2019

Datum odevzdání: 30.04.2020



doc. Ing. Jiří Koziolek, Ph.D.
vedoucí katedry



prof. Ing. Pavel Brandštetter, CSc.
děkan fakulty

Prohlášení studenta

Prohlašuji, že jsem tuto diplomovou práci vypracovala samostatně. Uvedla jsem všechny literární prameny a publikace, ze kterých jsem čerpala.

V Ostravě dne: 15. května 2020

A handwritten signature in blue ink, appearing to read 'Luc Kolašová', written over a horizontal dotted line.

podpis studenta

Poděkování

Ráda bych poděkovala mému vedoucímu, panu doc. Ing. Radku Martinkovi, Ph.D. za odbornou pomoc a konzultace při vytváření této diplomové práce. Dále bych chtěla poděkovat Ing. Radaně Kahánkové, Ph.D. za cenné rady, poskytnuté materiály a čas strávený nad danou problematikou. V neposlední řadě patří poděkování také mé rodině a přátelům za pomoc a podporu.

Abstrakt

Hlavním cílem této diplomové práce je extrakce plodového EKG signálu výhradně z abdominálních signálů (aEKG) snímaných neinvazivně, transabdominálně, pomocí elektrod umístěných na břicho matky. Signál aEKG v sobě obsahuje nejen plodovou, ale také mateřskou komponentu EKG (mEKG) a další rušivé signály. Teoretická část práce se věnuje současnému stavu této problematiky, popisu metod využívajících se k monitoraci plodu v klinické praxi a klasifikací vybraných metod a jejich matematickému rozboru. Dále se práce zaměřuje na návrh a realizaci hybridního systému, který k extrakci fEKG signálu využívá kombinace neadaptivních a adaptivních metod. Hodnocení kvality filtrace je provedeno na základě statistických parametrů ACC a F1 a také na základě stanovení variability tepové frekvence plodu (fHR). Ověření funkčnosti navrženého algoritmu bylo provedeno na reálných datech z klinické praxe a také na datech měřených přímo v laboratoři.

Klíčová slova

Plodový elektrokardiogram, neinvazivní monitorace plodu, hybridní algoritmus, extrakce EKG signálu, analýza nezávislých komponent (ICA), LMS, NLMS, BLMS, ADALINE (adaptivní lineární neuron).

Abstract

The main goal of this diploma thesis is the extraction of the fetal ECG signal exclusively from abdominal signals (aECG) scanned non-invasively by transabdominal method, using electrodes placed on the mother's abdomen. The aECG signal contains not only the fetal but also the maternal component of the ECG (mECG) and other interfering signals. The theoretical part of the work deals with the current state of this issue, a description of methods used to monitor the fetus in clinical practice and the classification of selected methods and their mathematical analysis. Furthermore, the work focuses on the design and implementation of a hybrid system that uses a combination of non-adaptive and adaptive methods to extract the fECG signal. Evaluation of filtration quality is performed on the basis of statistical parameters ACC and F1 and also on the basis of determination of fetal heart rate variability (fHR). Verification of the functionality of the proposed algorithm was performed on real data from clinical practice and also on data measured directly in the laboratory.

Key words

Fetal electrocardiogram, non-invasive fetal monitoring, hybrid algorithm, ECG extraction, Independent Component Analysis (ICA), LMS, NLMS, BLMS, ADALINE (Adaptive Linear Neuron).

Obsah

Seznam použitých zkratk	10
Seznam použitých symbolů	12
Seznam obrázků	14
Seznam tabulek	17
Úvod	19
1 Monitorace plodu v klinické praxi	21
1.1 Kardiotokografie	22
1.2 Fetální echokardiografie	23
1.3 Fetální elektrokardiografie	23
1.4 Magnetokardiografie	24
1.5 Fonokardiografie	24
1.6 Fetální pulsní oxymetrie	25
1.7 Měření pH krve plodu	25
1.8 Shrnutí nejpoužívanějších metod pro EFM	25
2 Elektrokardiografie plodu	27
2.1 Vznik a analýza fEKG signálu	27
2.2 Rušení v EKG signálu	29
3 Metody pro extrakci plodového EKG	31
3.1 Přehled neadaptivních metod pro extrakci fEKG signálu	31
3.1.1 Metody využívající vlnkové transformace	31
3.1.2 Korelační metody	32
3.1.3 Průměrovací techniky	32
3.1.4 Filtrační techniky	33
3.1.5 Slepá separace zdrojů (BSS)	33
3.1.6 ICA	34
3.1.7 PCA	34
3.2 Přehled adaptivních metod pro extrakci fEKG signálu	35
3.2.1 Adaptivní filtr	35

3.2.2	Adaptivní metody	36
4	Matematický popis vybraných metod	42
4.1	Vlnková transformace	42
4.2	Analýza nezávislých komponent	44
4.3	LMS	45
4.3.1	NLMS	47
4.3.2	BLMS	47
4.3.3	DLMS	48
4.4	RLS	48
4.5	ADALINE	49
4.6	ANFIS	51
5	Experimentální část	53
5.1	Testovaná data	53
5.2	Statistická analýza	54
5.3	Návrh hybridního algoritmu	55
5.3.1	Kombinace elektrod vstupujících do hybridního algoritmu	57
5.4	Optimalizace nastavení extrakčního adaptivního systému	59
5.4.1	Optimalizace parametrů metody LMS	60
5.4.2	Optimalizace parametrů metody BLMS	63
5.4.3	Optimalizace parametrů metody NLMS	67
5.4.4	Optimalizace parametrů metody ADALINE	70
5.5	Statistické vyhodnocení dosažených výsledků	73
5.5.1	LMS	74
5.5.2	BLMS	77
5.5.3	NLMS	80
5.5.4	ADALINE	83
6	Provádění experimentů na datech z databáze Challenge 2013	87
6.1	Kombinace elektrod vstupujících do ICA	87
6.2	Optimalizace parametrů filtru	88

6.3	<i>Statistická analýza a hodnocení dosažených výsledků</i>	91
7	Provádění experimentů na reálných datech z laboratoře	96
8	Diskuse dosažených výsledků	99
	Závěr	104
	Použitá literatura	105
	Seznam příloh	I
	Příloha A	I
	Příloha B	VII
	Příloha CD	XV

Seznam použitých zkratek

Zkratka	Význam
AA	Adaptivní algoritmus
ACC	Přesnost filtru, pravděpodobnost správné detekce (Accuracy)
ADALINE	Extrakční metoda využívající adaptivní lineární neuron (Adaptive Linear Neuron)
ADFECGDB	Databáze abdominálních a invazivních EKG signálů plodu
ANFIS	Adaptivní neuro-fuzzy interferenční systém
AVF	Adaptivní Voltera Filtr
AT	Metoda průměrování (Averaging techniques)
bpm	Počet tepů za minutu (Beats per minute)
BLMS	Blokový LMS algoritmus (Block LMS)
BS	Velikost bloku (parametr metody BLMS)
BSS	Slepá separace zdrojů (Blind Source Separation)
CCWT	Komplexní spojitá vlnková transformace
CWT	Spojitá vlnková transformace (Continuous Wavelet Transform)
DLMS	Zpožděný LMS algoritmus (Delay LMS)
DWT	Diskrétní vlnková transformace (Discrete Wavelet Transform)
EFM	Elektronické monitorování plodového srdce (Electronic Fetal Monitoring)
ECHO	Ultrazvukové vyšetření srdce (Echokardiografie)
EKF	Rozšířený Kalmanův filtr (Extended Kalman Filter)
EKG	Elektrokardiografie
F1	Celková přesnost metody (F1 score)
fEKG	Fetální elektrokardiogram
fEKG*	Odhadnutý Fetální elektrokardiogram metodou ICA, která obsahuje i matřskou komponentu
fHR	Plodová tepová frekvence (Fetal Heart Rate)
FIR	Filtr s konečnou impulzní odezvou (Finite Impulse Response)
FN	Falešně negativní detekce (False Negative)
FP	Falešně pozitivní detekce (False Positive)
FT	Fourierova transformace (Fourier Transform)
GA	Genetický algoritmus (Genetic Algorithm)
HA	Hybridní algoritmus
ICA	Analýza nezávislých komponent (Independent Component Analysis)
IFPO	Intrapartální fetální pulzní oxymetrie (Intrathecal Fetal Pulse Oximetry)

Seznam použitých zkratk

IIR	Filtr s nekonečnou impulzní odezvou (Infinite Impulse Response)
KTG	Kardiotokografie
LMS	Metoda odhadu s minimálními středními kvadratickými odchylkami (Least Mean Square)
mEKG	Mateřský elektrokardiogram
mEKG*	Odhadnutý Mateřský elektrokardiogram metodou ICA
MKG	Magnetokardiografie
NLMS	Normalizovaný LMS algoritmus (Normalized LMS)
PCA	Analýza hlavních komponent (Principal Component Analysis)
PKG	Fonokardiografie (Phonocardiography)
PPV	Pozitivní prediktivní hodnota (Positive Predictive Value)
RLS	Metody založené na rekurzivní optimální adaptaci (Recursive Least Square)
SE	Senzitivita (Sensitivity)
SNR	Odstup signálu od šumu (Signal to Noise Ratio)
SVD	Singulární rozklad spektrogramu (Singular Value Decomposition)
STAN	Analýza ST úseku fEKG (ST Segment Analysis)
TP	Správná detekce (True Positive)
WT	Metoda vlnkové transformace (Wavelet Transform)

Seznam použitých symbolů

Symbol	Význam symbolu
A	Směšovací matice algoritmu ICA
c_A	Aproximační koeficient metody DWT
c_D	Detailní koeficient metody DWT
D	Celkové zpoždění zpětné vazby metody DLMS
$d(n)$	Požadovaný signál
$e(n)$	Chybový signál
$E\{x\}$	Střední hodnota signálu
k	Translace na diskretní mřížce u metody DWT
$k(n)$	Vektor koeficientu filtru
m	Počet pozorovaných signálů
M	Délka filtru
n	Počet zdrojových signálů
p	Dilatace na diskretní mřížce u metody DWT
p	Dimenzionalita vstupu u metody ADALINE
$P(n)$	Inverzní korelační matice vstupního signálu
θ	Speciální vstup připojený na prahovou hodnotu signálu
s	Parametr pro změnu šířky mateřské vlnky metody WT
s	Původní neznámý multivariační zdroj signálu
S	Přenosová funkce
$s(t)$	Zdrojový (vstupní) signál u metody WT
W	Lineární nesmíšená matice (inverzní matici A)
$w(n)$	Váhový vektor
x	Multivariační pozorovaný signál u metody ICA
\tilde{x}	Vybělený vektor metody ICA
$x(n)$	Vstupní vektor filtru
x_c	Centrovaný vektor u metody ICA
y	Vektor odhadu neznámých komponent
$y(n)$	Výstupní signál filtru

Seznam použitých symbolů

γ	Zapomenutý faktor v rozmezí 0 až 1
δ	Regulační faktor
η	Míra učení
μ	Velikost kroku adaptivního filtru
τ	Parametr pro změnu umístění vlnky na časové ose algoritmu WT
ψ	Mateřská vlnka algoritmu WT

Seznam obrázků

Obr. 1: Dělení metod monitorace plodu.....	22
Obr. 2: Měření KTG.	23
Obr. 3: Bifázický tvar vlny ST segmentu s progresivní fetální hypoxií.	24
Obr. 4: Měření saturace oxyhemoglobinu pomocí padlike senzoru.....	25
Obr. 5: Průběh převodního systému srdečního.	28
Obr. 6: Ideální průběh EKG signálu.	29
Obr. 7: Obecná struktura adaptivního filtru (podle [44]).	36
Obr. 8: Možná kombinace metod pro hybridní algoritmus.....	42
Obr. 9: Schéma principu DWT (podle [70]).	43
Obr. 10: Schéma 3stupňového multirozkladu.....	44
Obr. 11: Schéma metody ICA.....	45
Obr. 12: Hledání minima střední kvadratické chyby.	46
Obr. 13: Obecné schéma perceptronu.	49
Obr. 14: Obecné schéma metody ADALINE.	50
Obr. 15: Struktura systému ANFIS.....	51
Obr. 16: Ukázka aEKG signálu, referenčního signálu a rozmístění elektrod pro záznam r01. ..	53
Obr. 17: Návrh hybridního algoritmu.	55
Obr. 18: Rozklad signálu pomocí metody ICA.....	56
Obr. 19: Hodnoty parametru ACC pro všechny kombinace elektrod záznamu r01.	58
Obr. 20: Hledání rozsahu metody LMS – krok 1.....	60
Obr. 21: Hledání rozsahu metody LMS – krok 2.....	61
Obr. 22: Hledání vhodného nastavení parametrů metody BLMS – BS=5.....	64
Obr. 23: Hledání vhodného nastavení parametrů metody BLMS – BS=25.....	64
Obr. 24: Rozšíření prohledávané oblasti pro záznam r03, r04, r06 a r07.	65
Obr. 25: Hledání rozsahu metody NLMS – krok 1.....	68
Obr. 26: Optimální rozsah parametrů pro záznam r0, r03, r04 a r07.....	71
Obr. 27: Testovaný HA využívající metodu LMS.....	74
Obr. 28: Porovnání vstupního a výstupního signálu spolu se signálem fEKG snímaným pomocí skalповé elektrody (záznam r01).	75
Obr. 29: Amplitudové spektrum vstupního a výstupního signálu pro záznam r01.....	75
Obr. 30: Porovnání průběhů fHR pro záznam r01 (metoda LMS).	76
Obr. 31: Testovaný HA využívající metodu BLMS.	Chyba! Záložka není definována.

Obr. 32: Porovnání vstupního a výstupního signálu spolu se signálem fEKG snímaným pomocí skalpové elektrody (záznam r01).	78
Obr. 33: Amplitudové spektrum vstupního a výstupního signálu pro záznam r01.....	79
Obr. 34: Porovnání průběhů fHR pro záznam r01 (metoda BLMS).....	80
Obr. 35: Testovaný HA využívající metodu NLMS.	81
Obr. 36: Porovnání vstupního a výstupního signálu spolu se signálem fEKG snímaným pomocí skalpové elektrody (záznam r01).	81
Obr. 37: Amplitudové spektrum vstupního a výstupního signálu pro záznam r01.....	82
Obr. 38: Porovnání průběhů fHR pro záznam r01 (metoda NLMS).....	82
Obr. 39: Testovaný HA využívající metodu ADALINE.	84
Obr. 40: Porovnání vstupního a výstupního signálu spolu se signálem fEKG snímaným pomocí skalpové elektrody (záznam r01).	84
Obr. 41: Amplitudové spektrum vstupního a výstupního signálu pro záznam r01.....	85
Obr. 42: Porovnání průběhů fHR pro záznam r01 (metoda ADALINE).....	85
Obr. 43: Porovnání vstupního a výstupních signálů pro 6 signálů s nejlepším výsledkem.	93
Obr. 44: Porovnání vstupních signálů snímaných z povrchu břišní stěny matky (aEKG1 – aEKG4) s výstupem metody ICA (fEKG* a mEKG).....	94
Obr. 45: Blokové schéma hybridního algoritmu, který jako referenční signál využívá záznam z KTG.....	96
Obr. 46: Porovnání trendů signálu fHR získaného pomocí KTG se signálem fHR stanoveného z extrahovaného fEKG signálu pomocí HA systému využívající metodu ADALINE (nastavení: $p=20$, $\eta=0,004$).	97
Obr. 47: Porovnání trendů signálu fHR získaného pomocí KTG se signálem fHR stanoveného z extrahovaného fEKG signálu pomocí HA systému využívající metodu LMS (nastavení: $M=20$, $\mu=0,004$).	97
Obr. 48: Porovnání trendů signálu fHR získaného pomocí KTG se signálem fHR stanoveného z extrahovaného fEKG signálu pomocí HA systému využívající metodu NLMS (nastavení: $M=250$, $\mu=0,001$).	98
Obr. 49: Porovnání trendů signálu fHR získaného pomocí KTG se signálem fHR stanoveného z extrahovaného fEKG signálu pomocí HA systému využívající metodu BLMS (nastavení: $M=20$, $\mu=0,001$).	98
Obr. 50: Porovnání vstupních a odhadovaných signálů pro 6 vybraných záznamů z Datasetu A.	100
Obr. 51: Porovnání průběhů; fHR referenčního a extrahovaných signálů pro tři zvolené záznamy.	101

Obr. 52: Hledání optimálního nastavené parametrů metody LMS (krok 1) – nastavení: $M=0-1000$, $\mu=0,001-0,1$	VIII
Obr. 53: Hledání optimálního nastavené parametrů metody LMS (krok 2) – nastavení: $M=0-100$, $\mu=0,001-0,1$	IX
Obr. 54: Hledání optimálního nastavené parametrů metody NLMS – nastavení: $M=0-100$, $\mu=0,001-0,1$	X
Obr. 55: Hledání optimálního nastavené parametrů metody NLMS – nastavení: $M=0-200$, $\mu=0,001-0,1$	XI
Obr. 56: Hledání optimálního nastavené parametrů metody BLMS – nastavení: $M=0-100$, $\mu=0,001-0,1$, $BS=5$	XII
Obr. 57: Hledání optimálního nastavené parametrů metody BLMS – nastavení: $M=0-100$, $\mu=0,001-0,1$, $BS=25$	XIII
Obr. 58: Hledání optimálního nastavené parametrů metody ADALINE – nastavení: $p=0-100$, $\eta=0,001-0,1$	XIV

Seznam tabulek

Tab. 1: Shrnutí nejpoužívanějších metod pro elektronické monitorování plodu [16].....	26
Tab. 2: Přehled dat využitých k prováděným experimentům.....	54
Tab. 3: Výsledky statistických parametrů pro každou z kombinací elektrod pro záznam r01....	57
Tab. 4: Stanovení hodnoty ACC pro každou z kombinací elektrod pro všech deset záznamů... 58	
Tab. 5: Shrnutí kombinací elektrod pro každý záznam.....	59
Tab. 6: Přehled parametrů jednotlivých metod.....	59
Tab. 7: Zúžení rozsahu parametrů ovlivňujících kvalitu filtrace.....	61
Tab. 8: Optimální nastavení parametrů pro algoritmus LMS.....	62
Tab. 9: Konečné nastavení parametrů M a μ pro jednotlivé záznamy – LMS.....	63
Tab. 10: Optimální nastavení parametrů pro algoritmus BLMS.....	66
Tab. 11: Konečné nastavení parametrů M a μ pro jednotlivé záznamy – BLMS.....	67
Tab. 12: Úprava rozsahu parametrů M a μ pro každý záznam.....	68
Tab. 13: Optimální nastavení parametrů pro algoritmus NLMS.....	69
Tab. 14: Konečné nastavení parametrů M a μ pro jednotlivé záznamy – NLMS.....	69
Tab. 15: Porovnání výsledků jednotlivých testovaných algoritmů.....	70
Tab. 16: Úprava pracovní oblasti parametru η	71
Tab. 17: Optimální nastavení parametrů pro algoritmus ADALINE.....	72
Tab. 18: Konečné nastavení parametrů při testování metody ADALINE.....	73
Tab. 19: Statistické hodnocení navrženého HA při použití metody LMS.....	77
Tab. 20: Statistické hodnocení navrženého HA při použití metody BLMS.....	79
Tab. 21: Statistické hodnocení navrženého HA při použití metody NLMS.....	83
Tab. 22: Statistické hodnocení navrženého HA při použití metody ADALINE.....	86
Tab. 23: Shrnutí kombinací elektrod pro jednotlivé záznamy.....	87
Tab. 24: Optimální nastavení parametrů pro algoritmus LMS.....	88
Tab. 25: Optimální nastavení parametrů pro algoritmus BLMS.....	89
Tab. 26: Optimální nastavení parametrů pro algoritmus NLMS.....	90
Tab. 27: Optimální nastavení parametrů pro algoritmus ADALINE.....	91
Tab. 28: Shrnutí nejlepších výsledků pro všechny testované algoritmy.....	92
Tab. 29: Porovnání výsledků parametru F1 pro všechny testované kombinace metod.....	99
Tab. 30: Shrnutí výsledků prováděných experimentů uvedených ve studii [84].....	102
Tab. 31: Shrnutí výsledků prováděných experimentů uvedených ve studii[85].....	102
Tab. 32: Shrnutí výsledků prováděných experimentů uvedených ve studii [86].....	102
Tab. 33 Shrnutí výsledků prováděných experimentů uvedených v této práci.....	103

Seznam tabulek

Tab. 34: Výsledky statistických parametrů pro každou z kombinací elektrod pro záznam r01..... I

Tab. 35: Výsledky statistických parametrů pro každou z kombinací elektrod pro záznam r02....II

Tab. 36: Výsledky statistických parametrů pro každou z kombinací elektrod pro záznam r03...II

Tab. 37: Výsledky statistických parametrů pro každou z kombinací elektrod pro záznam r04.. III

Tab. 38: Výsledky statistických parametrů pro každou z kombinací elektrod pro záznam r05.. III

Tab. 39: Výsledky statistických parametrů pro každou z kombinací elektrod pro záznam r06.. IV

Tab. 40: Výsledky statistických parametrů pro každou z kombinací elektrod pro záznam r07.. IV

Tab. 41: Výsledky statistických parametrů pro každou z kombinací elektrod pro záznam r08....V

Tab. 42: Výsledky statistických parametrů pro každou z kombinací elektrod pro záznam r09....V

Tab. 43: Výsledky statistických parametrů pro každou z kombinací elektrod pro záznam r10.. VI

Úvod

Diplomová práce se zaměřuje na možnosti využití adaptivních metod jako součásti hybridního systému pro extrakci fEKG signálu z abdominálního záznamu. Tato práce se dále zabývá rozborem a popisem dané problematiky, zejména pak klasifikací metod vhodných nejen pro extrakci plodové, ale také mateřské komponenty. Cílem práce je pak návrh a následná realizace hybridního systému pro získání plodového fEKG signálu, který kombinuje výhody neadaptivních i adaptivních metod. Ověření funkcionality navrženého systému je provedeno na reálných datech z klinické praxe.

Elektrokardiografie plodu (dále jen fEKG) v současné době patří mezi velice využívané metody sledující elektrickou aktivitu plodového srdce. Obecně nám tato metoda poskytuje velice důležité informace o zdravotním stavu plodu, jakými jsou zejména: morfologie EKG křivky a srdeční tepová frekvence. Signál fEKG lze snímat buďto, invazivní nebo neinvazivní cestou. Monitorování fEKG invazivně skalpovou elektrodou je nejpřesnější způsob, jak potřebné informace získat. Nese s sebou však několik omezení, jako je zejména provádění měření až po odtoku plodové vody (tedy v průběhu porodu), neumožňuje tedy kontinuální monitoring v celém průběhu těhotenství. Navíc může být toto měření pro matku dosti nepohodlné a z důvodu invazivity hrozí pro plod nebezpečí zavlečení infekce.

Oproti tomu neinvazivní plodová elektrokardiografie zaznamenává elektrické potenciály z mateřského břicha. Získávají se tak signály, které obsahují jak mateřskou, tak i plodovou komponentu EKG spolu s velkým množstvím nežádoucího rušení. Signály snímány transabdominální se ale překrývají v časové i ve frekvenční oblasti. Proto je přesná extrakce fEKG signálu poměrně náročná. Pro zpracování tohoto signálu se využívají neadaptivní nebo adaptivní filtrační metody. Tato diplomová práce je zaměřena na využití jejich kombinace.

Práce je rozdělena dvě části, a to na teoretickou a experimentální část. Teoretická část shrnuje veškeré poznatky týkající se dané problematiky a má charakter literární rešerše. První kapitola je zaměřena na popis a klasifikaci metod, které se v klinické praxi využívají k monitoraci plodu. Především jsou zde popsány metody elektronického monitorování plodu (EFM), jako jsou např. KTG, neinvazivní, ale také invazivní fEKG, fPKG a další. V závěru první kapitoly jsou diskutovány rovněž výhody a nevýhody metod EFM.

Další kapitola se věnuje fetální elektrokardiografii. Je zde popsán vznik EKG signálu, převodní systém srdeční, dále je zde popsána analýza fEKG signálu a artefakty, které mohou neinvazivně snímáný fEKG signál ovlivňovat. Následuje kapitola věnující se metodám pro extrakci fEKG signálu. V této kapitole je nejprve vysvětlen rozdíl mezi neadaptivními a adaptivními metodami. Dále jsou zde, formou literární rešerše, shrnuty dostupné odborné publikace zabývající se zkoumanou problematikou, představeny jednotlivé adaptivní i neadaptivní algoritmy. Následuje matematický popis vybraných metod, který zakončuje celou teoretickou část.

Experimentální část práce se zabývá návrhem a následnou softwarovou realizací hybridního systému pro extrakci fEKG ze signálu aEKG snímaného pomocí elektrod umístěných na povrchu břišní stěny matky. Hybridní systém je takový systém, ve kterém se využívá kombinace dvou a více filtračních metod. V této práci byla využita kombinace neadaptivní metody ICA a jedné z adaptivních metod, a to LMS, BLMS, NLMS nebo ADALINE. Celkem tedy vznikly čtyři kombinace metod pro hybridní systém, které byly dále testovány na dvou skupinách reálných dat z klinické praxe a jedné skupiny, která obsahuje data aEKG snímaná na reálných subjektech přímo v laboratoři. Hodnocení kvality dosažených

výsledků je provedeno subjektivně na základě porovnání časových průběhů signálu před vstupem do hybridního algoritmu a signálu po filtraci a následně objektivně na základě výsledných hodnot statistických parametrů. Dále je hodnocení provedeno také na základě stanovení průběhů variabilit tepové frekvence plodu. Dosažené výsledky na všech třech testovaných skupinách dat a pro každou ze čtyř testovaných kombinací metod budou diskutovány v poslední kapitole.

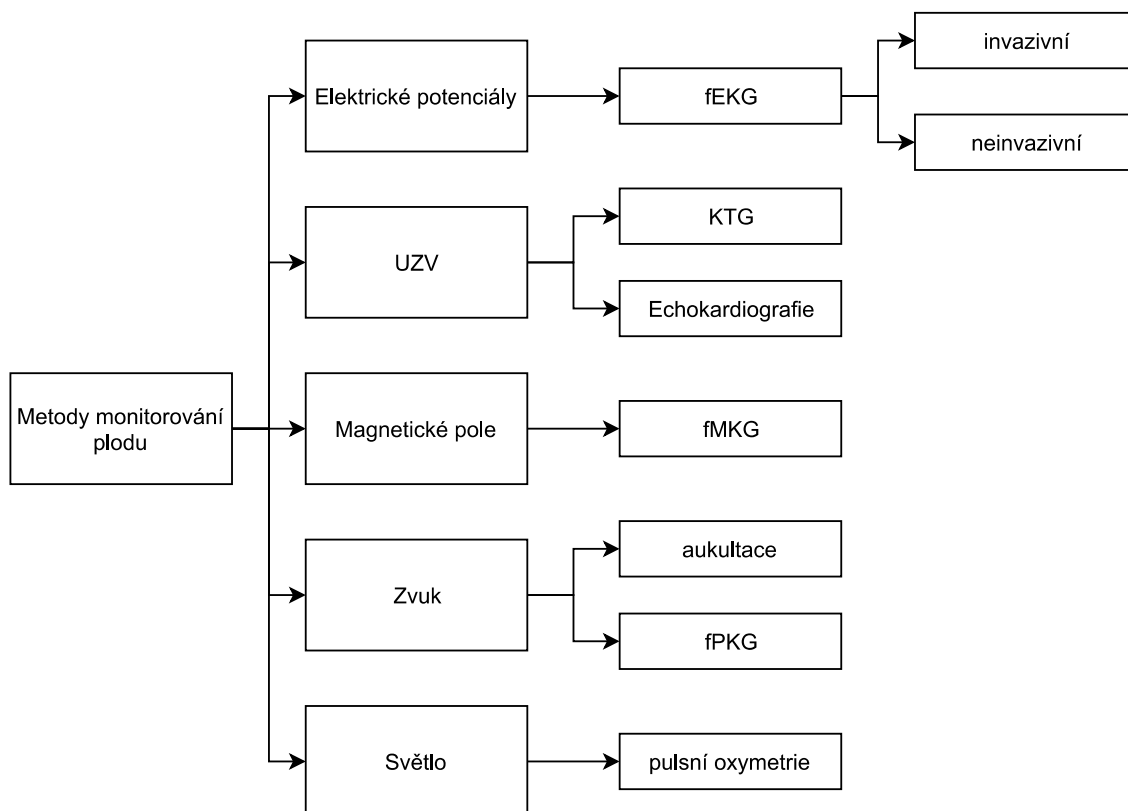
1 Monitorace plodu v klinické praxi

Elektronické monitorování plodu (Electronic fetal monitoring, EFM) bylo do praxe zavedeno koncem 60. let 20. století jako součást diagnostiky hypoxických stavů plodu během porodu. Do této doby probíhala kontrola plodu na základě periodické auskultace pomocí stetoskopu. Nástup EFM umožnil kontinuální zobrazení srdeční frekvence plodu a hodnocení patofyziologických událostí, které mohou zdraví plodu negativně ovlivnit, při morfologické analýze fEKG záznamu. Krátce po zavedení bylo elektronické monitorování srdeční frekvence plodu využíváno především u komplikovaných těhotenství. Rychle však došlo k jeho rozvoji.

Nejčastějšími problémy, které lze z fEKG zaznamenat, jsou hypoxémie, hypoxie a asfyxie. Tyto tři pojmy představují různé stupně poklesu saturace kyslíku v arteriální krvi plodu [1], [2].

- **Hypoxémie** je nejnižší stupeň poklesu O_2 v arteriální krvi. Plod se tomuto stavu brání zejména zpomalením růstu a pohybu. Funkce vnitřních orgánů není narušena a energetická rovnováha zůstává zachována [2].
- **Hypoxie** je druhý, vyšší stupeň, kdy dochází k dalšímu poklesu O_2 v arteriální krvi. Plod se brání centralizací oběhu, tzn., že kyslíkem jsou zásobeny pouze životně důležité orgány (mozek a srdce). Tento stav je možno zvládat pouze několik hodin [2].
- **Asfyxie** je třetí, kritický stupeň, kdy pokles O_2 je tak výrazný, že nestačí k zásobě ani životně důležitých orgánů. Tento stav je možno zvládat pouze několik minut [2].

Tato kapitola se dále zaměřuje na popis možných metod, které se v klinické praxi k těmto účelům využívají. Monitorování lze provádět dvěma způsoby, a to snímáním na vnější straně břicha (externí monitorování), nebo přímo na dítěti, v průběhu porodu prostřednictvím speciální elektrody (interní monitorování). Metody lze obecně rozdělit podle mnoha kritérií. Jedním z nich je např. dělení metod podle fyzikálního principu, který metoda využívá pro získání určité veličiny [3]. Rozdělení metod pro monitoraci plodu je zobrazeno na Obr. 1.




Obr. 1: Dělení metod monitorace plodu.

1.1 Kardiotokografie

Kardiotokografie (KTG) umožňuje grafické zaznamenání kontrakcí dělohy a srdeční frekvence plodu pomocí kardiotokografu. Zobrazení fHR a jejich změn závislých a kontrakční činnosti a pohybech plodu umožňuje získat důležité informace, které jsou pro porodníka nezbytné nejen v průběhu porodu, ale také během těhotenství.

Kardiotokograf se skládá ze záznamového zařízení a dvou sond (toko- a kardio-sondy). Princip měření KTG je naznačen na Obr. 2. Tokosonda obsahuje piezoelektrický krystal a slouží k zaznamenání děložních kontrakcí. Při děložních kontrakcích dochází přenosem tlaku k deformaci krystalu v sondě a díky tomu k zaznamenání délky a síly kontrakce. Sonda se umísťuje v místě fundu děložního a fixuje se na povrch břicha matky pomocí pružného pásu tak, aby byla pevně připevněna, ale zároveň aby rodičku co nejméně omezovala. Kardiosonda slouží k záznamu plodové srdeční frekvence. Současné kardiotokografy obsahují dva typy sond. První druh vychází z principu fetální elektrokardiografie. Jedná se o skalpovou elektrodu, která se upevňuje na hlavičku plodu. Použití této sondy je omezeno protržením plodových blan a odtokem plodové vody. Druhý typ sondy pracuje na principu Dopplerova ultrazvuku. Zaznamenává tahy srdečních chlopní. Aby byl záznam fHR co nepřesnější, je potřeba sondu upevnit tak, aby srdce plodu bylo v ohnisku ultrazvukových vln. To závisí na poloze plodu v děloze.



Obr. 2: Měření KTG.

Nevýhodou KTG je vysoká citlivost na pohyb plodu a matky, dále kvalita získaného signálu závisí na vzdálenosti mezi snímačem a zdrojem signálu. Navíc, jelikož jsou oba senzory připevněny na břicho matky prostřednictvím elastických páسů, je pohyb matky poměrně omezen.

1.2 Fetální echokardiografie

Je neinvazivní metoda založena na Dopplerově ultrazvuku, kdy dochází ke snímání akustických vln odražených od povrchu plodového srdce. Dokáže odhalit vrozené srdeční vady, které jsou jednou z nejčastějších vrozených vad a často odhalují mnohem složitější genetické vady. Tato metoda se využívá při hodnocení anatomie a při diagnostice zdravotních obtíží plodu [4].

1.3 Fetální elektrokardiografie


V roce 1901 Einthoven poprvé popsal použití strunového galvanometru k detekci přítomnosti elektrické aktivity na dospělém srdci. O pouhých pět let později (1906) M. Cramer poprvé identifikoval fKEG z kombinace měření pomocí abdominálních a vaginálních elektrod [5], [6].

Existují dvě skupiny metod záznamu fEKG, a to invazivní a neinvazivní metody. Při invazivním snímání se využívá speciální elektrody (např. Skalповé – spirální intradermální elektrody), která se upevňuje přímo na povrch hlavičky plodu. Z tohoto důvodu může být tento způsob měření využit pouze v průběhu porodu, jelikož je nutné narušení plodových obalů a odtok plodové vody. Interní monitorování poskytuje přesnější a konzistentnější přenos signálu než externí monitorování, protože některé rušivé faktory, jako jsou např. myopotenciály, na něj nemají vliv. Interní monitorování může být použito v případě, že externí monitorování plodu není dostatečné nebo je nutný přísnější dohled [6], [7].

Pro neinvazivní snímání fEKG se využívá elektrod umístěných na povrchu břišní stěny matky. Signál zaznamenaný z abdominálního svodu se skládá ze směsi fEKG signálu, mEKG a šumu. Kromě toho je amplituda mateřského signálu obvykle mnohem silnější než fetální signál. Extrakce klinicky

významných rysů je proto poměrně náročná. Řada vědců se však zaměřuje na nalezení nejlepší metody pro extrakci signálu fEKG.

Z fEKG signálu lze jednak určit tepovou frekvenci plodu (z R-R intervalu) a dále lze z jeho morfologie určit potenciální riziko hypoxie. Jak se fetální hypoxie zhoršuje, dochází postupně ke změnám v T-vlně a ST segmentu fEKG signálu. Podstatou této technologie je, že srdce plodu, který je vystavený hypoxémii, vyvíjí zvýšený segment ST s progresivním vzestupem výšky T-vlny, který lze vyjádřit jako poměr T:QRS. Předpokládá se, že rostoucí poměry T:QRS odrážejí fetální srdeční schopnost přizpůsobit se hypoxii a objevují se před neurologickým poškozením. Zhoršení hypoxie má za následek zvětšující se negativní výchylku ST (viz Obr. 3) [3].



Obr. 3: Bifázický tvar vlny ST segmentu s progresivní fetální hypoxií.

1.4 Magnetokardiografie


Fetální Magnetokardiografie (MKG) je založena na měření magnetického pole generovaného elektrickou aktivitou fetálního srdce. Obvykle se měří složka magnetického pole, která je kolmá na mateřské břicho. Fetální MKG ukazují typické rysy, které se vyskytují v EKG dospělých (tj. P-vlna, QRS-komplex a T-vlna). Aby bylo možné rozlišovat mezi patologickými a zdravými plody, shromažďují se hodnoty trvání těchto průběhů v několika výzkumných skupinách. Měření ukazují, že MKG plodů se závažným vrozeným srdečním onemocněním mají neobvyklý tvar. Fetální MKG mohou být nápomocné při detekci vrozených srdečních anomálií. Fetální MKG lze také použít ke klasifikaci arytmií plodu a diagnostice prodlouženého QT-syndromu [8].

1.5 Fonokardiografie

Fonokardiografie (PKG) je neinvazivní metoda založena na zachycení zvuků plodového srdce, které jsou následně transformovány na elektrické signály. Tato metoda není příliš náročná na speciální zdravotnickou techniku. Pro záznam srdečního signálu se využívá stetoskop a mikrofon. Umístění akustického senzoru by mělo být co možná nejbližší k fetálnímu srdci, aby se získal kvalitní signál. Z tohoto vyplývá, že kvalita metody bude záviset nejen na stáří plodu, ale také na jeho poloze v děloze [9].

1.6 Fetální pulsní oxymetrie

Jedná se o metodu měření saturace oxyhemoglobinu plodu, jakmile dojde k prasknutí plodových obalů. Tato metoda využívá stejného principu jako pulzní oxymetrie pro dospělé. Unikátní padlike senzor je vložen přes děložní čípek a umístěn v oblasti hlavičky plodu, kde je držen na místě děložní stěnou (viz Obr. 4). Transabdominální fetální pulsní oxymetr byl také popsán ve studii Yam a kol. (2000). Studie ukazuje, že spolehlivě registruje saturaci fetálním kyslíkem u 70 až 95 procent žen. Dolní limit pro normální saturaci fetálním kyslíkem je vyšetřovateli obecně považován za 30 procent ([10], [11]) [3].



Obr. 4: Měření saturace oxyhemoglobinu pomocí padlike senzoru.

Další obdobou této metody je intrapartální fetální pulsní oxymetrie (IFPO). Tato metoda je neinvazivní a umožňuje kontinuální monitorování fetální oxygenace. Jedná se spíše o doplňkovou metodu ke KTG, která napomáhá včasné diagnostice intrapartální fetální hypoxie [12].

1.7 Měření pH krve plodu

Je invazivní metoda, kdy jsou prostřednictvím speciálního vybavení odebírány vzorky krve přímo z hlavičky plodu. Tato metoda poskytuje pouze informace o aktuálním stavu plodu, a proto je nutno provádět měření opakovaně. Pro svou technickou náročnost a invazivitu vůči plodu se dnes již tato metoda příliš nevyužívá [13].

1.8 Shrnutí nejpoužívanějších metod pro EFM

Každá z výše uvedených metod EFM má určité výhody i nevýhody. V Tab. 1 je uvedeno shrnutí hlavních informací, technické řešení a omezení jednotlivých EFM metod a také jejich výhody a nevýhody. Z Tab. 1 je patrné, že neinvazivně získané fEKG je velmi bezpečný, jednoduchý a levný způsob, jak získat informaci o aktuálním stavu plodu nejen během těhotenství, ale také v průběhu porodu. Na základě některých nedávných studií ([14], [15]) dosahuje fEKG lepších výsledků než konvenční KTG. Navíc se také jeví jako přesnější metoda používaná u pacientů s vyšším BMI (Body mass index – index tělesné hmotnosti) [16].

Tab. 1: Shrnutí nepoužívanějších metod pro elektronické monitorování plodu [16].

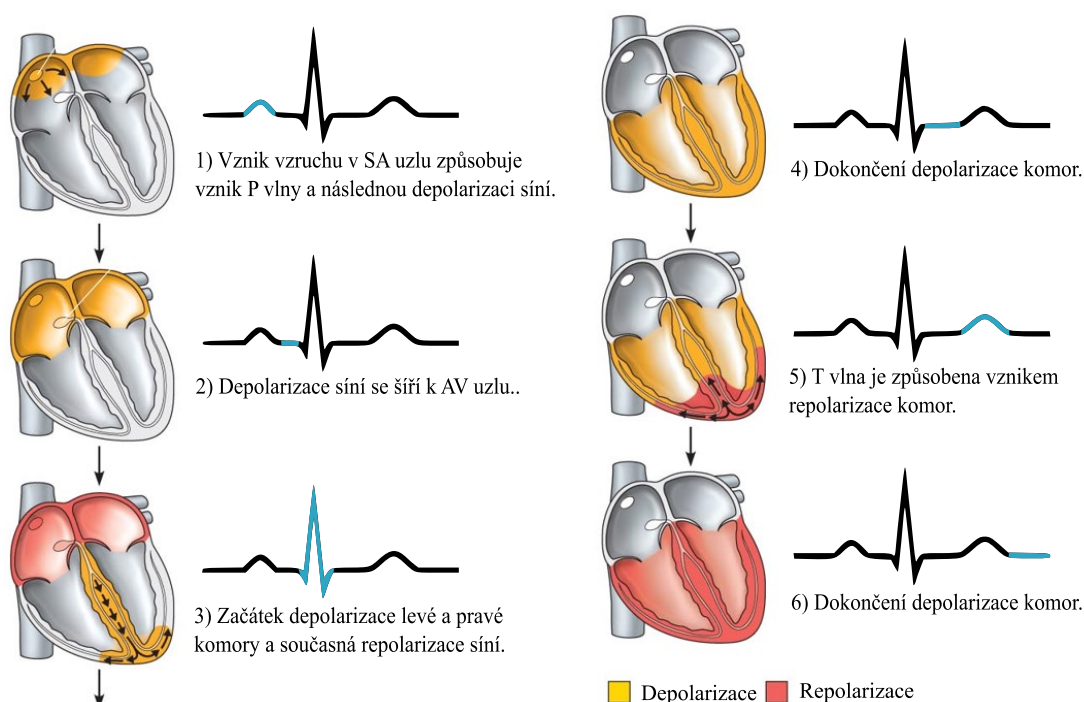
Metoda	Technické řešení	Gestační věkové omezení	Výhody a nevýhody
Neinvazivní fEKG	Standardní elektrody EKG umístěné na břicho rodičky (počet elektrod i jejich umístění se liší).	≥ 20 týdnů; s poklesem od 28. do 37. týdne	+ relativně přesné + možnost nepřetržitého monitorování + pohodlné (mobilita) - prozatím bez morfologické analýzy - velké množství překrývajících se nežádoucích signálů - nižší poměr signál-šum
KTG	Jeden UZV senzor pro monitoraci tepové frekvence plodu a jeden pro snímání děložních kontrakcí.	≥ 20 týdnů	+ nepoužívanější v klinické praxi + snadná implementace + robustní a spolehlivá - nelze posoudit variabilitu mezi dvěma rytmy - omezení pohybu rodičky pásy, kterými jsou přichyceny senzory - UZV záření
fECHO	Převodník v sondě slouží jako vysílač a přijímač pro UZV signály.	≥ 18 týdnů	+ poskytuje spolehlivé údaje o srdeční morfologii a o změnách rychlosti průtoku krve - vyžaduje kvalifikovaný personál - nevhodné pro nepřetržité monitorování
fPKG	Mikrofonní nebo optické senzory pro zachycení srdečních ozev plodu.	≥ 20 týdnů	+ levné + stanovení vícečetných těhotenství + možnost sledování z domova - citlivé na pohyblivé artefakty
fMKG	Detekce magnetického pole fetálního srdce pomocí SQUID snímačů umístěných na břicho matky.	≥ 20 týdnů	+ lepší morfologická analýza díky vyššímu poměru signálu k šumu - drahé - složitost měření - prozatím není možné dlouhodobé monitorování

2 Elektrokardiografie plodu

Fetální elektrokardiografie (z angl. Fetal Electrocardiography, fEKG) je metoda využívající se pro záznam a analýzu elektrické aktivity plodového srdce. Plodový elektrokardiogram lze snímat invazivními nebo neinvazivními metodami (podrobněji viz kap.1 - Monitorace plodu v klinické praxi). Práce se zabývá mimo jiné návrhem systému pro extrakci plodového elektrokardiogramu právě ze signálů získaných neinvazivním způsobem. Tato kapitola se věnuje popisu signálu fEKG, jeho vzniku a potenciálním zdrojům rušení.

2.1 Vznik a analýza fEKG signálu


Fetální elektrokardiogram je v podstatě mapa akčních potenciálů generovaných během srdečního cyklu. Srdce čerpá krev oběhovým systémem a zásobuje celé tělo kyslíkem. Čerpací pohyby jsou řízeny elektrickými impulzy rozváděnými v srdci prostřednictvím převodního systému srdečního. Vznik a šíření elektrického impulzu je způsoben ději na membránách srdečních buněk. Klidové membránové napětí pracovních buněk srdce je cca -90 mV. Srdeční cyklus začíná depolarizací sinoatriálního (SA) uzlu v levé síni v důsledku změny membránového potenciálu, která je způsobena velkým přílivem Na^+ iontů a současným odplavováním K^+ iontů. Potenciál se dále šíří svalovinou síní do atrioventrikulárního (AV) uzlu a dále s krátkým zpožděním buňkami komor přes Hisův svazek a levé a pravé Tawarovo raménko až do Purkyňových vláken v obou srdečních komorách. Vzruch způsobí, že se komory stáhnou a vyženou krev do oběhové soustavy. Následuje fáze repolarizace, kdy dochází k odeznění elektrického vzruchu, ochabnutí komor a obnovení klidového membránového napětí buněk a srdce je připraveno na další stimul [5], [17]. Jednotlivé fáze průběhu depolarizací a repolarizací srdce jsou zaznamenány na Obr. 5.



Obr. 5: Průběh převodního systému srdečního.

Při analýze fEKG pozorujeme zejména tvar, amplitudu a délku trvání jednotlivých vln, intervalů a úseků, ze kterých se signál EKG skládá. Tudiž vlnu P, QRS komplex a vlnu T. Na Obr. 6 je znázorněn ideální průběh elektrokardiogramu. Morfologická analýza tvaru vlny fEKG se však v klinické praxi obvykle neprovádí, s výjimkou monitoru STAN (Neoventa Medical, Goteborg, Švédsko), který využívá invazivní elektrodu zavedenou na pokožku hlavy. Tato elektroda může být umístěna pouze v poslední fázi těhotenství (antepartum). Naopak neinvazivní fEKG lze teoreticky provést již v dřívějších stádiích těhotenství (i když se slabší intenzitou pole). Neinvazivně snímané fEKG z břicha matky je však zatíženo i velkým množstvím nežádoucích signálů, jakým je zejména mateřský elektrokardiogram (mEKG), který je nutno odfiltrovat spolu s ostatním rušením, a proto je přesná extrakce a analýza tvaru vlny fEKG náročná [17], [18], [19].

Klíčovými rysy v monitorování plodu jsou fHR související s rytmem a morfologií fEKG (např. změny ST a QT). FHR lze použít jako indikátor fetální tísně. V lékařské praxi se k měření fHR obvykle používá 1-D Dopplerův ultrazvuk. Z důvodu změn poloh plodu v průběhu těhotenství není zavedena žádná standardizace umístění snímače. Jeho přesnost je navíc mnohem nižší než přesnost skalpové elektrody. Avšak bylo dosaženo pokroku ve využití fHR k poskytování klinicky významných informací. Ze signálu fEKG se pak dá hodnota fHR určit na základě vzdálenosti R kmitů. Některé studie ukázaly, že morfologie fEKG je slibná při identifikaci akčních abnormalit. To zahrnuje změny na QT intervalu, morfologii QRS komplexu a segmentu ST. Ukázalo se, že významné zkrácení intervalu QT je spojeno s intrapartální hypoxií (vedoucí k metabolické acidóze) bez ohledu na změny v fHR, zatímco u normální práce se tyto změny nevyskytují [19].



Obr. 6: Ideální průběh EKG signálu.

Signály EKG plodu a dospělého člověka jsou si, co se morfologie týče, velice podobné, avšak liší se ve velikosti jednotlivých vln a době trvání obou signálů. Velikost signálu mEKG se pohybuje v rozmezí 0,5-5mV. Velikost signálu fEKG závisí na způsobu snímání. U neinvazivního záznamu je amplituda v rozmezí od 0,01 mV do 0,4 mV, u invazivního záznamu je to cca do 0,8 mV. Tepová frekvence plodu se v průběhu těhotenství mění a oproti tepové frekvenci matky (mHR) je asi dvojnásobná. Srdce normálně se vyvíjejícího plodu začne bít okolo 21. dne těhotenství rychlostí 75-85 tepů za minutu (z angl. Beats Per Minutes, dále jen BPM). Poté se zvyšuje až na 185 BPM. V době okolo 7. týdne se začne zpomalovat a stabilizuje se mezi 120 a 160 BPM. Tuto tepovou frekvenci si pak udržuje až do porodu [18].

2.2 Rušení v EKG signálu

Naměřené hodnoty fEKG signálu mohou být nežádoucím způsobem ovlivněny různými typy rušení a artefaktů. Artefakty se rozumí částí signálu, které nemají fyziologický původ ve vyšetřovaném orgánu a lze je rozdělit na technické a biologické. Mezi technické artefakty patří elektrostatické potenciály, které vznikají zejména špatným kontaktem mezi elektrodou a vyšetřovanou osobou, malé množství gelu nebo pocení. Dále rušení z elektrorozvodné sítě (síťový brum – 50 Hz), které lze ze signálu odstranit Notch filtrem, nebo šum elektronických prvků a obvodů, který se projevuje zejména u analogových částí vstupních obvodů měřicích přístrojů [20]. Dalšími zdroji rušení jsou dechové artefakty (0,5 Hz) a kolísání izoelektrické linie způsobené změnami na rozhraní kůže matky a elektrody (0,8 Hz) [21].

Mezi biologické artefakty patří např. elektromyografické signály a pohybové artefakty (20 Hz až několik kHz). V případě neinvazivního snímání fEKG jsou zaznamenávány elektrické potenciály z mateřského břicha, které obsahují jak mateřskou, tak fetální složku a značné množství okolního rušení. Tyto signály se překrývají v čase i ve frekvenční oblasti, a proto je přesná extrakce nebo morfologická

analýza tvaru vlny fEKG poměrně náročná [19]. Neustále se vyvíjející elektronika a postupy metod zpracování signálu však umožňují extrakci fEKG na poměrně vysoké úrovni, a proto je tato metoda užitečným monitorovacím nástrojem v klinické praxi.

3 Metody pro extrakci plodového EKG

V současné době již existuje velké množství metod, které lze využít pro získání plodového EKG (fEKG), využívajících různých principů. Nejčastěji využívané metody lze rozdělit na adaptivní a neadaptivní. Rozdíl mezi těmito dvěma skupinami je v tom, zda mají schopnost se přizpůsobovat danému systému, či nikoliv. Adaptivní metody lze dále rozdělit na lineární a nelineární. Neadaptivní metody je pak možno rozdělit na jedno nebo vícekanálové.

3.1 Přehled neadaptivních metod pro extrakci fEKG signálu

Technikou neadaptivních metod je odstranění nežádoucích signálů za účelem získání signálu fEKG bez přizpůsobení systému. Neadaptivní algoritmus se tedy nemůže přizpůsobovat stávajícím okolnostem nebo nenadálým událostem, které by se mohly objevit, a pracuje pouze tak, jak byl nastaven, i když dochází ke změně počátečních podmínek. Jednakanálové metody využívají jen jednoho zdroje signálu z abdominální oblasti. Mezi tyto metodologie patří např. metody založené na vlnkové transformaci, korelační metody, metody průměrování, filtry s konečnou impulsní odezvou (FIR), Wienova filtrace a další. Vícekanálové metody pak využívají dva a více signálů z abdominální oblasti, nebo využívají kombinace elektrod abdominálních a hrudních, které lze využít pro snímání referenčního mEKG signálu. Mezi metody vícekanálové patří zejména analýza nezávislých komponent (ICA) nebo analýza hlavních komponent (PCA) [22].

3.1.1 Metody využívající vlnkové transformace

Vlnková transformace (WT) je velmi účinný nástroj pro analýzu nestacionárních signálů, a je tudíž významný pro problematiku zpracování a klasifikaci fEKG signálu. Y. Datin ve své práci [23] (1996) poprvé představuje metodu vlnkové analýzy pro detekci fEKG signálu z abdominálního záznamu. Pro tyto experimenty byla využita komplexní kontinuální vlnková transformace (CCWT) k nalezení R-kmitu, který je důležitým ukazatelem známek srdečních onemocnění.

Později J. C. Echeveria a spol (1996) v [24] doplňují odstranění mateřské komponenty a dalšího rušení a představují algoritmus pro detekci QRS komplexu plodu. Autoři uvádějí, že se jedná o velice slibnou metodu, která je schopna potlačit aditivní rušení, ne však úplně odstranit vliv mateřské komponenty.

Dále v roce 2000 představují autoři Khamene a Negahdaripour (2000) v [25] metodu založenou na vlnkové transformaci pro extrakci fEKG ze signálu aEKG. Tato metoda využívá detekce singularit získaných z kompozitního abdominálního signálu pomocí modulu maxima ve vlnkové doméně. Polohy modulů maxima břišního signálu se používají k rozlišování mezi signály mEKG a fEKG. Byly zavedeny 2 různé přístupy. V prvním se využívá alespoň jeden hrudní signál, ve druhém se již nevyužívá žádný hrudní signál. Metoda popisovaná v této práci je efektivní hlavně při záznamu fHR a její účinnost byla ověřena na syntetických i reálných datech.

V roce 2002 použil vlnkovou transformaci k detekci fEKG Mochimaru a kol. [26]. Waveletova multiresoluční analýza (MRA) byla využita jako nástroj pro odstranění rušení z EKG signálu. Autoři dále pro ověření kvality filtrace využili matematického aparátu založeného na charakterizaci singularit na základě Lipschitzových exponentů.

Karvounis a spol., 2004 [27] navrhli CCWT pro detekci komplexů QRS srdeční činnosti plodu pomocí mateřských EKG záznamů. Navrhovaná metoda se skládá ze čtyř fází, průměrného stárnutí signálu, detekce QRS komplexu matky, detekce fetálního QRS komplexu a detekce srdeční frekvence plodu. Senzitivita a pozitivní prediktivní přesnost ve fetální R-vlnové detekci byly 99,4% a 99,5%.

Sargolzaei a spol., 2008 [28], použili spline vlnku pro detekci mECG hran. Pro stanovení kritických bodů pomocí negativního prahu byla použita lokální maxima pro pozitivní části a lokální minima pro negativní části. Výhodou této metody bylo, že fECG signalizace byla provedena pomocí jednoho kanálu a také pomocí této metody byly extrahovány P a T vlny.

Chourasia a kol. (2009) ve své práci [29] navrhuje nový algoritmus vycházející z principů vlnkové transformace. Je hledána vhodná mateřská vlnka na základě vlastností různých vlnových skupin a fPKG signálu. Jako objektivní parametr pro vyhodnocování výkonu těchto algoritmů byla použita střední kvadratická chyba (MSE – z angl. Mean square error). Výsledky ukázaly, že vlnka Coiflers čtvrtého řádu rozkladu je pro analýzu signálů fPKG nejvhodnější. Stejný autor později představil vlastní bázi mateřských vlnek, která prokazovala ještě vyšší účinnost při filtraci fPKG než již existující typy vlnek. Pro tento účel byla vytvořena dvoukanálová banka filtrů, která byla založena na charakteristických vlastnostech fPKG signálu.

3.1.2 Korelační metody

D. J. Jagannath a spol. [22] popisují korelační metody jako užitečný systém, který je možno využít také k extrakci fEKG. Zprůměrovaný signál EKG je získán pomocí vhodné korelační funkce ze signálů mEKG a aEKG. Tato korelační funkce je následně odečtena od signálu aEKG pro získání požadovaného fEKG signálu. Dále uvádějí, že autokorelační techniky jsou vhodné pro určení fHR i v zarušených signálech, avšak pouze pokud nedochází k překrytí R vln mEKG a aEKG signálů.

V roce 1968 vyvinul V. Bemel viz [30] korelační techniku, která byla schopna detekovat přítomnost fEKG ze signálu snímaného neinvazivně v břišní oblasti. Navrhovaná metoda zahrnuje autokorelační a křížové korelační techniky. Ověření funkčnosti metody proběhlo na syntetických i reálných datech. Výsledky ukázaly, že navrhovaná metoda je efektivní, ne však dostatečně účinná.

Z. Shi a C. Zhang [31] (2007) přišli s myšlenkou kombinující časovou korelaci a nerovnoměrnost zdrojových signálů pro extrakci fEKG. Korelační koeficienty byly vypočteny mezi odhadovaným fEKG v časovém zpoždění, čímž bylo dosaženo odpovídajícího odhadu požadovaného signálu. Extrakce byla považována za úspěšnou, pokud byly hodnoty koeficientů vyšší než 0,9. Výběr vhodného časového zpoždění pro požadovaný fEKG signál bylo problematické.

3.1.3 Průměrovací techniky

Metoda průměrování (AT – Averaging Techniques) je jednou z nejpoužívanějších technik pro extrakci mEKG z abdominálního signálu. R-vlny jsou snadno detekovány díky jejich vysoké amplitudě v aEKG signálu. Zprůměrováním úseků aEKG signálu jdoucích po sobě, kdy všechny obsahují QRS komplexy matky, je získán referenční signál odpovídající jednomu z úseků signálu mEKG. Signál fEKG a další rušení jsou v tomto signálu potlačeny, neboť jsou na mEKG statisticky nezávislé. Výsledný signál srdeční aktivity plodu je pak získán odečtením aEKG signálu a referenčního signálu [22].

Hon a kol. (1964) ve svém příspěvku [32] navrhli metodiku průměrování pro extrakci fEKG signálu. Metoda vychází z předchozích znalostí o signálu a charakteristikách šumu. Negativním

aspektem průměrování signálu je přítomnost nízkofrekvenčních rušivých složek. Výsledky práce ukázaly, že metoda přispěla ke zvýšení poměru signálu od šumu.

3.1.4 Filtrační techniky

Signály, které přispívají k rušení, jako je např. signál mEKG a jiné formy šumu, se označují jako artefakty. Proto je nutno pro získání požadovaných signálů využít filtračních metod, jako jsou filtry v lineární časové nebo frekvenční oblasti, Wienerovy filtry s konečnou odezvou (FIR) nebo s nekonečnou impulsní odezvou (IIR) či fixované celočíselné filtrování [22].

Některé typy rušení lze filtrovat přímo v časové oblasti, která je rychlejší než filtrování ve frekvenční oblasti. Lineární filtry není dobré používat v případech, kdy dochází k překrytí spekter signálu a šumu. Ve frekvenční oblasti se využívají filtry typu dolní propust, horní propust, pásmová propust a notch filtry. Průměrové filtry jsou vhodnou alternativou, pokud dojde k překrytí spekter, protože nedochází k narušení signálu fEKG. Synchronizované průměrování však není účinné, pokud část signálu není přístupná. V tom případě se využívá průměrového okna filtru, které klouže po signálu [33].

A. Kam a A. Cohen (1999) v [34] vytvořili techniku filtrace pro detekci fEKG signálu na základě IIR filtru. Navrhovaná metodika využívá IIR filtr s genetickým algoritmem bez adaptace. Výsledky navrhované metody vykazují vyšší přesnost extrahovaného signálu než při využití pouze extrakce prostřednictvím genetického algoritmu.

R. Alcaraz a spol. (2007) v [35] implementovali různé filtry pro zpracování signálů EKG. Vysokofrekvenční šum byl eliminován obousměrným IIR chebyshevovým filtrem osmého řádu (typu dolní propust) a mezní frekvencí 70 Hz. Nízkofrekvenční rušení bylo potlačeno vysokofrekvenčním filtrem s mezní frekvencí 0,5 Hz. Rušení elektrického vedení (50 Hz) bylo eliminováno pomocí notch filtru. Vzorkovací frekvence signálů byla zvolena na 1 kHz, aby se zlepšila časová orientace pro QRS komplex. Dále bylo využito Wienerovo optimální filtrování jako neadaptivní technika eliminace interferencí.

Chmelka a kol. (2005) v [36] provedli Wienerovu filtraci na datech s malými vlnami Q a vysokými R vlnami se vzorkovací frekvencí 500 Hz. Data, která použili, obsahovala také morfologické změny QRS komplexu. S klesající úrovní hladiny hluku tato metoda přestala fungovat.

Sun a spol. (2002) v [37] implementovali filtrační algoritmus využívající modifikované morfologické operátory pro korekci základní hodnoty a odstranění šumu. Autoři dospěli k závěru, že výběr sekvence strukturujících prvků závisí na rychlosti pulzu a tvaru původního signálu. Tento algoritmus je vhodný pro úpravu signálu fEKG ve fázi předzpracování.

3.1.5 Slepá separace zdrojů (BSS)

Extrakce fEKG z abdominálního signálu může být efektivnější při využití metody BSS. Tato metoda využívá předpokladu, že jsou jednotlivé komponenty snímaného signálu na sobě statisticky nezávislé. Metody BSS jsou rozděleny do dvou hlavních skupin, a to na metody, které využívají statistiky druhého řádu, provádějí analýzu hlavních komponent (PCA) nebo rozklad singulárních hodnot, a ty, které využívají statistické informace vyššího řádu obsažené v dostupných datech, provádějí analýzu nezávislých komponent (ICA) [38].

Matematickým rozbořením metody BSS se ve svém příspěvku [39] zabývají Bacharakis a spol. Metoda BSS obsahuje množinu q , která reprezentuje statisticky nezávislé zdrojové signály s nulovou střední hodnotou. V tomto případě se jedná o signál aEKG, který se skládá ze složek x_{mEKG} a x_{fEKG} , které představují mateřskou a plodovou komponentu signálu (viz rovnice 3.1).

$$q = x_{mEKG} + x_{fEKG} \quad (3.1)$$

Dále metody BSS obsahují pozorované signály p , které jsou tvořeny neznámými lineárními kombinacemi neznámých zdrojů a aditivním šumem, o kterém se předpokládá, že se jedná o Gaussovský šum, vzájemně nezávislý. Poté lze stanovit následující rovnost matic:

$$\begin{bmatrix} y_1(t) \\ \vdots \\ y_p(t) \end{bmatrix} = \begin{bmatrix} m_{11} & \dots & m_{1q} \\ \vdots & \ddots & \vdots \\ m_{p1} & \dots & m_{pq} \end{bmatrix} \cdot \begin{bmatrix} x_1(t) \\ \vdots \\ x_q(t) \end{bmatrix} + \begin{bmatrix} n_1(t) \\ \vdots \\ n_p(t) \end{bmatrix} \quad (3.2)$$

$$Y_{aEKG} = m \cdot x + n, \quad (3.3)$$

kde x reprezentuje zdroj signálů a m (lineární kombinaci koeficientů) přenos signálu od bioelektrických zdrojů k elektrodám. Koeficienty lineární transformace udávají, jak moc každá z elektrod zachycuje signál. Šum, který obsahuje nasnímaný signál, je označen n . Tato metoda vykazuje poměrně dobré výsledky. Její přesnost lze však zvýšit, pokud se pro snímání signálu využije více elektrod.

3.1.6 ICA

Lieven De Lathauwer a spol. (2000) ve své [40] navrhuje metodu ICA pro extrakci signálu fEKG z aEKG, které je snímáno neinvazivně. Autoři se zaměřují na přímou obnovu statisticky nezávislých zdrojů bioelektrických signálů, jakožto i na charakteristiku jejich šíření směrem k elektrodám. Řešení popisované metody jsou neparametrická a nevyužívají vzorové průměrování. To může vést ke komplikacím zejména při detekci a analýze změn fHR.

Ye a kol. (2008) v [41] navrhuje algoritmus rychlé adaptivní ortogonální skupiny (využívá algoritmus ICA doplněný o neuronové sítě), který nejenže dokáže oddělit směsi sub Gaussovských a super Gaussovských zdrojových signálů, ale také může oddělit zkosené nebo super Gaussovské zdrojové signály. Separáčnický výkon velmi závisí na nelineárních funkcích. Autoři v navrhovaném algoritmu využívají samo adaptivní nelineární funkce, která upravuje své parametry tak, aby bylo dosaženo lepšího výkonu podle odhadu momentů zdrojových signálů. Algoritmus byl úspěšně použit k získání signálů fEKG s lepším výkonem separace a rychlejší konvergenční rychlostí ve srovnání s několika slavnými algoritmy ICA.

D. Luo a kol. (2012) v [42] ve své studii představují základní teorii ICA a aplikace ICA ve smíšeném signálu aEKG. Experimentální výsledky ukazují, že tato metoda může účinně zlepšit efektivitu provozu a dosáhnout dobrého separáčnického účinku. Chyba sledování času je menší než 0,5 % a frekvence chyby spektrálního diagramu je menší než 1 %.

3.1.7 PCA

PCA je technika, která se běžně používá ve vícerozměrné statistické analýze. Jejím cílem je zmenšení počtu rozměrů numerickým měřením několika proměnných. S touto redukcí rozměrů technika PCA hledá zjednodušení statistického problému s minimální ztrátou informací. Tato metoda se také

používá ve zpracování signálu pro oddělení lineární kombinace signálů generovaných ze zdrojů, které jsou statisticky nezávislé. To se provádí reprezentací dat v novém souřadnicovém systému. Transformace je obousměrná a neztrácí se žádné [43].

Bacharaki a spol. se ve své studii [39] zabývají metodou PCA a jejím matematickým popisem. PCA je založena na rozkladu matice SVD metody (the Singular Value Decomposition – metoda singulárního rozkladu) podle rovnice (3.4):

$$Y = U \cdot S \cdot V^T, \quad (3.4)$$

kde U a V představují levé a pravé singulární vektory. Směšovací matice SVD metody lze při extrakci fEKG poměrně snadno odhadnout, nicméně algoritmus je výpočetně náročný.

I. Romero (2010) ve své práci [43] popisuje, že PCA lze využít k potlačení nežádoucích signálů ze signálu EKG. Za tímto účelem bylo vytvořeno EKG s umělým pohybovým artefaktem kombinací čistého 8 kanálového EKG s šumovými signály. Vstup a výstup filtrování PCA byl porovnán výpočtem korelačního koeficientu a odhadem SNR. Nad 0 dB dosáhl nejlepší výkon PCA odpovídající nejvyšší varianci. Když hodnota SNR klesla, PCA fungovala lépe. Snížení počtu vstupních kanálů EKG nepřineslo významný rozdíl.

3.2 Přehled adaptivních metod pro extrakci fEKG signálu

Adaptivní metody jsou pro extrakci fEKG vhodnější než neadaptivní, protože tolik nedochází ke zkreslení snímaných dat a tím ke ztrátám významných informací. Pro odstranění mEKG a získání fEKG signálu je využito mnoho metod, které používají jeden nebo i více referenčních mateřských kanálů. Dosavadní adaptivní filtrační metody pro odstranění artefaktu mEKG vyžadují buďto referenční kanál mEKG, který je morfologicky podobný kontaminovanému signálu, nebo který zahrnuje řadu lineárně nezávislých kanálů, které přibližně vytvářejí požadovaný signál z referenčních. Tyto metodologie zahrnují např. LMS a RMS algoritmy, techniky umělé inteligence, Kalmanovy filtry, genetické algoritmy a další [22].

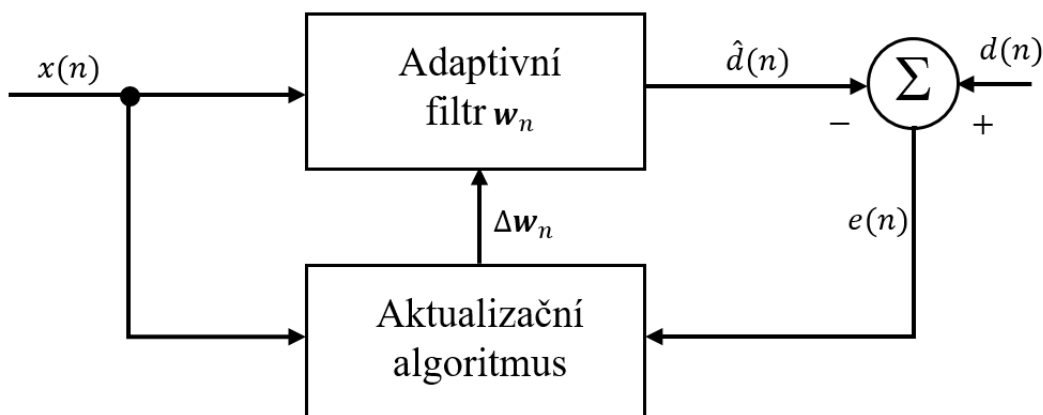
3.2.1 Adaptivní filtr

Adaptivní filtry jsou samoučící se filtry, které se svými vlastnostmi dokážou přizpůsobovat vnějším vlivům – mění své parametry v závislosti na změně parametrů vstupního signálu. Jedná se o filtry, které mají schopnost samočinného nastavení koeficientů filtru podle optimalizovaného trénovacího algoritmu, jenž je poháněn zpětně propagovaným chybovým signálem [22].

Adaptivní filtrace je proces, kdy je z použitého užitečného signálu odfiltrováno parazitní rušení. V tomto případě se jedná o proces, kdy ze signálu aEKG, který je tvořen signály mEKG, fEKG a dalšími rušivými signály, z okolí získáváme signál fEKG. Adaptivní filtry se používají při oddělení signálu a šumu nebo pro zvýšení poměru signál - šum (SNR), dále se mohou adaptivní filtry využít k odstranění harmonických signálů, jako jsou např. síťové rušení 50 Hz, odstranění sinusových rušivých signálů naindukovaných ve vedení, nebo pro odstranění širokopásmového náhodného rušivého signálu [44].

V nejjednodušší podobě je adaptivní filtr tvořen FIR filtrem a nějakým algoritmem (např. algoritmy LMS - Least Mean Squares nebo RLS - Recursive Least Squares), díky kterému filtr získá svou schopnost učení [44].

Obecné blokové schéma adaptivního filtru je znázorněno na Obr. 7. Vstupním signálem $x(n)$ je suma signálu požadovaného $d(n)$ a parazitního signálu (šumu působícího na soustavu) $v(n)$.



Obr. 7: Obecná struktura adaptivního filtru (podle [44]).

$$x(n) = d(n) + v(n) \quad (3.5)$$

Adaptivní filtr obsahuje variabilní filtr s koeficienty $\mathbf{w}(n)$ a aktualizací algoritmus, který upravuje nastavení variabilního filtru. Tento filtr má strukturu FIR filtru (podle Finite Impulse Response) s konečnou impulsní odezvou. Impulsní charakteristika je tedy ekvivalentní ke koeficientům filtru [44]. Koeficienty filtru řádu p pro časový vektor \mathbf{n} jsou definovány jako:

$$\mathbf{w}_n = [w_n(0), w_n(1), \dots, w_n(p)]^T. \quad (3.6)$$

Adaptivní filtr využívá adaptivních algoritmů, pomocí kterých může měnit hodnoty vektoru impulsní odezvy tak, aby hodnoty tzv. chybového signálu $e(n)$, který je dán rovnicí (3.7), byly co nejmenší.

$$e(n) = d(n) - \hat{d}(n). \quad (3.7)$$

Chybový signál je rozdíl mezi požadovaným signálem $d(n)$ a odhadovaným signálem $\hat{d}(n)$. Proměnný filtr odhaduje požadovaný signál tak, že spojuje vstupní signál s impulsní odezvou vektorově, podle (3.8) [44].

$$\hat{d}(n) = \mathbf{w}_n^T \mathbf{x}(n), \text{ kde} \quad (3.8)$$

$$\mathbf{x}(n) = [x(n), x(n-1), \dots, x(n-p)]^T. \quad (3.9)$$

Adaptivní filtr aktualizuje koeficienty filtru v každém časovém okamžiku podle:

$$\mathbf{w}_{(n+1)} = \mathbf{w}_n + \Delta \mathbf{w}_n. \quad (3.10)$$

3.2.2 Adaptivní metody

Lineární metody využívají adaptivních algoritmů, pomocí kterých mohou měnit hodnoty a lépe se přizpůsobit okolnímu prostředí. Systém lze považovat za lineární, pokud splňuje několik podmínek. První z nich je definice linearit. Jedná se o vlastnost superpozice, která říká, že na každý vstup musí existovat konkrétní odezva dané soustavy. Druhou vlastností lineárního systému je posun invariance, tedy pokud je $\hat{d}(n)$ odezva na lineární invariantní systém se vstupem $x(n)$, pak $\hat{d}(n - n_0)$ musí být

odezvou na systému na vstup $x(n - n_0)$. Kromě těchto dvou podmínek musí dále platit kauzalita a stabilita systému. Stabilita systému může být při nulovém počátečním stavu, tj. V-V (neboli BIBO, bounded input, bounded output) stabilita, nebo stabilita při nulovém vstupním signálu, tj. stabilita podle Ljapunova. Systém je kauzální, pokud okamžitý výstupní signál soustavy není závislý ani na budoucím vstupním signálu soustavy, ani na budoucím stavu soustavy [45].

Systém je vyhodnocován ve frekvenční oblasti. K tomu je zapotřebí konvoluční věta, která poskytuje potřebné nástroje pro vyhodnocení informací o frekvenční oblasti. Pokud $x(n)$ a $w(n)$ jsou 2 sekvence, jejichž konvoluce je definovaná podle (3.11).

$$d(n) = \sum_{p=-\infty}^{\infty} x(p)w(n-p), \quad (3.11)$$

odpovídající frekvenční odezva soustavy je uvedena v (3.12).

$$Y(e^{-j\omega}) = X(e^{-j\omega}) W(e^{-j\omega}), \text{ kde} \quad (3.12)$$

$e^{-j\omega}$ reprezentuje frekvenční oblast a kde ω představuje úhlový kmitočet, který nabývá hodnot od $-\pi$ do π . V závislosti na volbě filtračního koeficientu $w(n)$, může být pro libovolnou oblast dat realizováno velké množství výstupů [45].

Na rozdíl od lineárních filtrů nestanovuje nelineární filtr výstupní hodnotu jako lineární kombinaci vstupních hodnot obrazu, ale podle jiného algoritmu vybírá některou z hodnot ve stanoveném okolí. Nelineární adaptivní metody využívají fuzzy logiku a umělé neuronové sítě. Pracují s proměnným signálem mateřského EKG, které se liší, pokud je snímáno přímo z hrudníku nebo z abdominální oblasti matky. To je způsobeno šířením signálu mezi torakální a abdominální částí těla a snížením tepové frekvence [46], [47].

Tato podkapitola se dále bude věnovat popisu a využití jednotlivých metod pro extrakci fEKG pomocí lineárního i nelineárního adaptivního filtrování spolu s pracemi, ve kterých byly využity pro stejný účel. Jedná se o přehled dosavadního vývoje a aktuálního stavu řešené problematiky.

- **LMS**

LMS algoritmus patří mezi nejpoužívanější adaptační algoritmy. Hlavním důvodem je nízká výpočetní náročnost, jednoznačná konvergence ve stacionárním prostředí a stabilní chování systému při výpočtu s konečnou přesností. Je založen na gradientním vyhledávacím algoritmu, tj. na metodě nejstrmějšího sestupu.

R. Martinek a spol. (2017) ve své práci [48] představují návrh a ověření nové metody pro optimalizaci nastavení řídicích parametrů adaptivních filtrů LMS a RMS (velikost kroku μ a délka filtru N), jejichž výstupní signály dále využívají pro neinvazivní monitorování plodu. Navržený optimalizační algoritmus je řízen pozicí elektrody snímající signál na povrchu těla matky. Hlavním kritériem pro optimální nastavení parametrů byla velikost odstupů signálu od šumu (SNR). Autoři zjistili, že v prováděných experimentech vykazuje lepší výsledky RMS algoritmus i přesto, že způsobuje zvýšení izoelektrické linie. RMS algoritmus umožňuje vysokou kvalitu detekce tvaru fEKG vln a vykazuje vysokou přesnost. Jeho nevýhodou je nadhodnocení hodnoty fHR. LMS algoritmus naopak tuto hodnotu podhodnocuje. Při použití LMS je kvalita filtrace tím větší, čím je vyšší délka filtru. Druhým důležitým parametrem, který autoři nastavovali, je konvergenční hodnota, která ovlivňuje stabilitu a velikost chyby systému. Experimentální výsledky dále ukázaly, že optimální nastavení parametrů filtrů závisí mimo

jiné na velikosti plochy elektrody, kterou jsou EKG signály snímány. To vede k lepším výsledkům optimalizace parametrů, k přesnější detekci hypoxie plodu.

- **RLS**

RLS algoritmus patří do skupiny adaptivních algoritmů. Rozdíl oproti LMS algoritmu je vlastní statistické pojetí. RLS pracuje s průměrnými hodnotami veličin, které jsou počítány z časových vývoje, nikoliv z vzorkových průměrů počítaných z několika relací stejného náhodného procesu. Struktura filtru zůstává stejná jako u LMS algoritmu, ale liší se adaptivním procesem a je výpočetně náročnější.

- **Kalmanova filtrace**

Jacek Łeski (1991) [49] ve své práci představuje metodu pro potlačení šumu ze signálu EKG, jehož kmitočtové spektrum se překrývá s velkým množstvím rušivých signálů, které signál EKG ovlivňují. Pro potlačení rušení byl použit Kalmanův filtr spolu s metodou GPIA (Generalized Partitioned Identification Algorithm [50], [51]). Pro ověření funkčnosti této metody byly prováděny simulační testy, kdy byl původní signál EKG rušen bílým šumem, následně byl parazitní signál pomocí pozorované metody, která využívá Kalmanův filtr, potlačen a výstupní signál byl porovnán se signálem původním. Bylo zjištěno, že metoda demonstruje závislost stupně potlačení interferencí na SNR (Signal to Noise Ratio – odstup signálu od šumu). Aplikací této metody byl získán průměrný tvar signálu. Odhad stavů a parametrů filtru byl proveden algoritmem GPIA. Modelovaný signál je auto regresivní proces řádu 2. Při porovnání této metody s metodou statického zprůměrování bylo zjištěno, že dochází k potlačení interference jedné periody signálu EKG, a navíc není vyžadována klasifikace a centrování průměrných period signálu. Metoda může být použita k potlačení svalových artefaktů v signálu EKG, artefaktů plodového signálu EKG, elektrokardiogramu s vysokým rozlišením a další.

Sameni a spol. (2005) v [52] představuje práci, kde byl navržen rozšířený Kalmanův filtr (EKF – Extended Kalman Filter) pro odstranění parazitního rušení z EKG signálů. Tato metoda je založena na modifikovaném nelineárním dynamickém modelu, který byl nejprve využit pro generování syntetických EKG signálů. Autoři také vytvořili metodu automatického výběru parametrů, aby se model lépe přizpůsobil velkému množství EKG signálů. Výsledky ukazují, že výstup EKF je schopen sledovat původní tvar signálu i v těch nejvíce zarušených oblastech. Tato metoda může být využita pro extrakci plodového signálu fEKG z abdominálního signálu matky (aEKG).

Niknazar a spol. (2013) v [53] ve své práci představují metodu využívající opět rozšířený Kalmanův filtr pro extrakci fEKG signálu, který je snímán jen z jednoho svodu. Tím, že je zapotřebí pouze jedné snímací elektrody, je konstrukčně méně náročná, obsahuje menší množství elektronických součástí, a proto je i levnější. Snímané signály jsou modelovány jako součet několika signálů (mEKG, fEKG a okolního rušení). Každý z nich je popsán nelineárním dynamickým modelem, který byl nejprve využit pro generování syntetických signálů. Díky tomu má každý signál EKG odpovídající podmínky, které umožňují rozlišení jednotlivých signálů, i když se průběhy jednotlivých křivek v časové oblasti překrývají.

- **Adaptivní lineární neuron**

Metodu ADALINE odvodili a popsali Windrow a Hoff v roce 1959. ADALINE je model neuronu s několika vstupy, doplněný jednotkovým signálem. Spojením jednotlivých ADALINE vzniká umělá neuronová síť s názvem MADALINE (Many Adaptive Linear Neuron). Tato neuronová síť je velmi podobná síti perceptronů s tím rozdílem, že výstupy neuronové sítě mohou být obecně reálné.

Metoda popsaná v [54] využívá ADALINE pro extrakci fEKG, která se učí průběh mateřského signálu a odečítá ho od abdominálního, čímž je získán signál fEKG. Proces, který umožňuje extrakci fEKG, je způsoben korelací mezi mateřským a abdominálním signálem. Na vstup systému jsou přivedeny zarušený aEKG signál, obsahující komponenty jak mEKG, tak i fEKG signálu a čistý mEKG. Autorům se tato metoda osvědčila jako jeden z možných nástrojů pro monitoraci plodu, hlavně z důvodu velmi dobré a vysoké rychlosti učení, nízké hybností a nízké počáteční hmotnosti.

Bin Ibne Reaz a kol. (2004) v [55] představují metodu k oddělení fEKG pomocí ADALINE, která využívá lineárního přenosu a může se tedy přizpůsobovat změnám ve svém okolí. Dochází k odečtení aEKG a mEKG signálů a k následnému porovnání vstupních a výstupních hodnot. Pokud je velikost odchylky nulová, pak je výstupní signál roven požadovanému signálu. Pro optimální funkčnost je zapotřebí určité nastavení parametrů. Autoři zjistili, že čím je vyšší míra učení, tím daná filtrace probíhá lépe.

Dále byla tako metoda využita v [56], kde pro extrakci fEKG využili programu vytvořeného v prostředí Matlab. Autoři opět využívají signálu mEKG, který si měří pomocí elektrod umístěných na hrudníku. K těmto účelům bylo využito tři elektrod. A signálu aEKG, který je snímán pomocí pěti elektrod umístěných v abdominální oblasti těla. Výsledný signál fEKG byl získán odečtením mEKG a aEKG. Autoři uvádějí, že adaptivní neuronová síť je vhodná pro extrakci fEKG z důvodu vysoké rychlosti učení a přesnosti s jakou algoritmus dokáže získat požadovaný signál.

- **Adaptivní Voltera filtr**

Maha Shadaydeh a spol. (2008) ve svém článku [57] popisují extrakci fEKG pomocí adaptivního Voltera filtru (AVF). Představují zde nový způsob extrakce signálu fetálního EKG z jednoho hrudního mEKG signálu a jednoho nebo i více abdominálních signálů aEKG. AVF je schopen syntetizovat nelineární vztah mezi mateřským hrudním signálem a abdominálními signály, které obsahuje transformované mEKG a fEKG a další signály představující rušení. V případě použití více než jednoho aEKG signálu používá navrhovaný algoritmus lineární kombinátor (LC – podle linear combiner) pro vytvoření primárního signálu z aEKG signálů snímaných z povrchu břicha matky. LC adaptivně přiřazuje váhu každému signálu tak, aby mohl být vytvořen co nejreálnější primární signál. LC a AVF jsou aktualizovány RLS algoritmem. Navrhovaná metoda byla vyzkoušena na reálných i syntetických datech. Autoři se tímto tématem chtějí dále zabývat, neboť zde vidí příležitost k dalšímu výzkumu.

N. M.Verulkar a spol. v [58] (2012) popisují různé filtrační techniky včetně adaptivního Voltera filtru, které se dají využít k odstranění parazitních signálů ze signálu původního. Autoři mezi sebou porovnávali AVF, Nyquistův filtr, FIR filtr a IIR notch filtr. Hodnotícím kritériem zkoumaných metod byla velikost parametru SNR. Ze všech navrhovaných metod se nejvíce osvědčil IIR notch filtr, který poskytoval nejlepší potlačení (odstranění) elektrického rušení ze sítě a na výstupu je signál EKG bez šumu.

J. Mateo a spol. v [59] (2013) uvádí návrh AVF pro zlepšení zpracování signálu elektroencefalografu (EEG). Tento článek představuje algoritmus filtru Voltera založený na více kanálové struktuře pro redukci nežádoucího rušení. Autoři tuto metodu porovnali i s dalšími metodami (PCA, SVD a ICA). Experimentální výsledky ukazují, že pomocí AVF lze dosáhnout nejlepších výsledků z porovnávaných metod. Tato metoda poskytuje optimální řešení ke snížení rušení signálu a nízkého zkreslení signálu. Snížení šumu bylo vypočteno porovnáním odhadovaného a původního

signálu EEG ve vztahu ke vzájemné korelaci a střední kvadratické odchylce. Účinnost metody byla ověřena na syntetických i na reálných datech.

W. A. Zgallai ve svém článku Aplikace adaptivních LMS kvadratických a kubických filtrů Voltera na EKG signály [60] (2015) představuje metodu rozložení mateřského transabdominálního signálu EKG do jeho lineárních, kvadratických a kubických částí a zachovává pouze lineární část pro další zpracování signálu. Pro syntézu aEKG signálu je hledán nelineární prediktor, protože použití lineární struktury k zajištění nelineárních signálů by vedlo k neoptimálnímu rušení. Hodnoty koeficientů AVF jsou nastaveny sestupně, aby se minimalizovala hodnota MSE rozdílu mezi odezvou a skutečným signálem. Autor navrhuje linearizaci fetální skalpové elektrody, elektrod umístěných na matčině hrudníku i elektrod snímajících transabdominální signál EKG pomocí adaptivních struktur Voltera spolu s algoritmy LMS (least mean squares) a LMF (least mean fourth based).

- **ANFIS**

Khaled Assaleh ve svém příspěvku (2007) [61] popisuje použití metody ANFIS (Adaptive Neuro-Fuzzy Interference System) pro extrakci fEKG ze dvou EKG signálů snímaných na hrudníku (mEKG) a z povrchu břišní stěny matky (aEKG). Složka mEKG signálu v aEKG je nelineárně transformovaná verze mEKG. K identifikaci tohoto pozměněného signálu je využita právě struktura ANFIS. Tímto způsobem je extrahován fEKG signál odečtením přizpůsobené verze signálu mEKG z aEKG. Účinky metody byly ověřeny na reálných i syntetických datech.

Tato metoda je velice populární, co se týče problematiky extrakce fetálního elektrokardiogramu, a zabývá se jí velké množství autorů. Metoda ANFIS byla například použita v práci Assaleh (2006) v [62] nebo Vijila a spol. (2008) v [63].

Jiný způsob využití metody ANFIS je popsán v příspěvku T. M. Nazmy a spol. (2010) [64], kde je představen diagnostický systém využívající metodu ANFIS pro klasifikaci signálů EKG. Extrakce vlastností pomocí analýzy nezávislých komponent (ICA) a výkonového spektra R-R intervalu sloužila jako vstupní vektor do systému. Navrhovaný model ANFIS kombinuje adaptivní schopnost neuronové sítě a fuzzy interferenčního systému. Experimentální výsledky ukazují velmi vysokou efektivitu navrhované metody s přesností 97 %.

- **Genetické algoritmy**

A. Kam a A. Cohen ve svém příspěvku [34] (1999) představili metodu, která pro extrakci fEKG využívá IIR filtr spolu s genetickými algoritmy (GA). Výsledky této metody byly ověřeny na syntetických i reálných datech a porovnány s výsledky metody využívající FIR filtr spolu s LMS algoritmem. Experimenty s reálnými daty nevykazují významné rozdíly mezi těmito dvěma porovnávacími metodami. Autoři se domnívají, že je to dáno funkcí přenosu signálu tělem v nízkofrekvenčním pásmu EKG signálu, které se chová jako filtr nízkého řádu, a proto se této problematice chtějí věnovat v dalším výzkumu.

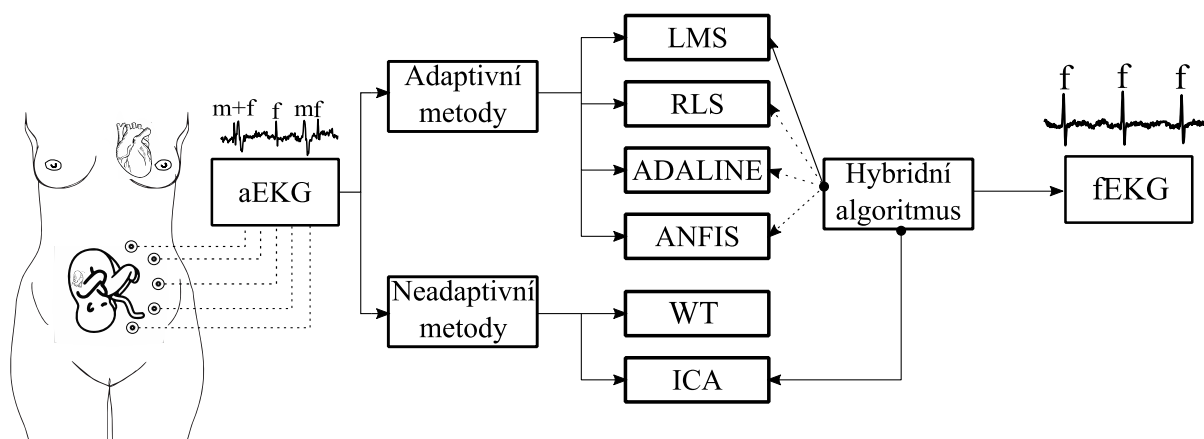
K. Nazarpour a spol. (2007) v [65] představují metodu pro modelování signálu fEKG pomocí GA. Tento příspěvek obsahuje přesný matematický model pro fEKG signál založený na skutečném fEKG signálu. Parametry navrhovaného modelu jsou optimalizovány podle velikosti sumy kvadratické chyby pomocí genetického algoritmu. Tento model chtějí autoři využít v dalším výzkumu jako omezení pro filtr, který bude sloužit pro extrakci fEKG ze smíšeného signálu aEKG.

M. Nasiri a spol. (2012) [66] představují práci, která popisuje metodu extrakce fEKG ze dvou signálů EKG snímaných na hrudníku a na povrchu břišní stěny matky. Metoda používá strukturu systému ANFIS k identifikaci nelineární transformace. Genetický algoritmus byl použit jako nástroj pro učení struktury ANFIS. Při identifikaci nelineární transformace byl extrahován fEKG signál odečtením mEKG od aEKG. Metoda byla ověřena na syntetických i reálných datech.

Často se pro dosažení ještě lepšího výsledku využívá kombinací výše popsaných algoritmů, což nám umožňuje spojit výhody jednotlivých metod a přesněji analyzovat morfologii signálu fEKG, a tím přesněji určit tepovou frekvenci plodu (fHR – fetal heard rate), která patří mezi jeden z nejdůležitějších ukazatelů zdravotního stavu plodu. Např. v [64] je popsána metoda využívající kombinaci ANFIS pro stanovení nelineární transformace (signálu mEKG) a GA. Signál fEKG byl pak získán odečtením mEKG a aEKG signálu. Dále metoda navržená v [67] využívá strukturu ANFIS v kombinaci s metodou PSO, která je použita jako nástroj pro učení struktury. Identifikaci nelineární transformace pomocí metody ANFIS byl fEKG signál opět extrahován odečtením mEKG a aEKG signálu.

4 Matematický popis vybraných metod

Na základě výše uvedené řešební části a nastudování dané problematiky lze říci, že jak adaptivní, tak i neadaptivní metody, které se využívají pro extrakci fEKG signálu a eliminaci mateřské komponenty, mají řadu výhod, ale také omezení. Každá z nich je tedy vhodnější pro jiný případ a typ signálů. Na základě nejnovějších experimentů lze usoudit, že různou kombinací dostupných metod lze vytvořit hybridní systém, který bude kombinovat vlastnosti použitých metod a bude tak vytvořen algoritmus, který bude dosahovat ještě lepších výsledků extrakce fEKG. Obr. 8 ukazuje blokové schéma ilustrující možné použití a kombinaci adaptivních a neadaptivních metod pro vytvoření hybridního systému.



Obr. 8: Možná kombinace metod pro hybridní algoritmus.

Tato kapitola se bude dále věnovat matematickému popisu metod, které byly po nastudování problematiky vyhodnoceny jako nejvhodnější pro návrh a softwarovou realizaci systému k extrakci plodového elektrocardiogramu z transabdominálního záznamu s využitím hybridního systému.

4.1 Vlnková transformace

Vlnková transformace představuje poměrně novou metodu ve srovnání s jinými typy transformací, jakou jsou např. Fourierova transformace, kosínová a sínová transformace, které jsou obecně známy déle. Vlnková transformace se spojitým časem (z angl. Continuous Wavelet Transform, CWT), umožňuje získat časově-frekvenční popis signálu. Udává tedy nejen, které frekvence jsou ve zkoumaném signálu obsaženy, ale také nám dává informaci o jejich poloze v čase. Na rozdíl od Fourierovy transformace (FT), která udává pouze rozložení frekvencí v signále a je proto vhodná pouze pro popis stacionárních signálů. WT využívá okno s mateřskou vlnkou ψ , které v určitém čase překrývá malou část zkoumaného signálu. Cílem WT je vhodnou změnou šířky okna v čase a tvarem mateřské vlnky dosáhnout optimálního poměru rozlišitelnosti v čase a frekvenci. Pro vysoké frekvence je vhodné zvolit užší vlnku, naopak pro nízké frekvence vlnku širší. Pomocí parametru měřítka (s) je možno měnit šířku vlnky (dilatace) a pomocí parametru polohy (τ) nastavení polohy vlnky na ose času (translace) [68], [69]. Obecně je mateřská vlnka dána vztahem:

$$\psi_{s,\tau}(t) = \frac{1}{\sqrt{s}} \psi\left(\frac{t-\tau}{s}\right), \quad (4.1)$$

kde s a τ jsou výše zmíněné parametry a člen $\frac{1}{\sqrt{s}}$ slouží k normalizaci energie vlnky při změně parametru s . Vlnka musí mít nulovou střední hodnotu, finitní energii a vhodný frekvenční obsah [69]. CWT je pak definována pro signály s konečnou energií, tzn. $f \in L^2(\mathbb{R})$ takto:

$$W f(\tau, s) = \frac{1}{\sqrt{s}} \int_{-\infty}^{\infty} f(t) \bar{\psi}\left(\frac{t-\tau}{s}\right) dt, \quad (4.2)$$

kde $\bar{\psi}$ představuje komplexně sdruženou funkci. Grafickým vyjádřením vlnkových koeficientů v rovině (τ, s) je vlnková mapa neboli scalogram. Vodorovná osa odpovídá posunu wavelet funkce a osa svislá představuje úroveň rozkladu do zvolené úrovně p s měřítkem s . Pro zpracování signálu je dále vhodná diskretní vlnková transformace (Discrete Wavelet Transform, DWT) [68]. Mateřská vlnka pro DWT je dána následovně:

$$2^p = s \text{ a } 2^p k = \tau; p, k \in Z \quad (4.3)$$

$$\psi_{k,p}(t) = \frac{1}{\sqrt{2^p}} \psi\left(\frac{t-2^p k}{2^p}\right), \quad (4.4)$$


kde proměnné p a k určují dilataci a translaci vlnky na diskretní mřížce. DWT lze dále vyjádřit takto:

$$W f(k, p) = \int_{-\infty}^{\infty} f(t) \overline{\psi_{p,k}(t)} dt. \quad (4.5)$$

Inverzní DWT je dána rovnicí (4.6) [70].


$$f(t) = \sum_k \sum_p W f(k, p) \psi_{k,p}(t). \quad (4.6)$$

Na Obr. 9 je zobrazeno schéma principu DWT. Nejprve je potřeba definovat typ a šířku vlnky a počet úrovní rozkladu. Poté probíhá rozklad na akční a detailní koeficienty. Inverzní DWT je pak prodloužení posloupnosti signálu pomocí těchto detailních a aproximačních koeficientů, které jsou na vstupu a provedení konvoluce s rekonstrukčními filtry. Vlnka se aplikuje na signál s nejmenším měřítkem a posunem nula, dále se pro nejmenší měřítko aplikuje jeden posun, a tak dále pro celý signál.



Obr. 9: Schéma principu DWT (podle [70]).

Principem DWT je rozklad na aproximační koeficienty cA (konvoluce posloupnosti 1D signálu s dolnoproputným filtrem) a detailní koeficienty cD (konvoluce posloupnosti 1D signálu s hornoproputným filtrem). Následně se provádí dynamické dělení podvzorkováním posloupnosti, ponechají se pouze sudé prvky. Tento multirozklad je znázorněn na Obr. 10.



Obr. 10: Schéma 3stupňového multirozkladu.

Inverzní DWT je pak analogická. Na vstupu jsou aproximační a detailní koeficienty, posloupnosti se prodlužují ze vzorků na dvojnásobnou délku vložím nul na pozice prvků s lichými indexy. Nakonec je provedena konvoluce s rekonstrukčními filtry [71].

4.2 Analýza nezávislých komponent

Metoda ICA vychází z techniky statistické analýzy, která se využívá k rozkladu vstupního multivariabilního signálu. Předpokládá se, že tento vstupní signál je tedy složen z více neznámých signálů, které jsou vzájemně nezávislé. Cílem ICA je vstupní signál separovat na soubor vzájemně nezávislých negaussovských komponent. Matematicky lze metodu ICA popsat podle rovnice (4.7) [72].

$$\mathbf{x} = \mathbf{A} \cdot \mathbf{s}, \quad (4.7)$$

kde $\mathbf{x} = [x_1, x_2, \dots, x_n]^T$ je pozorovaný multivariační signál, $\mathbf{s} = [s_1, s_2, \dots, s_m]^T$ je původní neznámý multivariační zdrojový signál, n je počet pozorovaných signálů a m je počet zdrojových signálů. \mathbf{A} představuje směšovací matici, na jejichž řádcích se nacházejí vektory \mathbf{x}^T . Cílem ICA je získat odhad neznámých komponent \mathbf{y} pomocí lineární nesmíšené matice \mathbf{W} podle vztahu:

$$\mathbf{y} = \mathbf{W} \cdot \mathbf{x}. \quad (4.8)$$

Pokud je neznámá směšovací matice \mathbf{A} čtvercová a nesingulární, pak platí, že \mathbf{W} je inverzní matici \mathbf{A} podle rovnice (4.9).

$$\mathbf{W} = \mathbf{A}^{-1}. \quad (4.9)$$

V opačném případě lze využít zobecněnou inverzní Penroseovu-Mooreovu matici:

$$\mathbf{W} = \mathbf{A}^+ \text{ a } \|\mathbf{y} - \mathbf{s}\| = \min. \quad (4.10)$$

Před aplikací metody ICA je vhodné vstupní signály předzpracovat. Hlavními důvody pro předběžné zpracování jsou zjednodušení algoritmů, zjednodušení problému a snížení počtu odhadovaných parametrů. Algoritmus ICA využívá zejména dvě techniky předzpracování, a to centrování a bělení [72]. Centrování je velice jednoduchá operace, kdy dochází k odečtení střední hodnoty od původního signálu podle vztahu:

$$\mathbf{x}_c = \mathbf{x} - E\{\mathbf{x}\}. \quad (4.11)$$

Vystředěné vektory pak mají nulovou střední hodnotu. Tato operace se využívá výhradně ke zjednodušení algoritmu.

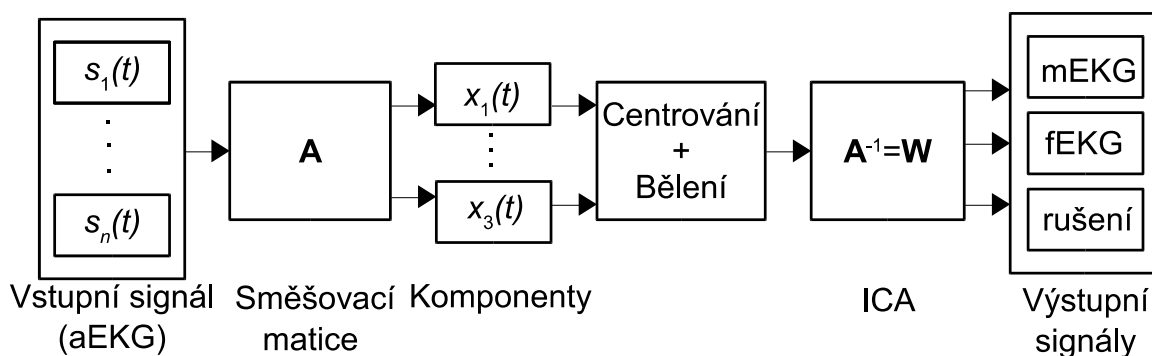
Bělení lze provést pomocí rozkladu vlastní hodnoty kovarianční matice dle:

$$E\{\mathbf{x}_c \mathbf{x}_c^T\} = \mathbf{V} \mathbf{D} \mathbf{V}^T, \quad (4.12)$$

kde \mathbf{V} je ortogonální matice vlastních vektorů a \mathbf{D} je diagonální matice vlastních čísel. Nový bělený vektor lze pak vyjádřit podle rovnice (4.13).

$$\tilde{\mathbf{x}} = \mathbf{V} \mathbf{D}^{-1/2} \mathbf{V}^T \mathbf{x}_c. \quad (4.13)$$

Při bělení dochází ke snížení počtu odhadnutých parametrů potřebných k výpočtu z n^2 na $\frac{n(n-1)}{2}$ [73] [73]. Na Obr. 11 je znázorněno blokové schéma algoritmu ICA.




Obr. 11: Schéma metody ICA.

Nevýhodou algoritmu ICA je předpoklad, že Gaussovo rozdělení může mít pouze jedna původní nezávislá komponenta. Pokud existuje více Gaussovských zdrojů, není metoda ICA schopna tyto komponenty extrahovat. Další limitací této metody je, že pořadí původních nezávislých komponent nelze určit a některé nebo všechny vypočtené komponenty \mathbf{y} mohou být vynásobeny hodnotou -1 vůči původním komponentám. Existuje-li n -rozměrný datový vektor, lze pomocí metody ICA najít maximálně n nezávislých komponent [70].

4.3 LMS

LMS algoritmus je založen na metodě minimalizace střední kvadratické chyby výstupu signálu od požadovaného signálu. Závislost střední kvadratické chyby adaptivního výstupu FIR filtru vzhledem ke koeficientům filtru je kvadratická křivka s jedním globálním minimem. Na Obr. 12 je zaznamenáno hledání minimální hodnoty střední kvadratické odchylky [74].



Obr. 12: Hledání minima střední kvadratické chyby [74].

Toto hledání je založeno na posouvání koeficientů ve směru sestupného gradientu. Počáteční hodnoty koeficientů jsou postupně adaptovány tak dlouho, až je dosaženo minima. Metodu nejstrmějšího sestupu lze vyjádřit jako:

$$\begin{aligned}
 \mathbf{w}(n+1) &= \mathbf{w}(n) + \mu \left[-\frac{\partial \{e^2(n)\}}{\partial \{\mathbf{w}(n)\}} \right] \\
 &= \frac{\partial \{[d(n) - \mathbf{w}^T(n)\mathbf{x}(n)]^2\}}{\partial \{\mathbf{w}(n)\}} \\
 &= 2 \cdot e(n) \frac{\partial \{d(n) - \mathbf{w}^T(n)\mathbf{x}(n)\}}{\partial \{\mathbf{w}(n)\}} \\
 &= 2 \cdot e(n) \{-\mathbf{x}(n)\} \\
 &= -2 \cdot e(n)\mathbf{x}(n).
 \end{aligned} \tag{4.14}$$

kde μ představuje krok adaptivního filtru, $\mathbf{w}(n)$ váhový vektor a $\mathbf{x}(n)$ vstupní vektor filtru. Každá iterace algoritmu LMS vyžaduje 3 kroky v následujícím pořadí:

- Výstup FIR filtru $y(n)$ se vypočítá dle:

$$y(n) = \sum_{i=0}^{N-1} \mathbf{w}(n)\mathbf{x}(n-i) = \mathbf{w}^T(n)\mathbf{x}(n). \tag{4.15}$$

- Vypočítá se hodnota chybového signálu:

$$e(n) = d(n) - y(n). \tag{4.16}$$

- Vektory vah FIR filtru jsou aktualizovány v rámci přípravy na další iteraci:

$$\mathbf{w}(n+1) = \mathbf{w}(n) + 2\mu e(n)\mathbf{x}(n). \tag{4.17}$$

Správné nastavení velikosti parametru μ je velice důležité pro vysokou rychlost konvergence adaptivního filtru a nalezení co nejpřesnějšího výstupu filtru, který bude ideálně stejný jako signál požadovaný [75].

LMS algoritmus byl vyvinut Widrowem a Hoffem již v roce 1959 a dnes patří k nejpoužívanějším adaptačním algoritmům. Hlavním důvodem pro časté využívání LMS algoritmů v adaptivní filtraci je jejich výpočetní nenáročnost a jednoduchost implementace [22], [74].

4.3.1 NLMS

Jednou z primárních nevýhod algoritmu LMS je, že má pro každou iteraci fixní velikost parametru μ . Pokud vstupní signál obsahuje vysoké hodnoty, má algoritmus LMS tendenci zesilovat šum. V NLMS je krok gradientu μ normalizovaný energií vstupního vektoru \mathbf{x} , tudíž bude-li vstupní signál nabývat velkých hodnot, algoritmus bude k minimu postupovat pomaleji a naopak [22], [75].

Jelikož je NLMS rozšířením standardního algoritmu LMS, je praktická implementace algoritmů velmi podobná. Každá iterace algoritmu NLMS vyžaduje tyto kroky v následujícím pořadí:

- Vypočítá výstup adaptivního filtru:

$$y(n) = \sum_{i=0}^{N-1} \mathbf{w}(n)\mathbf{x}(n-i) = \mathbf{w}^T(n)\mathbf{x}(n). \quad (4.18)$$

- Vypočítá chybový signál s jako rozdíl mezi požadovaným signálem a výstupem filtru:

$$e(n) = d(n) - y(n). \quad (4.19)$$

- Vypočítá hodnotu velikosti kroku pro vstupní vektor:

$$\mu(n) = \frac{1}{\mathbf{x}^T(n)\mathbf{x}(n)}. \quad (4.20)$$

- Aktualizuje hodnoty vektoru vah v rámci přípravy na další iteraci.

$$\mathbf{w}(n+1) = \mathbf{w}(n) + \mu e(n)\mathbf{x}(n). \quad (4.21)$$

4.3.2 BLMS

BLMS (Block LMS) algoritmus implementuje adaptivní filtr LMS, ve kterém se přizpůsobení filtračních vah provádí pouze jednou pro každý blok vzorků. Tento algoritmus poskytuje významné zlepšení při snižování chyby MSE a následné minimalizaci zkreslení signálu. Místo aktualizace vektoru filtru pro každý vzorek, jako u standardního LMS, je vektor filtru aktualizován jednou za každý L-tý vzorek [76]. Vztah aktualizace vah pro algoritmus BLMS je následující:

$$\mathbf{w}(k+1) = \mathbf{w}(k) + \mu \sum_{i=0}^{L-1} \mathbf{x}(kL+i) e(kL+i), \quad (4.22)$$

kde vzorový index n a blokový index k jsou definovány jako:

$$n = kL + i. \quad (4.23)$$

Tímto je získán výstup algoritmu BLMS podle rovnice:

$$y(k) = \mathbf{w}^T(k)\mathbf{x}(k). \quad (4.24)$$

4.3.3 DLMS

Algoritmus DLMS (Delay LMS – Zpožděný LMS algoritmus) je používán v různých aplikacích adaptivního filtrování zejména díky své stabilitě a nízké výpočetní náročnosti. Algoritmus DLMS byl zaveden z důvodu minimalizace chyby mezi daným požadovaným signálem a výstupem lineárního filtru rekurzivním nastavením parametrů tohoto filtru. Vztahy pro aktualizaci vah algoritmu DLMS jsou následující:

$$y_D(n) = \mathbf{w}^T(n-D)\mathbf{x}(n-D), \quad (4.25)$$

$$e_D(n) = d(n-D) - y_D(n-D), \quad (4.26)$$

$$\mathbf{w}(n+1) = \mathbf{w}(n) + \mu e_D(n) \mathbf{x}(n-D), \quad (4.27)$$

kde D představuje celkové zpoždění zpětné vazby LMS algoritmu. Pokud $D = 0$, pak rovnice (4.25), (4.26) a (4.27) představují standardní předpis pro algoritmus LMS. Nevýhodou DLMS algoritmu je pomalejší konvergenční rychlost ve srovnání se standardní LMS metodou kvůli zpoždění D [76].

4.4 RLS

Algoritmus RLS patří mezi rekurzivní adaptivní algoritmy vycházející ze základních principů Kalmanovy filtrace, časového průměrování a metody nejmenších čtverců. Myšlenkou RLS filtru je minimalizovat hodnotu MSE vhodným výběrem koeficientů. Filtry LMS a RLS mají podobnou strukturu. Hlavním rozdílem mezi nimi je, že RLS algoritmus využívá deterministických hodnot vstupního signálu i předchozích odhadů. Dále filtr RLS má vyšší míru konvergence, což je užitečné v aplikacích, kde by měl být filtr schopen sledovat relativně rychlé změny v průběhu signálu [74], [77]. Standardní algoritmus RLS provádí následující operace k aktualizaci koeficientů adaptivního filtru:

- Vypočítá výstupní signál adaptivního filtru podle následujícího vzorce:

$$y(n) = \mathbf{w}^T(n-1)\mathbf{x}(n). \quad (4.28)$$

- Určuje odhad chyby $e(n)$ pomocí rovnice:

$$e(n) = d(n) - y(n). \quad (4.29)$$

- Aktualizuje koeficienty filtru podle následující rovnice:

$$\mathbf{w}(n+1) = \mathbf{w}^T(n) + e(n)\mathbf{k}(n), \quad (4.30)$$

kde $\mathbf{k}(n)$ je vektor koeficientů filtru, který je definován jako:

$$\mathbf{k}(n) = \frac{P(n)\mathbf{u}(n)}{\lambda + \mathbf{u}^T(n)P(n)\mathbf{u}(n)}, \quad (4.31)$$

kde $P(n)$ je inverzní korelační matice vstupního signálu $\mathbf{x}(n)$ a λ je zapomenutý faktor v rozmezí od 0 do 1. Účelem tohoto parametru je dát větší váhu nedávným vzorkům „zapomenutím“ minulých vzorků. Pokud $\lambda = 1$, pak odhad není zapomenut [74]. Počáteční hodnota inverzní korelační matice $P(0)$ má následující tvar:

$$P(0) = \begin{bmatrix} \delta^{-1} & 0 & \dots & 0 \\ 0 & \delta^{-1} & \dots & 0 \\ \dots & \dots & \dots & \dots \\ 0 & 0 & \dots & \delta^{-1} \end{bmatrix}, \quad (4.32)$$

kde δ je regulační faktor. Standardní algoritmus RLS používá k aktualizaci matice inverzní korelace následující rovnice:

$$P(n+1) = \lambda^{-1}P(n) - \lambda^{n-1}\mathbf{k}(n)\mathbf{u}^T(n)P(n). \quad (4.33)$$

- Následně zopakuje všechny tyto kroky pro další iterace ($k+1$).

Volba zapomenutého faktoru závisí na počtu vzorků n podle následujícího vztahu:

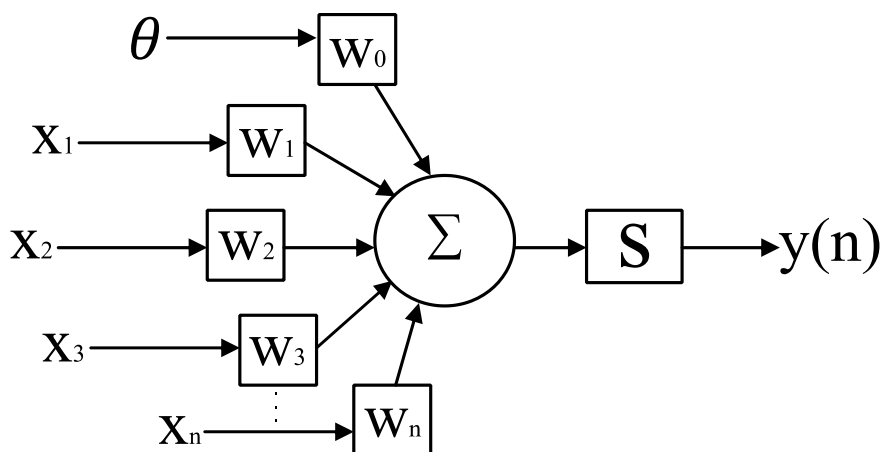
$$n = \frac{\lambda}{1-\lambda}. \quad (4.34)$$

Standardní algoritmus RLS nabízí vysokou rychlost konvergence. Když však inverzní korelační matice $P(n)$ ztratí Hermitianovu symetrii nebo vlastnosti pozitivní definitivity, diverguje, což omezuje použití tohoto algoritmu. Algoritmus RLS (QR-RLS) založený na rozkladu QR může tuto nestabilitu vyřešit, protože provádí rozklad QR přímo na korelační matici vstupního signálu. Negativní je, že tento algoritmus je výpočetně rozsáhlejší než standardní algoritmus RLS. Více o metodě QR-RLS např. v [78].

4.5 ADALINE

V kapitole 3.2.2 byly představeny práce, ve kterých se autoři zabývali extrakcí fEKG signálu z aEKG pomocí metody ADALINE. Tato metoda se zdá být vhodným nástrojem využívajícím se v této problematice. Nyní bude podrobněji popsána a matematicky rozebrána.

ADALINE je binární klasifikační algoritmus a jednovrstevná neuronová síť velice podobná konvenčnímu perceptronu. Klíčový rozdíl mezi ADALINE a perceptronem spočívá v tom, že váhové vektory ADALINE jsou aktualizovány na základě lineární aktivační funkce, zatímco perceptron využívá funkci jednotkového skoku. Dalším důležitým rozdílem mezi ADALINE a perceptronem je to, že v ADALINE jsou váhy aktualizovány pouze jednou na konci iterace celého datového souboru, ale u perceptronu, jsou váhy aktualizovány po každém vzorku v každé iteraci [79], [80]. Obecné schéma perceptronu je znázorněno na Obr. 13.



Obr. 13: Obecné schéma perceptronu.

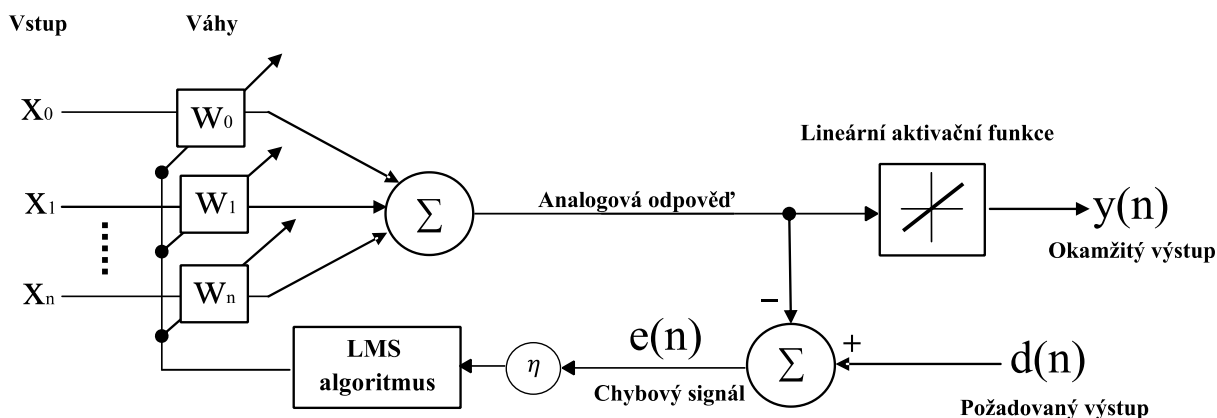
Perceptron je tvořen jedním pracovním neuronem McCullochova typu. Aplikace perceptronu umožňuje nalézt řešení pouze u problémů lineárního charakteru (jedná se o lineární klasifikátor). Potenciál perceptronu lze určit podle rovnice (4.35).

$$y(n) = S\left(\sum_{j=1}^n w_j x_j + \theta\right), \quad (4.35)$$

kde $y(n)$ je výstup neuronu, S představuje přenosovou funkci, x_j jsou vstupy do neuronu, w_j představuje vektory vah a θ je speciální vstup připojený na prahovou hodnotu signálu. Aktivační funkce perceptronu lze vyjádřit následovně:

$$S(y_{in}) = \begin{cases} 0 & \text{pro } x \leq 0 \\ 1 & \text{pro } x > 0 \end{cases}. \quad (4.36)$$

ADALINE je také tvořena jedním neuronem McCullochova typu, ale s lineární aktivační funkcí a zpětnovazebnou smyčkou. Obecné schéma metody ADALINE je zobrazeno na Obr. 14.



Obr. 14: Obecné schéma metody ADALINE.

ADALINE provádí vážený součet vstupů $x_0 - x_n$ spolu s příslušnými vahami $w_0 - w_n$. Následně porovnává výsledky tohoto součtu s hodnotou prahu. Pokud hodnota váženého součtu vstupů překračuje hodnotu prahu, je výstup systému roven jedné. Pokud tuto hodnotu nepřekročí, pak je výstup systému roven nule (viz (4.37)) [80].

$$S(y_{in}) = \begin{cases} 0 & \text{pro } \sum_{i=1}^n w_i x_i \leq \theta \\ 1 & \text{pro } \sum_{i=1}^n w_i x_i \geq \theta \end{cases}. \quad (4.37)$$

Cílem ADALINE je nalezení optimálního nastavení vah lineárního neuronu tak, aby se výstupní signál $y(n)$ co nejvíce blížil požadovanému signálu $d(n)$. Adaptace vah je umožněna díky algoritmu LMS, který minimalizuje kvadratickou chybu systému. Tato chyba je dána jako rozdíl skutečného výstupu $y(n)$ a požadovaného výstupu $d(n)$ podle vztahu:

$$mse = \frac{1}{n} \sum_{i=1}^n (d(n) - y(n))^2. \quad (4.38)$$

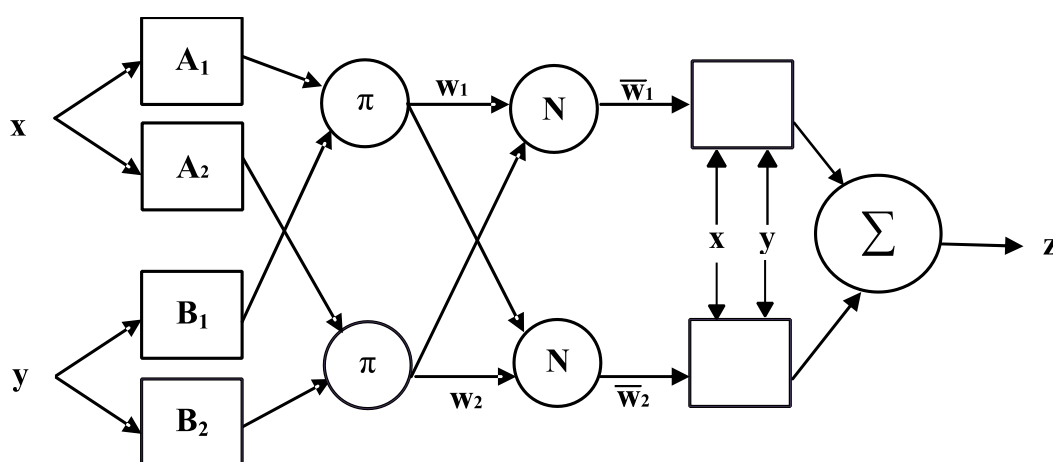
Pomocí algoritmu LMS je tedy určen okamžitý výstup systému. Chybový signál $e(n)$ lze opět určit jako rozdíl mezi požadovaným a okamžitým výstupem. Následně jsou dopočítány koeficienty filtru dle vztahu:

$$\mathbf{w}(n+1) = \mathbf{w}(n) + \eta \cdot e(n)\mathbf{x}(n), \quad (4.39)$$

kde η je míra učení. Tento parametr by měl být zvolen spíše menší tak, aby hodnota chyby konvergovala ke globálnímu minimu [80].

4.6 ANFIS

ANFIS je vícevrstevná adaptivní síť tvořená fuzzy interferenčním systémem (FIS) Sugenoova typu doplněná o učící algoritmus a dopřednou strukturu neuronových sítí. Výhodou tohoto systému je schopnost kombinace vlastností neuronových sítí a fuzzy systému v učení nelinearit. ANFIS používá k aktualizaci parametrů hybridní algoritmus učení skládající se z metody LMS a metody sestupného gradientu. Hlavní nevýhodou predikčního modelu ANFIS je poměrně značná časová náročnost na optimální stanovení parametrů a učení systému [80], [81]. Schéma struktury ANFIS je znázorněno na Obr. 15.



Obr. 15: Struktura systému ANFIS.

Z Obr. 15 je patrné, že struktura obsahuje 5 vrstev FIS dopředně propojených, 2 vstupy (x a y) a 1 výstup z . Čtvercově znázorněné uzly v jednotlivých vrstvách jsou adaptivní, kruhové neadaptivní [80]. Dále lze zavést bázi pravidel o dvou fuzzy IF-THEN pravidlech následujícího tvaru [81]:

$$\begin{aligned} IF(x \text{ is } A_1 \text{ and } y \text{ is } B_1 \text{ THEN } (z_1 = p_1x + q_1y + r_1), \\ IF(x \text{ is } A_2 \text{ and } y \text{ is } B_2 \text{ THEN } (z_2 = p_2x + q_2y + r_2) \end{aligned} \quad (4.40)$$

kde p_i, q_i a r_i ($i = 1$ nebo 2) jsou lineární parametry následné části Sugeno-Fuzzy modelu prvního řádu.

První vrstva obsahuje vstupní uzly. Každý uzel této vrstvy generuje přenosové funkce odpovídající funkcím příslušnosti daných lingvistických hodnot. Funkce pro každý uzel v této vrstvě je dána:

$$O_i^1 = \mu_{A_i}(x), \quad (4.41)$$

kde μ_{A_i} je míra příslušnosti k lingvistické hodnotě A_i a x je vstupní proměnná i -tého uzlu.

Druhá vrstva je tvořena neadaptivními vstupy, ve kterých dochází k vynásobení vstupních signálů z vrstvy předchozí. Jednotlivé uzly pak odpovídají jednomu IF-THEN fuzzy pravidlu. Výstupem je vypočtená váha w_i pravidla podle vztahu:

$$O_i^2 = w_i = \mu_{A_i}(x) \times \mu_{B_i}(y); i = 1 \text{ nebo } 2. \quad (4.42)$$

Třetí vrstva je také tvořena neadaptivními uzly, které vyjadřují poměr vah jednotlivých pravidel vzhledem k celkové sumě všech vah. Získáme tedy normalizovanou váhu pravidla.

$$O_i^3 = \bar{w}_i = \frac{w_i}{w_1 + w_2}; i = 1 \text{ nebo } 2, \quad (4.43)$$

kde \bar{w}_i je normalizovaná váha pravidla.

Čtvrtá vrstva je tvořena adaptivními uzly, pro které platí následující funkce:

$$O_i^4 = \bar{w}_i z_i = \bar{w}_i (p_i x + q_i y + r_i); i = 1 \text{ nebo } 2, \quad (4.44)$$

kde parametry p_i , q_i a r_i představují parametry konsekventu (následujícího členu).

Pátá vrstva struktury ANFIS určuje celkový výstup jako sumu výstupů čtvrté vrstvy.

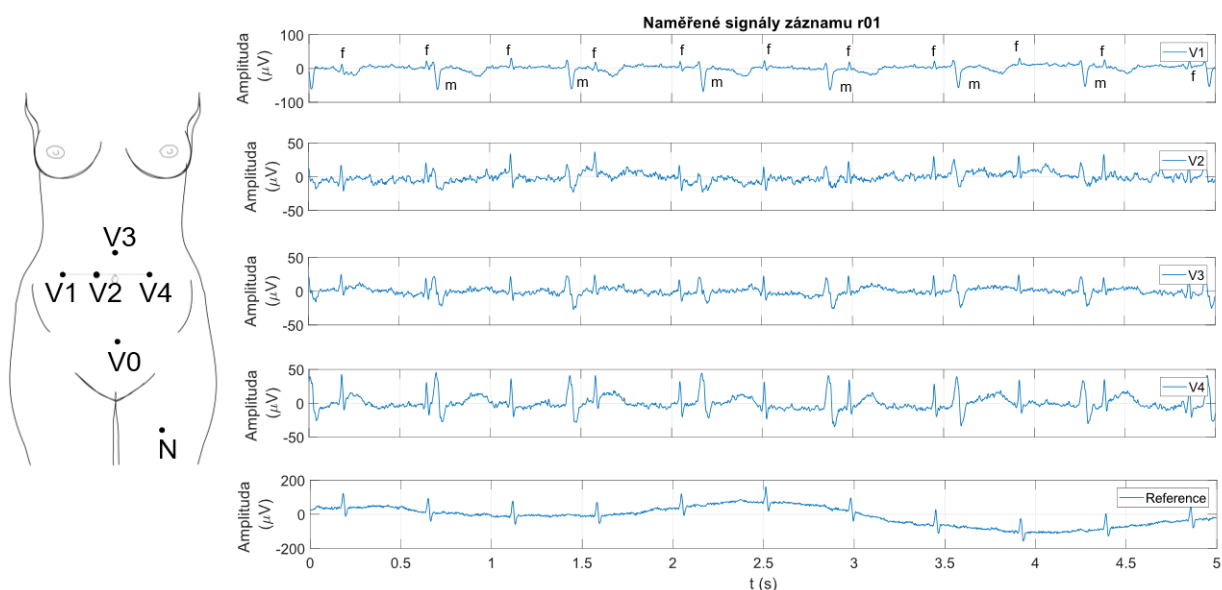
$$O_i^5 = \sum_i \bar{w}_i z_i = \frac{\sum_i \bar{w}_i z_i}{\sum_i w_i}; i = 1 \text{ nebo } 2. \quad (4.45)$$

5 Experimentální část

Na základě nastudování zkoumané problematiky v teoretické části této práce bylo dále přikročeno k realizaci praktické části. Cílem experimentální části je návrh a softwarová realizace systému pro testování extrakce fEKG z transabdominálního záznamu s využitím hybridních metod. Součástí je také ověření navrženého systému na reálných datech z klinické praxe a statistické vyhodnocení výsledků jednotlivých metod.

5.1 Testovaná data

Data, která jsou využita v následujících experimentech, jež slouží k extrakci fEKG z abdominálního signálu a ověření funkčnosti navrženého algoritmu, lze rozdělit do tří skupin. V první skupině je obsaženo deset reálných záznamů těhotných žen s označením r01-r10. Jedná se o záznamy snímané v průběhu porodu pomocí čtyř abdominálních elektrod umístěných v okolí pupku, navíc doplněných o referenční signál ze skalpové elektrody. Gestační stáří plodu se pohybuje mezi 38. a 41. týdnem. Databáze dále obsahuje zaznamenání pozice R-vln plodu, které byly určeny pomocí systému KOMPOREL. Během všech nahrávek bylo umístění elektrod konstantní. Pro záznamy r01, r04, r07, r08 a r10 byla využita vzorkovací frekvence 1000 Hz, pro ostatních pět záznamů byla vzorkovací frekvence 500 Hz. Šířka pásma se pohybovala od 1 Hz do 150 Hz a rozlišení bylo 16 bitů. Pět z deseti záznamů je dostupných v databázi ADFECGDB dostupné na webu PhysioNet (viz [82]). Ukázka signálů aEKG pro záznam r01 včetně zobrazení rozmístění elektrod, je zobrazeno na Obr. 16.



Obr. 16: Ukázka aEKG signálu, referenčního signálu a rozmístění elektrod pro záznam r01.

Abdominální EKG signály byly snímány pomocí čtyř elektrod s označením V1, V2, V3 a V4. Skalповá elektroda je označena jako V0 a elektroda N představuje aktivní zem.

Ve druhé skupině jsou obsažena data z databáze Computing Cardiology Challenge 2013 dostupné na webu PhysioNet. Všechny záznamy obsahují 4 abdominální signály a jeden signál obsahující pozice QRS komplexů plodu. Z této databáze bylo vybráno 25 záznamů. Ve třetí skupině dat jsou obsaženy

reálné signály aEKG nasnímané ve školní laboratoři. Bližší popis druhé a třetí skupiny se nachází přímo v kapitolách zabývajících se experimenty, které jsou prováděny s těmito daty (kapitola 6 a kapitola 7).

Tab. 2: Přehled dat využitých k prováděným experimentům.

Označení skupiny dat	Databáze (zdroj dat)	F _{vz} [Hz]
Dataset A	ADFECGDB	1000 Hz / 500 Hz
Dataset B	Challenge 2013	1000 Hz
Dataset C	Data z laboratoře	600 Hz

5.2 Statistická analýza

Tato podkapitola se věnuje popisu statistických parametrů, které budou dále sloužit pro vyhodnocování přesnosti filtrace výstupního signálu z navrženého hybridního algoritmu a porovnání jednotlivých metod mezi sebou. Při hodnocení kvality bude filtrovaný signál porovnán se svou referencí. Základními parametry, které budou v této práci k hodnocení využity, jsou: Senzitivita (Se), Pozitivní prediktivní hodnota (PPV), Přesnost (ACC) a F1 skóre. Výpočty a popis jednotlivých parametrů jsou uvedeny níže.

- **Senzitivita**

Parametr Se udává citlivost metody a nabývá hodnot od 0 do 1, popř. je udáván v procentech. Jedná se o parametr, který vyjadřuje pravděpodobnost, že bude zachycena přítomnost existujícího fQRS komplexu v fEKG signálu. Senzitivitu lze určit dle rovnice (5.1).

$$Se = \frac{TP}{TP + FN} \quad (5.1)$$

- **PPV**

Parametr PPV udává pravděpodobnost, že detekovaný fQRS komplex se v fEKG signálu skutečně vyskytuje. Tento parametr lze určit dle vztahu (5.2).

$$PPV = \frac{TP}{TP + FP} \quad (5.2)$$

- **ACC**

Určuje celkovou správnost algoritmu detekce fQRS komplexů, tj. pravděpodobnost správné detekce, která je rovna poměru správně označených fQRS k celkovému počtu označených fQRS komplexů.

$$ACC = \frac{TP + TN}{TP + TN + FN + FP} \quad (5.3)$$

- **F1 skóre**

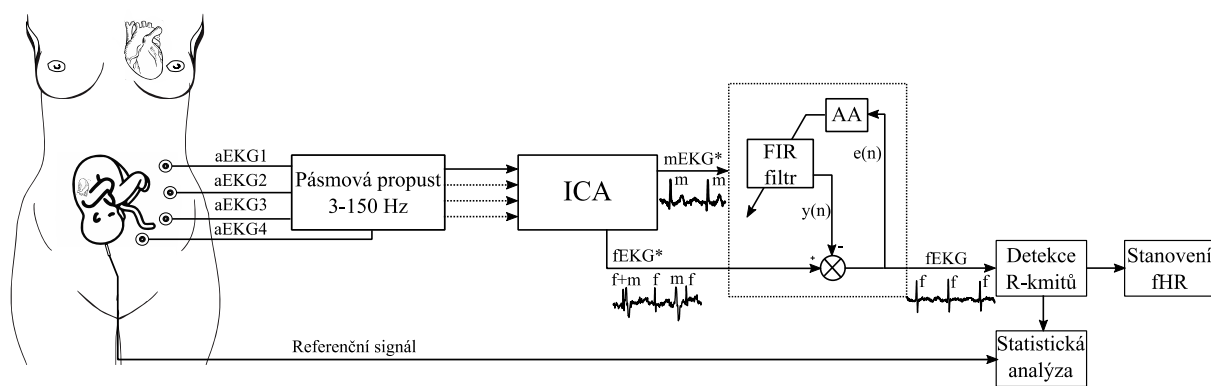
Parametr F1 představuje míru přesnosti algoritmu, tedy udává celkovou pravděpodobnost, že je komplex fQRS správně detekován. Tento parametr lze určit dle rovnice (5.4)

$$F1 = 2 \cdot \frac{PPV \cdot Se}{PPV + Se} = \frac{2 \cdot TP}{2 \cdot TP + FN + FP} \quad (5.4)$$

Ve všech uvedených rovnicích (5.1, 5.2, 5.3 a 5.4) představuje TP (true positive) správnou detekci komplexů fQRS přítomných v fEKG signálu, TN (true negative) správnou detekci nepřítomnosti fQRS komplexů v fEKG signálu, FP (false positive) označuje nesprávné označení přítomnosti fQRS komplexu a FN (false negative) nesprávnou detekci fQRS komplexů, které v fEKG signálu nejsou přítomny. Pro další vyhodnocení přesnosti určených hodnot lze využít Bland-Altmanovu analýzu.

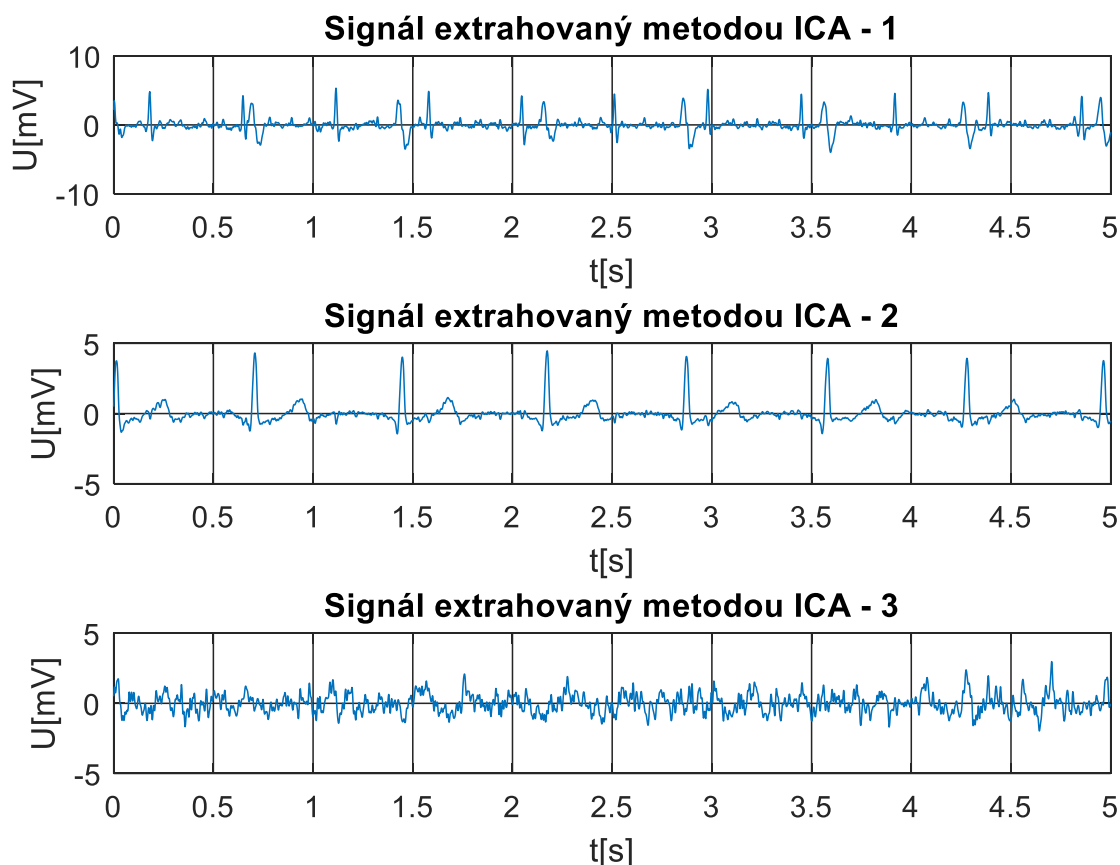
5.3 Návrh hybridního algoritmu

Obr. 17 zobrazuje návrh hybridního systému kombinující jak adaptivní, tak i neadaptivní metody, který umožňuje extrakci fEKG signálu, zhodnocení dosažených výsledků a určení tepové frekvence plodu. Navržený hybridní systém by se dal rozdělit do dvou bloků, a to na blok pro odhad mateřské složky (ICA) a následného adaptivního algoritmu pro extrakci fEKG s použitím odhadované mateřské komponenty jako referenčního vstupu.



Obr. 17: Návrh hybridního algoritmu.

Signál aEKG je snímán transabdominálně prostřednictvím elektrod označených aEKG1 – aEKG4. Následuje fáze předzpracování signálu, kdy je využito filtru typu pásmová propust o rozsahu 3–150 Hz. Tento filtr slouží k vymezení zájmového pásma EKG signálu a odstranění kolísání izoliny. Po průchodu signálu filtrem je dále aplikována metoda ICA. Pomocí této metody byl vstupní signál rozložen na tři komponenty, a to na komponenty šumu, komponenty mEKG* a fEKG*. Signál fEKG* představuje signál fEKG, který stále ještě obsahuje i mateřskou složku signálu, která je však oproti původnímu snímanému signálu částečně potlačena. Tento rozklad signálu je znázorněn na Obr. 18.



Obr. 18: Rozklad signálu pomocí metody ICA.

Extrahovaný signál 1 odpovídá signálu fEKG*, neboť je zde patrná jak plodová, tak i potlačená mateřská komponenta signálu. Extrahovaný signál 2 odpovídá odhadnuté mateřské komponentě (mEKG*) a extrahovaný signál 3 představuje šum. Pro další zpracování jsou zvoleny právě tyto dva spočtené signály (mEKG* a fEKG*), které dále vstupují do adaptivního algoritmu (AA).

Pro odhad mateřské komponenty může být využit pouze jeden snímaný aEKG signál nebo i všechny. Kvalita vypočtené mateřské složky závisí nejen na množství aEKG vstupů, ale také na jejich kvalitě a vzájemné kombinaci. Nejvhodnější kombinace elektrod vstupujících do bloku ICA pro odhad mateřské a plodové komponenty je testována v kapitole 5.3.1.

Po nastudování dané problematiky byly jako vhodné adaptivní metody, které budou dále testovány v této práci, vybrány metody LMS, NLMS, BLMS a ADALINE. Důvodem výběru metod z rodiny LMS algoritmů je jejich nízká složitost a snadná implementovatelnost. Metody rodiny LMS patří mezi jedny z nejčastěji používaných algoritmů v systémech používajících se k potlačení šumu. ADALINE je neuronová síť, která pro učení využívá právě LMS algoritmus, což oproti obyčejnému LMS slibuje vyšší výkon. Doba pro získání výsledku však může být vyšší, jelikož se už jedná o složitější výpočty než při využití klasického LMS algoritmu. Po aplikaci adaptivní metody je získán extrahovaný fEKG signál, který v ideálním případě již neobsahuje žádnou mateřskou složku. Získaný signál fEKG je dále porovnán s dostupnou referencí, která byla součástí záznamu z databáze. Následuje detekce R-kmitů a stanovení fHR. Určení správné pozice R-vlny je zajištěno pomocí detektoru, který využívá metodu CWT pro vypočtení všech lokálních maxim a minim.

5.3.1 Kombinace elektrod vstupujících do hybridního algoritmu

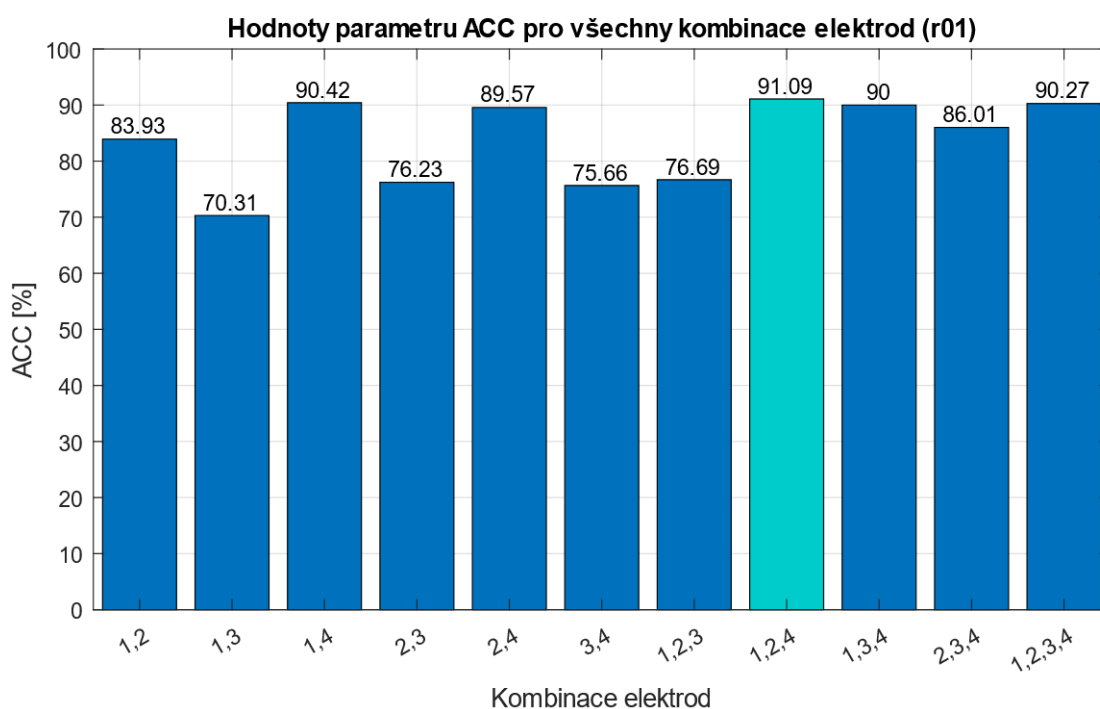
V této podkapitole jsou testovány vhodné kombinace elektrod pro jednotlivé záznamy z Datasetu A. Jak již bylo zmíněno výše, metoda ICA je nezbytná pro odhad mateřské komponenty signálu. Kvalita odhadnutého mEKG* pak dále ovlivňuje i celkový výsledek extrakce navrženého hybridního algoritmu. Správná kombinace elektrod je tedy nezbytná pro získání relevantních výsledků. Proto autorka testovala různé kombinace vstupů aEKG.

Ze čtyř snímajících elektrod umístěných na břicho matky bylo celkem vytvořeno 11 možných kombinací. Pro každý záznam pak bylo pomocí statistických parametrů určeno, která z kombinací je pro daný záznam nejvhodnější. Výsledky statistického hodnocení pro záznam r01 jsou shrnuty v Tab. 3 (pro ostatní záznamy jsou výsledky statistického hodnocení metody ICA součástí Příloha A).

Tab. 3: Výsledky statistických parametrů pro každou z kombinací elektrod pro záznam r01.

r01	TP	FP	FN	ACC [%]	SE [%]	PPV [%]	F1 [%]
1,2	606	78	38	83,93	94,09	88,59	91,27
1,3	547	134	97	70,31	84,94	80,32	82,57
1,4	632	55	12	90,42	98,14	91,99	94,96
2,3	574	109	70	76,23	89,13	84,04	86,51
2,4	627	56	17	89,57	97,36	91,80	94,49
3,4	575	116	69	75,66	89,29	83,21	86,14
1,2,3	576	107	68	76,69	89,44	84,33	86,81
1,2,4	634	52	10	91,09	98,44	92,42	95,34
1,3,4	630	56	14	90	97,82	91,84	94,74
2,3,4	615	71	29	86,01	95,49	89,65	92,48
1,2,3,4	631	55	13	90,27	97,98	91,98	94,89

Při vyhodnocování nejvhodnější kombinace elektrod byl největší důraz kladen na velikost parametru ACC, který znázorňuje přesnost metody ICA. Grafické znázornění výsledků parametru ACC pro záznam r01 a všechny možné kombinace elektrod je zaznamenáno na Obr. 19.



Obr. 19: Hodnoty parametru ACC pro všechny kombinace elektrod záznamu r01.

Nejlepší kombinace elektrod pro záznam r01 je kombinace 1., 2. a 4. elektrody, při které dosahoval parametr ACC hodnoty 91,09 %. Výsledné hodnoty ACC pro všechny záznamy a všechny kombinace elektrod jsou zaznamenány v Tab. 4. Nejvyšší hodnoty tohoto parametru jsou zvýrazněny.

Tab. 4: Stanovení hodnoty ACC pro každou z kombinací elektrod pro všech deset záznamů.

Kombinace elektrod	ACC [%]									
	r01	r02	r03	r04	r05	r06	r07	r08	r09	r10
1,2	83,93	58,87	14,92	22,05	54,23	10,55	29,54	91,22	26,60	26,99
1,3	70,31	38,19	6,57	25,44	44,80	9,41	27,39	46,42	46,16	34,81
1,4	90,42	68,38	7,41	27,13	76,15	5,92	29,88	98,19	73,29	17,94
2,3	76,23	36	11,70	20,46	45,96	12,43	28,13	84,49	46,11	28,44
2,4	89,57	61,05	5,57	21,07	71,77	5,92	33,90	83,43	60,15	16,71
3,4	75,66	33,86	5,89	23,12	50,35	7,48	24,87	87,63	57,52	22,26
1,2,3	76,69	56,08	14,46	19,73	44,38	10,10	30,18	78,61	51,16	37,15
1,2,4	91,09	68,17	8,58	19,26	75,73	6,39	30,68	98,63	54,28	18,52
1,3,4	90	65,85	5,24	20,48	72,83	5,92	22,62	97,45	71,39	16,44
2,3,4	86,01	62,47	5,38	21,07	53,97	5,92	30,43	92,22	67,78	20,99
1,2,3,4	90,27	66,83	5	20,19	71,41	12,78	29,59	83,14	71,97	35,42

Na základě výsledků zaznamenaných v Tab. 4 je patrné, že pro záznam r01 a r08 je nejvhodnější kombinace elektrod 1, 2, 4. Pro záznamy r02, r04, r05 a r09 je vhodná kombinace 1, 4. Dále pro záznam r03 je to kombinace 1, 2, pro r07 kombinace 2, 4, pro r10 kombinace 1, 2, 3 a pro záznam r06 je nejvhodnější kombinace všech čtyřech elektrod. Výsledky jsou shrnuty v Tab. 5.

Tab. 5: Shrnutí kombinací elektrod pro každý záznam.

Záznam	r01	r02	r03	r04	r05	r06	r07	r08	r09	r10
Kombinace elektrod	1,2,4	1,4	1,2	1,4	1,4	1,2,3,4	2,4	1,2,4	1,4	1,2,3

5.4 Optimalizace nastavení extrakčního adaptivního systému

Před samotnou extrakcí fEKG signálu z aEKG signálu snímaného neinvazivně je nutno najít optimální nastavení filtru pro každou metodu a každý záznam. Při hledání pracovní oblasti každou z metod bylo využito programu MATLAB, verze 2017b. Zde bylo pomocí programu hledáno správné nastavení parametrů ovlivňujících kvalitu filtrace. Tyto parametry jsou rozdílné pro každou z metod a nabývají různých hodnot pro každý záznam. Shrnutí všech parametrů ovlivňujících kvalitu filtrace pro každou z adaptivních metod je zaznamenáno v Tab. 6.

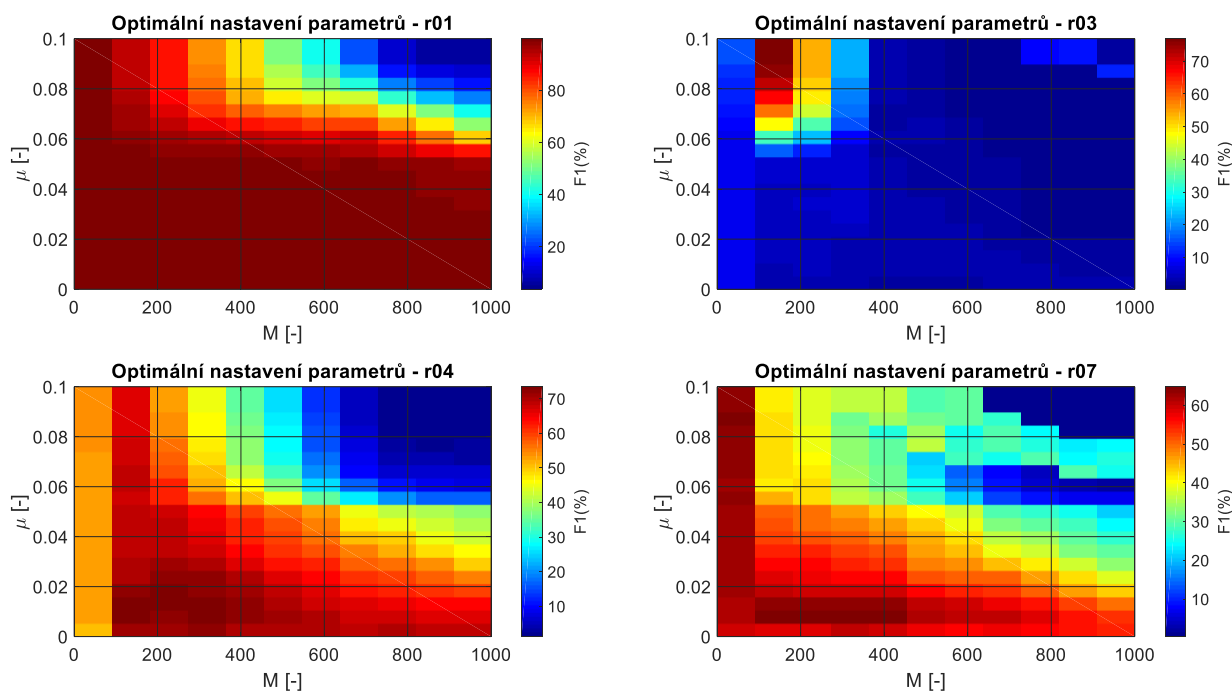
Tab. 6: Přehled parametrů jednotlivých metod.

Metoda	Parametr
LMS	M – délka filtru μ – velikost kroku
NLMS	
BLMS	
ADALINE	p – vstupní prostor (dimenzionalita vstupu) η – míra učení

Pro níže popsané experimenty bylo využito 10 reálných záznamů dostupných z databáze ADFECGDB (r01-r10) se vzorkovací frekvencí 1000 Hz nebo 500 Hz.

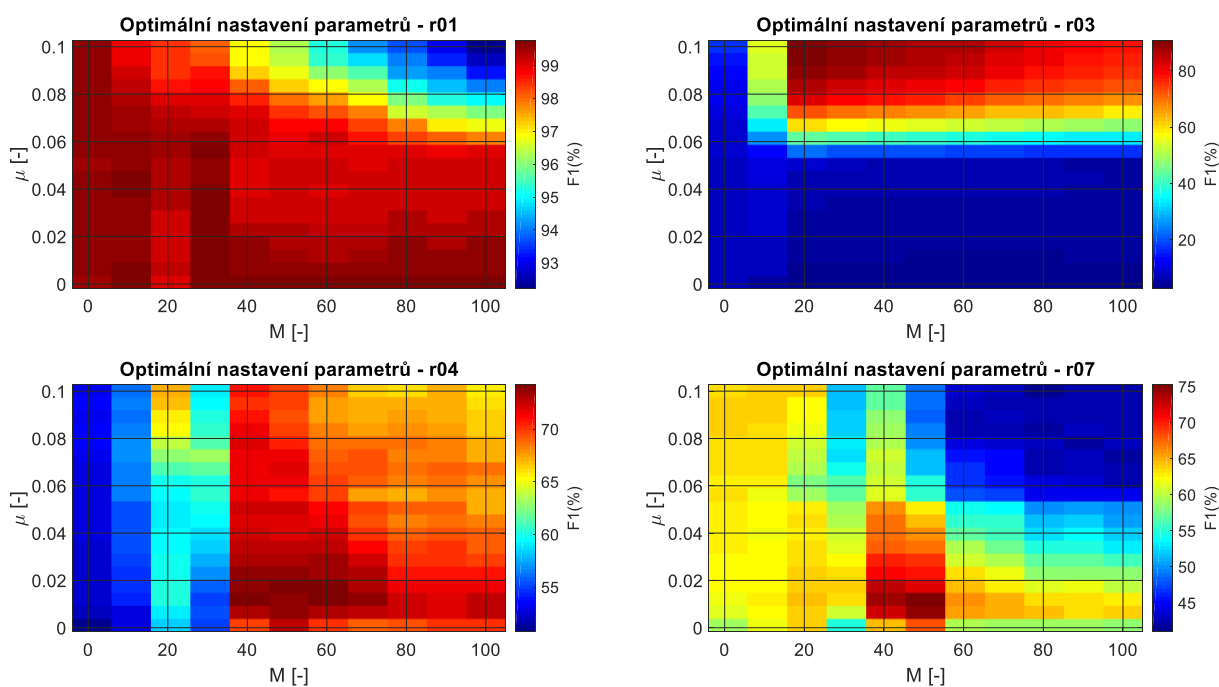
5.4.1 Optimalizace parametrů metody LMS

Při hledání rozsahu pracovní oblasti metody LMS se autorka nejprve zaměřila na testování většího rozsahu nastavení parametrů tak, aby byly nalezeny extrémy testovaného algoritmu. Proto bylo v první iteraci zvoleno nastavení délky filtru M od 1 do 1000 a parametru μ od 0,001 do 0,1. Při hodnocení vhodného nastavení parametrů byl největší důraz kladen na hodnotu parametru kvality filtrace F1, jehož hodnota by neměla být menší než 75 %. Grafické výstupy tohoto experimentu jsou zobrazeny na Obr. 20 pro 4 zvolené záznamy. Ostatní výsledky jsou součástí Příloha B.



Obr. 20: Hledání rozsahu metody LMS – krok 1.

Na Obr. 20 je zaznamenána závislost velikosti parametrů M a μ na výsledné hodnotě parametru F1, která je v grafech barevně znázorněna. Čím červenější oblast grafu, tím kvalitnější nastavení obou volených parametrů. Výsledky dále ukázaly, že algoritmus dosahuje nejvyššího výkonu při nastavení $M < 100$ a $\mu < 0,1$. Při vyšších hodnotách je výpočetní náročnost příliš vysoká, což vede také k prodloužení doby výpočtu prováděných experimentů. Proto mohla autorka přistoupit k dalšímu kroku, kterým bylo zúžení rozsahu prohledávané oblasti pro parametr M od 0 do 100.



Obr. 21: Hledání rozsahu metody LMS – krok 2.

Na Obr. 21 je opět znázorněna velikost parametru F_1 v závislosti na volbě parametru M a μ pro upravený rozsah nastavení. Z výsledků je patrné, že např. pro záznam r03 nebo r07 je toto nastavení stále zbytečně rozsáhlé, neboť se hodnota parametru F_1 nepohybuje nad 75 % hodnotou v celé prohledávané oblasti, jako je tomu např. u záznamu r01, a proto došlo k další úpravě prohledávané oblasti pro každý ze záznamů takto:

Tab. 7: Zúžení rozsahu parametrů ovlivňujících kvalitu filtrace.

Záznam	M [-]	μ [-]
r01	0-50	0-0,1
r02	0-50	0,05-0,1
r03	10-80	0,07-0,1
r04	30-70	0-0,06
r05	20-100	0-0,10
r06	0-30	0,05-0,1
r07	30-60	0-0,05
r08	0-50	0-0,05
r09	20-100	0,01-0,1
r10	40-100	0-0,1

Pro každý záznam byla pro daný rozsah (viz Tab. 7) vypočítána hodnota parametru F_1 . Jako optimální řešení byla zvolena hodnota určena jako globální maximum prohledávané oblasti. Grafické

výstupy pro každý záznam jsou k dispozici v Příloha B. Tab. 8 shrnuje optimální nastavení parametrů pro každý záznam.

Tab. 8: Optimální nastavení parametrů pro algoritmus LMS.

Záznam	F_{vz} [Hz]	M [-]	μ [-]	F1 [%]
r01	1000	30	0,003-0,007; 0,02	99,77
		31	0,001-0,004	
		32	0,001; 0,002	
		33, 34, 49, 50	0,001	
r02	500	19, 20	0,1	98,35
		20	0,05	
		23	0,09; 0,1	
r03	500	22, 23	0,1	91,68
r04	1000	43, 46	0,004	75,52
r05	500	21, 26, 27, 28, 29, 35, 36, 37, 38, 39, 40	0,003	99,61
r06	500	1	0,1	54,24
r07	1000	46, 47, 48	0,003	77,61
r08	1000	3	0,03	99,85
		4	0,007-0,01	
		5	0,006-0,01	
		6	0,007-0,02	
		7	0,01	
r09	500	24, 25, 26, 28	0,1	98,62
		38	0,07	
r10	1000	56	0,03	94,32

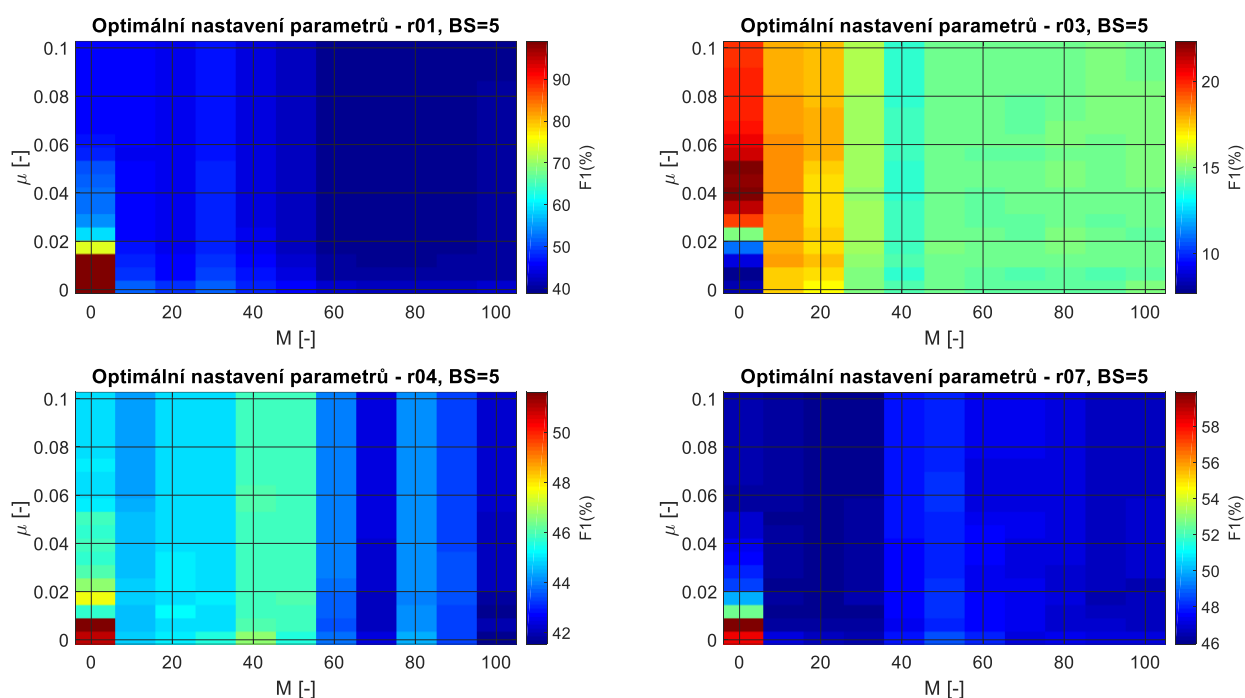
Pro všechny záznamy bylo nalezeno nejlepší možné nastavení. V Tab. 8 jsou zaznamenány všechny vhodné kombinace parametrů M a μ spolu s velikostí hodnoty parametru F1. U všech záznamů byla splněna podmínka, že $F1 \geq 75\%$, kromě záznamu r06. Pro tento záznam byla dále upravena pracovní oblast parametru μ od 0,001 do 1,0. Ovšem ani poté nedošlo k překročení 75% hodnoty. Nejlepšího výsledku, kterého bylo pro záznam r06 dosaženo, bylo 57,2 % při nastavení $M = 1$ a $\mu = 0,5$. Nakonec v Tab. 9 je zaznamenáno konečné nastavení parametrů pro každý záznam, které bude dále použito pro statistickou analýzu navrženého filtru, spolu s jejich výpočetní náročností.

Tab. 9: Konečné nastavení parametrů M a μ pro jednotlivé záznamy – LMS.

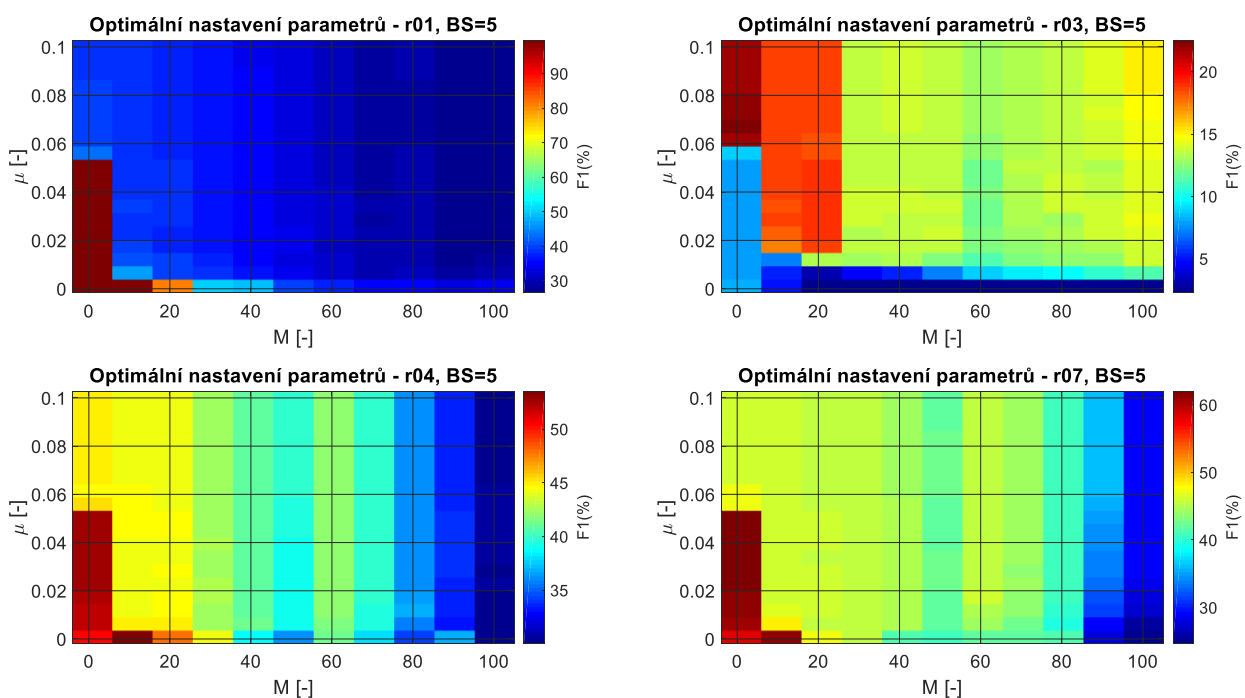
Záznam	M [-]	μ [-]	F1 [%]	Čas [s]
r01	30	0,003	99,77	3,49
r02	20	0,05	98,35	2,44
r03	22	0,1	91,68	0,58
r04	43	0,004	75,52	0,89
r05	21	0,003	99,61	0,62
r06	1	0,1	54,24	0,61
r07	46	0,003	77,61	0,96
r08	3	0,03	99,85	0,88
r09	38	0,07	98,62	0,56
r10	56	0,03	94,32	0,88

5.4.2 Optimalizace parametrů metody BLMS

Vzhledem k teoretickým poznatkům, které předpokládají, že se metody fungující na principu LMS algoritmů budou chovat podobně, byla pro první iteraci zvolena pracovní oblast pro M = od 0 do 100 pro μ = od 0,001 do 0,1. Metoda BLMS však navíc obsahuje parametr velikost bloku BS. Hodnota parametru BS musí mít podle vlastností funkce *dsp.blmsfilter* v programu Matlab celočíselný násobek délky záznamu. Pro experiment byly využity 2 typy záznamů. Záznamy r01, r04, r07, r08 a r10 obsahují 299 975 hodnot a záznamy r02, r03, r05, r06 a r09 obsahují 149 975 hodnot. Byl tedy nalezen společný násobek obou délek záznamů a to 5 a 25. Nejprve byla hodnota BS nastavena na hodnotu 5. Následně byla hodnota parametru BS změněna na hodnotu 25, přičemž nastavení parametrů M a μ zůstalo stejné. Výsledné hodnoty parametru F1 jsou při tomto nastavení pro čtyři zvolené záznamy zobrazeny níže (výstupy ostatních záznamů jsou součástí Příloha B).



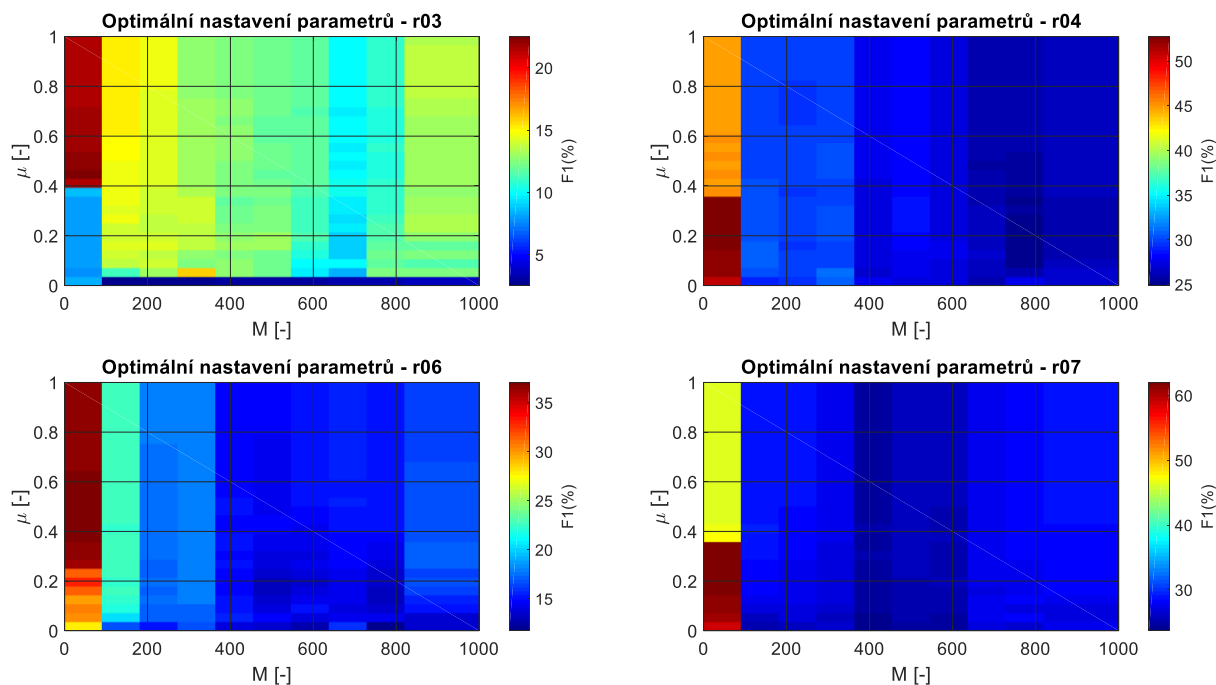
Obr. 22: Hledání vhodného nastavení parametrů metody BLMS – BS=5.



Obr. 23: Hledání vhodného nastavení parametrů metody BLMS – BS=25.

Z dosažených výsledků zobrazených na Obr. 22 a Obr. 23 je patrné, že při nastavení parametru BS na vyšší hodnotu (tedy BS = 25) se v prohledávané oblasti vyskytuje větší množství vyšších hodnot parametru F1. Proto budou následující experimenty prováděny při nastavení parametru BS=25. Dále lze při hodnocení výsledků zobrazených na Obr. 23 pozorovat, že při testovaném rozsahu nedošlo u záznamů r03, r04 ani r07 ke splnění podmínky, že F1 by mělo být vyšší než 75 %. U těchto záznamů

tedy došlo ke zvětšení prohledávané oblasti, podobně jako tomu bylo u metody LMS v první iteraci. Tedy $M =$ od 0 do 1000 a $\mu =$ od 0,001 do 1,0. Na Obr. 24 jsou zaznamenány grafické výstupy pro záznamy r03, r04, r06 a r07, u kterých při prvním nastavení nebyla nalezena vhodná pracovní oblast.



Obr. 24: Rozšíření prohledávané oblasti pro záznam r03, r04, r06 a r07.

Zvětšení pracovní oblasti pro tyto čtyři záznamy nepřispělo k získání vyšších hodnot parametru F1 než v první iteraci. Na základě všech dosažených výsledků byla následně zvolena taková pracovní oblast obou volených parametrů, aby výsledná hodnota parametru F1 byla co nejvyšší. Optimální nastavení parametrů pro každý záznam je zaznamenáno v Tab. 10.

Tab. 10: Optimální nastavení parametrů pro algoritmus BLMS.

Záznam	F_{vz} [Hz]	M [-]	μ [-]	F1 [%]
r01	1000	2-12	0,001	99,61
		1, 3-7	0,002	
		4	0,003	
		2	0,007	
r02	500	33, 34	0,03	97,83
r03	500	1	0,04	22,52
r04	1000	15	0,001	57,32
r05	500	22	0,001	98,61
r06	500	34	0,3-1,0	39,54
r07	1000	4	0,002	63,07
r08	1000	2, 3, 4, 5	0,001	99,541
		2	0,002	
r09	500	21	0,004; 0,006	96,72
		22, 42	0,005; 0,006	
		40, 41, 43	0,005	
r10	1000	56, 60	0,001	89,11

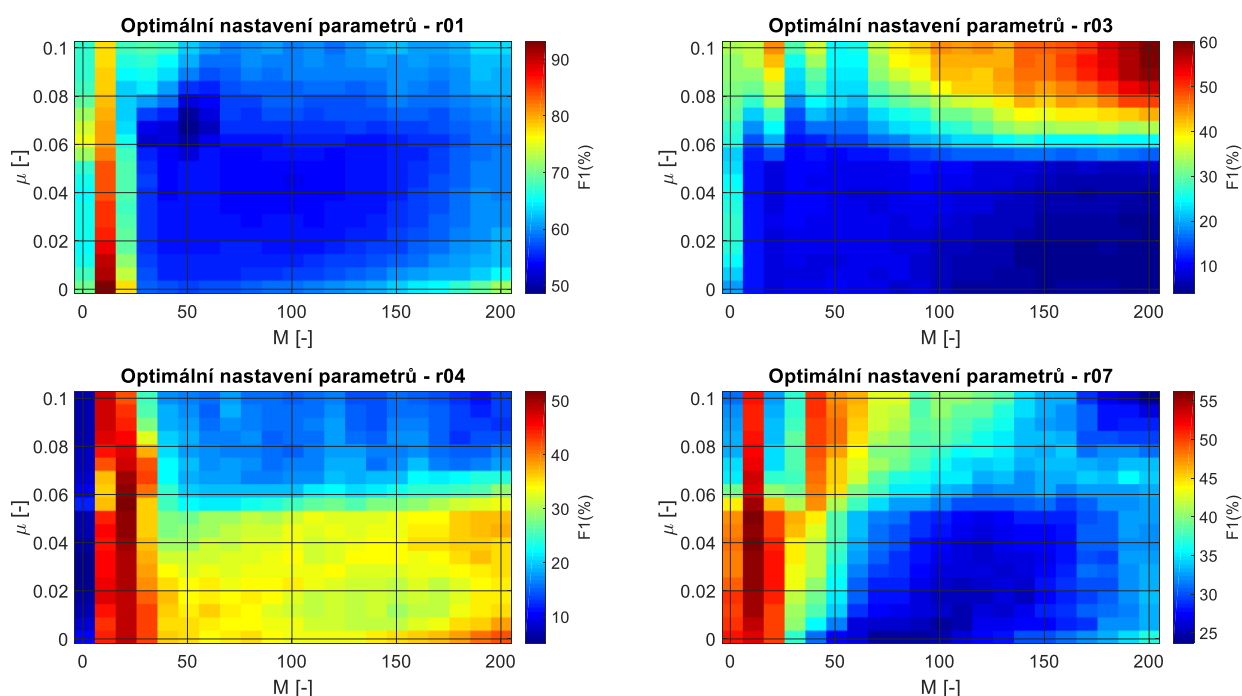
Rozsah pracovní oblasti u metody BLMS je obecně pro všech deset záznamů v okolí M od 1 do 35, kromě záznamu č. 10, kdy bylo dosaženo nejvyšší hodnoty parametru F1 při nastavení $M=60$ a oblast parametru μ od 0,001 do 0,04. Z výsledků je patrné, že při použití metody BLMS nedošlo u všech záznamů ke splnění podmínky, že F1 musí být větší než 75 %. Nejnižší hodnota parametru F1 byla dosažena u záznamu r03, kde $F1 = 22,5$ %. Tab. 11 shrnuje konečné nastavení parametrů pro každý záznam spolu s jejich výpočetní náročností, které bude dále použito ve statistické analýze navrženého filtru.

Tab. 11: Konečné nastavení parametrů M a μ pro jednotlivé záznamy – BLMS.

Záznam	M [-]	μ [-]	F1 [%]	Čas [s]
r01	2	0,001	99,61	1,66
r02	33	0,03	97,83	0,95
r03	1	0,004	22,52	0,87
r04	15	0,001	57,32	1,01
r05	22	0,001	98,61	0,77
r06	34	0,3	39,54	0,69
r07	4	0,002	63,07	0,96
r08	2	0,001	99,54	1,46
r09	21	0,004	96,72	0,67
r10	56	0,001	89,11	1,03

5.4.3 Optimalizace parametrů metody NLMS

Hledání pracovní oblasti metody NLMS probíhalo stejným způsobem, jako u metod LMS a BLMS. V první iteraci byla zvolena pracovní oblast pro M = od 1 do 200 pro μ = od 0,001 do 0,1. Výsledky jsou pro čtyři zvolené záznamy zobrazeny níže (viz Obr. 25). Ostatní grafické výstupy se opět nacházejí v Příloha B.



Obr. 25: Hledání rozsahu metody NLMS – krok 1.

Na základě výše zobrazených výsledků bylo dále přikročeno k výběru pouze takové oblasti, kde hodnota parametru F1 splňuje výše definovanou podmínku anebo takové oblasti, kde F1 dosahuje nejvyšších hodnot. Úprava rozsahu pracovní oblasti metody NLMS pro každý záznam shrnuje Tab. 12.

Tab. 12: Úprava rozsahu parametrů M a μ pro každý záznam.

Záznam	M [-]	μ [-]
r01	0-30	0-0,06
r02	100-200	0-0,05
r03	180-200	0,05-0,10
r04	0-30	0-0,10
r05	120-200	0-0,05
r06	0-15	0,05-0,1
r07	0-30	0-0,06
r08	0-40	0-0,1
r09	120-200	0-0,05
r10	0-20	0-0,1

Pro každý záznam byla pro daný rozsah (viz Tab. 12) vypočítána hodnota parametru F1 stejně jako u předchozích experimentů prováděných s metodou LMS a BLMS. Tab. 13 shrnuje optimální nastavení parametrů pro každý záznam.

Tab. 13: Optimální nastavení parametrů pro algoritmus NLMS.

Záznam	F_{vz} [Hz]	M [-]	μ [-]	F1 [%]
r01	1000	3	0,001	97,77
r02	500	189-193	0,004	98,204
r03	500	200	0,09	60,21
r04	1000	22	0,02	52,08
r05	500	200	0,002	98,308
r06	500	3	0,01	38,54
r07	1000	7	0,004	57,68
r08	1000	12	0,001	98,56
r09	500	197-200	0,02	97,11
r10	1000	8	0,04	52,32

V Tab. 13 jsou zaznamenány nejlepší kombinace obou volených parametrů. Nakonec by šlo konstatovat, že pokud se jedná o rozsah pracovní oblasti u metody NLMS obecně pro všech 10 záznamů, pohybovala by se v okolí M od 1 do 20 a pak okolo 200. hodnoty a u parametru μ od 0,001 do 0,09. V Tab. 14 je zaznamenáno konečné nastavení všech parametrů ovlivňujících kvalitu filtrace spolu s výpočetní náročností testovaného algoritmu.

Tab. 14: Konečné nastavení parametrů M a μ pro jednotlivé záznamy – NLMS.

Záznam	M [-]	μ [-]	F1 [%]	Čas [s]
r01	3	0,001	97,77	6,48
r02	189	0,004	98,204	2,84
r03	200	0,09	60,21	2,33
r04	22	0,02	52,08	2,55
r05	200	0,002	98,308	2,47
r06	3	0,01	38,54	2,32
r07	7	0,004	57,68	2,53
r08	12	0,001	98,56	2,78
r09	197	0,02	97,11	2,43
r10	8	0,04	52,32	0,89

Při porovnání všech testovaných metod rodiny LMS (LMS, BLMS a NLMS) lze pozorovat, že hodnoty parametru F1 jsou u některých záznamů velice rozdílné. Např. u záznamu r03 došlo u algoritmů BLMS a NLMS k velkému poklesu parametru F1 oproti hodnotě při aplikaci LMS algoritmu. Dále lze ve výsledcích pozorovat, že jediným záznamem, u kterého nedošlo k překročení hodnoty 75 % ani

u jednoho z aplikovaných algoritmů, je záznam r06. Nejlepších výsledků ze všech provedených experimentů dosáhl algoritmus LMS, u kterého všechny záznamy, kromě jednoho, splnily podmínku $F1 \geq 75\%$ a zároveň jsou získané hodnoty parametru F1 vyšší než u ostatních dvou testovaných metod. Porovnání výsledků všech testovaných metod je zaznamenáno v Tab. 15.

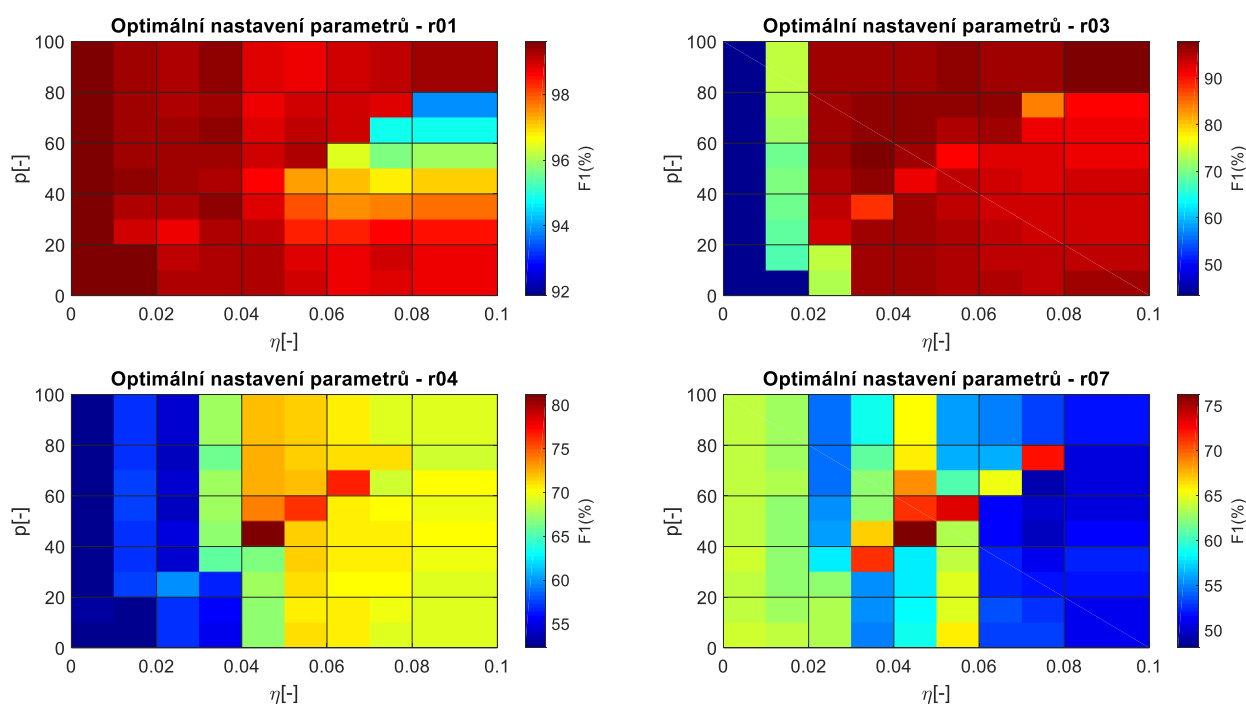
Tab. 15: Porovnání výsledků jednotlivých testovaných algoritmů.

Záznam	LMS F1 [%]	BLMS F1 [%]	NLMS F1 [%]
r01	99,77	99,61	97,77
r02	98,35	97,83	98,204
r03	91,68	22,52	60,21
r04	75,52	57,32	52,08
r05	99,61	98,61	98,308
r06	54,24	39,54	38,54
r07	77,61	63,07	57,68
r08	99,85	99,54	98,56
r09	98,62	96,72	97,11
r10	94,32	89,11	52,32

5.4.4 Optimalizace parametrů metody ADALINE

Systém využívající metodu ADALINE obsahuje dva hlavní parametry, které nejvíce ovlivňují kvalitu filtrace, a proto je nutná jejich optimalizace. Jedná se o parametr p vyjadřující dimenzionalitu vstupu a parametr η , který představuje míru učení algoritmu. Optimalizace extrakčního systému byla provedena na reálných datech z databáze ADFECGDB (Dataset A). Při hodnocení kvality byl hlavní důraz kladen na hodnotu parametru F1, která by neměla být menší než 75 %.

Nejprve bylo potřeba opět určit limity dané metody. Proto bylo provedeno nastavení hodnoty p od 0 do 100 a hodnoty η od 0 do 0,1. Závislost velikosti hodnot obou parametrů, spolu s hodnotou parametru F1, je pro čtyři zvolené zobrazena na Obr. 26, kde je právě velikost parametru F1 znázorněna barevně.



Obr. 26: Optimální rozsah parametrů pro záznam r0, r03, r04 a r07.

Z výsledku pro záznam r01 je patrné, že algoritmus dosahuje nejvyššího výkonu při nastavení $\eta \leq 0,01$ a $p \leq 100$, přičemž hodnoty parametru F1 přesahují 99 %. Záznam r03 vykazuje své maximální hodnoty F1 při nastavení $\eta > 0,02$. Dále záznam r04 dosahuje nejvyššího výkonu v oblasti nastavení pro p od 40 do 50 a pro η mezi 0,04-0,05. Po zjištění rozsahu velikosti obou parametrů bylo přikročeno k hledání neoptimálnějšího nastavení p a η tak, aby byla velikost parametru F1 co nejvyšší. Tento proces proběhl následovně. Nejprve byla podle předchozích výsledků zúžena oblast rozsahu parametru η , zatím co rozsah parametru p zůstal nezměněn ($p = 0$ až 100). Změna rozsahu hodnoty η je zaznamenána v Tab. 16.

Tab. 16: Úprava pracovní oblasti parametru η .

Záznam	η [-]
r01	0-0,01
r02	0,02-0,04
r03	0,02-0,04
r04	0,05-0,05
r05	0,02-0,05
r06	0-0,01
r07	0,04-0,05
r08	0-0,01
r09	0,02-0,04
r10	0,06-0,08

Následně bylo podle dosažených výsledků určeno neoptimálnější nastavení obou parametrů, podle velikosti hodnoty F1. Všechny grafické výstupy z procesu optimalizace nastavené metody ADALINE pro ostatní záznamy jsou přiloženy v Příloha B. Optimální nastavení extrakčního systému pro každý záznam je zaznamenáno v Tab. 17.

Tab. 17: Optimální nastavení parametrů pro algoritmus ADALINE.

Záznam	F_{vz} [Hz]	η [-]	p [-]	F1 [%]
r01	1000	0,001	71, 61, 51, 31	99,61
		0,005-0,01	1	
r02	500	0,02	51	98,43
		0,025; 0,036	21	
r03	500	0,022; 0,025	31	97,53
		0,023	51	
r04	1000	0,001	48	78,27
r05	500	0,022; 0,024	21	99,54
r06	500	0,001	1	51,12
r07	1000	0,001	40	76,53
r08	1000	0,004	31	99,85
		0,004; 0,005-0,01	41	
		0,006-0,01	51	
		0,008-0,01	61	
		0,007-0,009	71	
		0,009	81	
		0,009	91	
r09	500	0,021; 0,027; 0,028	71	98,85
		0,029; 0,032	81	
r10	1000	0,071	51	93,22

Z výsledků uvedených v Tab. 17 lze pozorovat, že u všech záznamů byla splněna podmínka $F1 > 75\%$, kromě záznamu r06, kde bylo dosaženo 51,12 % při nastavení $p = 1$ a $\eta = 0,001$. Nakonec v Tab. 18 je zaznamenáno konečné nastavení parametrů pro každý záznam, které bude dále použito pro statistickou analýzu navrženého filtru spolu s jejich výpočetní náročností.

Tab. 18: Konečné nastavení parametrů při testování metody ADALINE.

Záznam	p [-]	η [-]	F1 [%]	Čas [s]
r01	31	0,001	99,61	4,02
r02	21	0,025	98,43	1,81
r03	31	0,022	97,53	1,76
r04	48	0,001	78,27	3,21
r05	21	0,022	99,54	1,54
r06	1	0,02	51,12	0,56
r07	40	0,001	76,53	3,12
r08	31	0,004	99,85	2,95
r09	71	0,021	98,85	1,77
r10	51	0,071	93,22	3,17

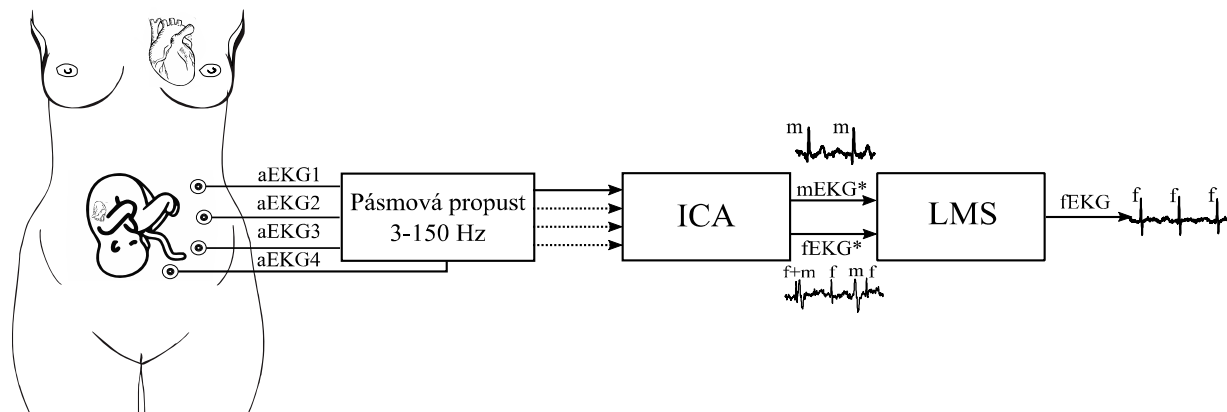
Po získání optimálního nastavení pro každý záznam a každou metodu mohlo být dále přikročeno ke statistickému zhodnocení dosažených výsledků. Této problematice se věnuje následující kapitola.

5.5 Statistické vyhodnocení dosažených výsledků

Hlavním cílem aplikace hybridního algoritmu (podle Obr. 17) je účinná extrakce fEKG signálu, ve kterém bude mateřská složka co nejvíce eliminována tak, aby výstupem z filtru byl ideálně čistý signál plodového EKG. Níže je uveden podrobný popis výsledků, kterých bylo dosaženo u jednotlivých metod pro jeden zvolený záznam. Při hodnocení kvality filtrace byl kladen největší důraz na hodnotu parametru F1. Výsledná hodnota parametru F1 by měla být co nejvyšší. Neměla by však být nižší než 75 %. Kromě statistických parametrů bylo pro každou metodu využito také subjektivního hodnocení při porovnání vstupních a výstupních signálů nejen v časové, ale také ve frekvenční oblasti.

5.5.1 LMS

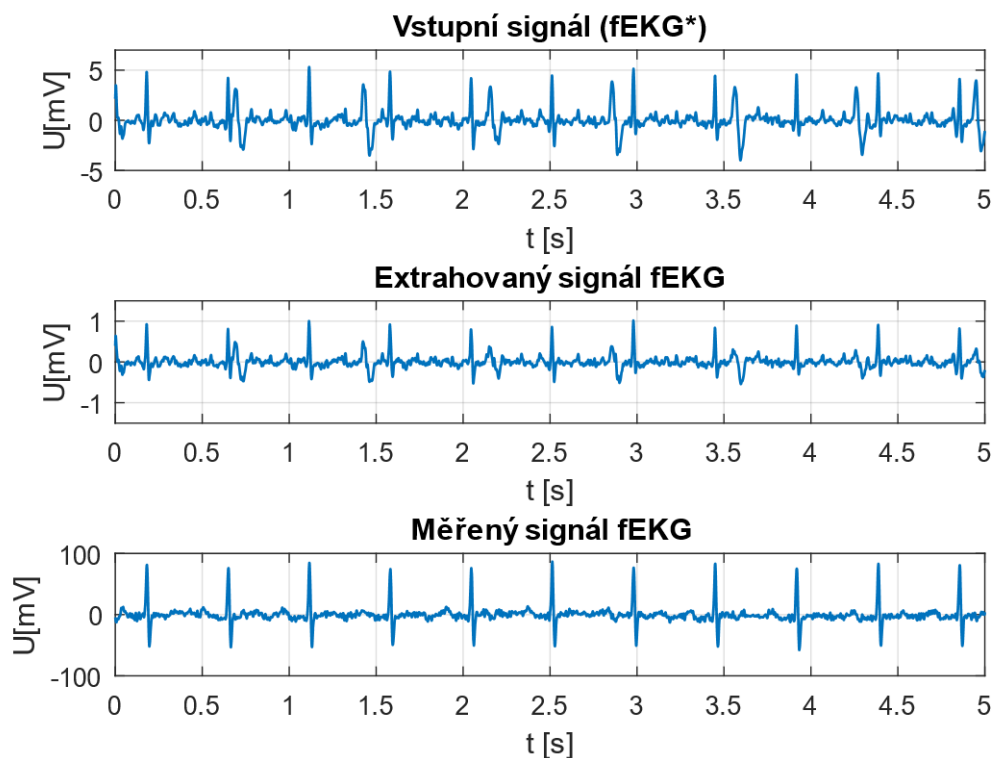
Na Obr. 27 je zobrazeno schéma navrženého hybridního algoritmu, který pro extrakci fEKG signálu využívá metodu LMS. Vstupem do bloku LMS jsou odhadnuté signály mEKG* a fEKG*, které byly určeny pomocí metody ICA. Výstupem pak je extrahovaný fEKG signál.



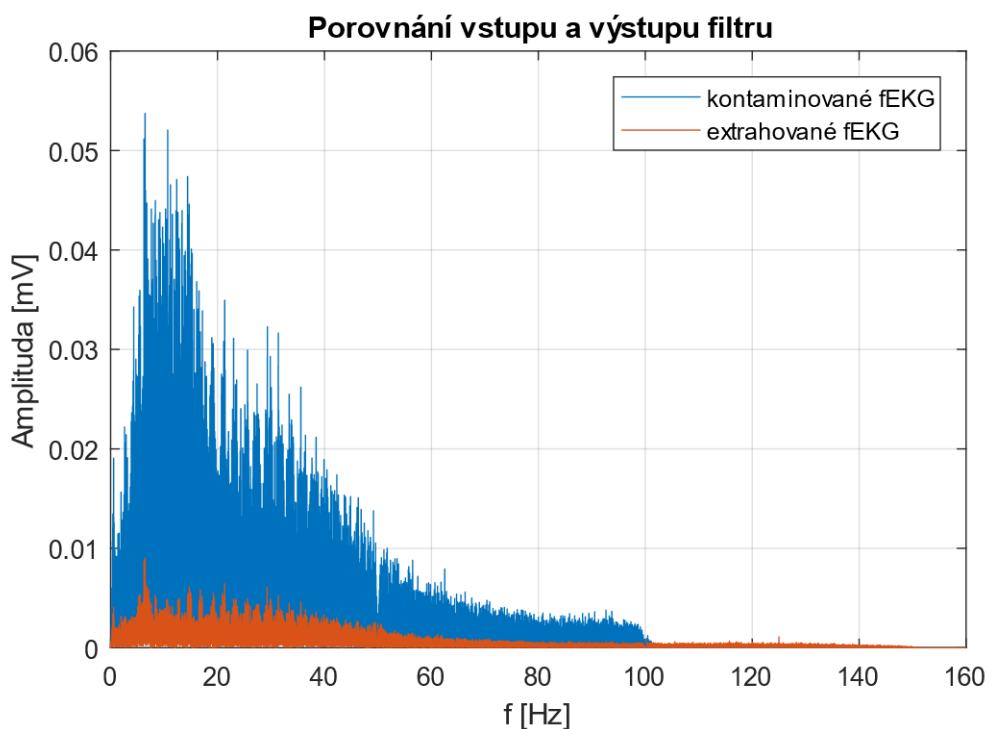
Obr. 27: Testovaný HA využívající metodu LMS.

Dále na Obr. 28 je zobrazen časový průběh vstupního signálu (fEKG*) v porovnání s výstupním signálem, který představuje extrahovaný fEKG signál. Z tohoto je patrné, že došlo k úspěšnému potlačení mateřské komponenty v původním zarušeném signálu. Ve výstupním fEKG jsou stále ještě patrné mateřské QRS komplexy. Jejich amplituda je však nižší než amplituda QRS komplexů plodu. Pro doplnění byl dále vykreslen průběh signálu fEKG měřený prostřednictvím skalpové elektrody přímo na povrchu hlavičky plodu. V případě porovnání extrahovaného a měřeného signálu fEKG nemůžeme tyto signály srovnávat z hlediska velikosti signálů, neboť signál měřený přímo na hlavičce plodu má vždy vyšší amplitudu než signál měřený přes břišní stěnu matky. Můžeme však tyto signály porovnat z hlediska pozic QRS komplexů, které by po extrakci měly zůstat zachované.

Potlačení nežádoucího rušení v podobě mateřské složky je patrné i z tvaru amplitudového spektra zobrazeného na Obr. 28. Zde je vidět porovnání amplitudových spekter kontaminovaného signálu (vstupní signál fEKG*) a signálu extrahovaného (výstupní signál fEKG). Výše popsané grafické výstupy odpovídají výsledkům dosaženým u testování datového souboru r01. Pro ostatní záznamy jsou tyto časové a frekvenční analýzy součástí Příloha CD.



Obr. 28: Porovnání vstupního a výstupního signálu spolu se signálem fEKG snímaným pomocí skalpové elektrody (záznam r01).




Obr. 29: Amplitudové spektrum vstupního a výstupního signálu pro záznam r01.

Po subjektivním zhodnocení dosažených výsledků vizuální srovnávací metodou bylo dále přikročeno k hodnocení fHR v reálném čase a následně k výpočtu objektivních hodnotících parametrů. Na Obr. 30 je zaznamenáno grafické porovnání průběhů fHR získaného ze záznamu snímaného

skalповou elektrodou s průběhem fHR určeného z extrahovaného fEKG signálu prostřednictvím metody LMS v reálném čase na ukázkou pro datový soubor r01. Aby bylo možno tento grafický výstup vykreslit, muselo nejprve dojít k určení průběhu křivky fHR pro oba porovnávané signály. Toto bylo provedeno následujícím způsobem. Nejprve byla pro každou sekundu z obou srovnávaných signálů (skalповé fEKG a extrahované fEKG) o celkové délce 300 s stanovena hodnota fHR v každé sekundě záznamu. K tomuto bylo využito detektoru R vlny, pomocí kterého byl určen interval mezi dvěma R-kmity. Dále byl aplikován klouzavý průměr.

Klouzavý průměr se používá pro vyhlazení signálu a vytvoření odhadu trendu nějaké časové řady (v tomto případě je to hodnota tepové frekvence v každé sekundě záznamu). Lze ho určit jako aritmetický průměr několika po sobě jdoucích hodnot. Pro tuto práci bylo zvoleno 5 po sobě jdoucích vzorků.



Obr. 30: Porovnání průběhů fHR pro záznam r01 (metoda LMS).

Obr. 30 zobrazuje porovnání signálů fHR v čase pro signál referenční získaný snímáním skalповou elektrodou a extrahovaného signálu při použití HA s adaptivním blokem využívajícím metodu LMS. Z obrázku je patrné, že metoda LMS dosahuje velice dobrých výsledků, neboť signál extrahovaný kopíruje trend referenční křivky poměrně přesně. Hodnoty statistických parametrů pro objektivní hodnocení a pro každý z testovaných datových souborů jsou zaznamenány v Tab. 19.

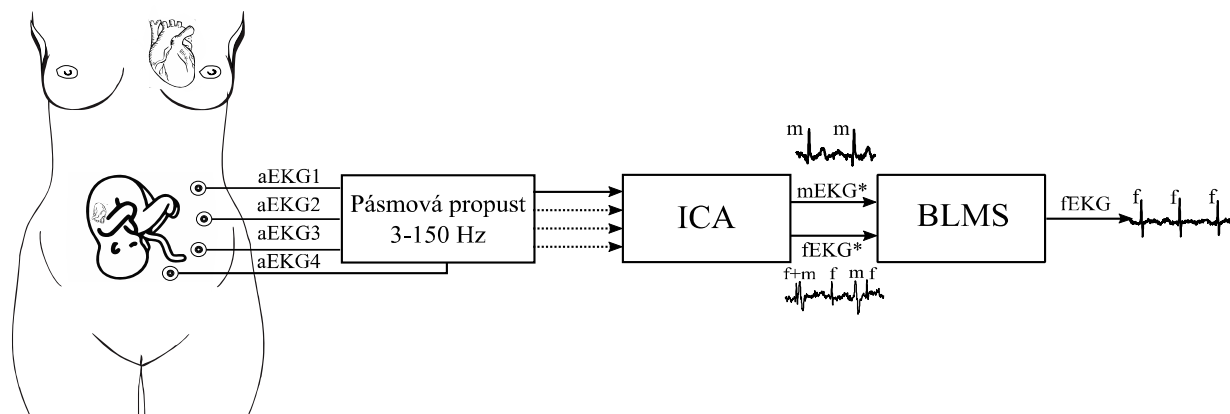
Tab. 19: Statistické hodnocení navrženého HA při použití metody LMS.

Záznam	TP	FP	FN	ACC [%]	SE [%]	PPV [%]	F1 [%]
r01	643	2	1	99,54	99,85	99,69	99,77
r02	657	19	3	96,76	99,55	97,189	98,35
r03	595	19	89	84,64	86,99	96,91	91,68
r04	471	146	161	60,54	74,53	76,34	75,42
r05	643	3	2	99,23	99,69	99,54	99,61
r06	368	315	306	37,21	54,60	53,88	54,24
r07	454	89	173	63,41	72,41	83,61	77,61
r08	651	2	0	99,69	100	99,69	99,85
r09	644	5	13	97,28	98,02	99,23	98,62
r10	614	51	23	89,24	96,39	92,33	94,32

Kvalita extrahovaného systému byla posuzována na základě statistických parametrů ACC, SE, PPV a F1. Aby se jednalo o uspokojivé výsledky, neměly by tyto parametry dosahovat nižších hodnot než 75 %. Největší důraz při hodnocení kvality filtrace byl kladen zejména na hodnotu F1 označující kvalitu filtrace a parametru ACC, který představuje přesnost daného algoritmu. Podle výsledků zaznamenaných v Tab. 19 lze usoudit, že metoda LMS dosahuje vynikajících výsledků ($F1 \geq 90\%$) u většiny testovaných záznamů. U záznamů r04 a r07 jsou hodnoty parametru F1 okolo 75 %. Nejhorších výsledků všech určených parametrů bylo dosaženo u datového souboru r06.

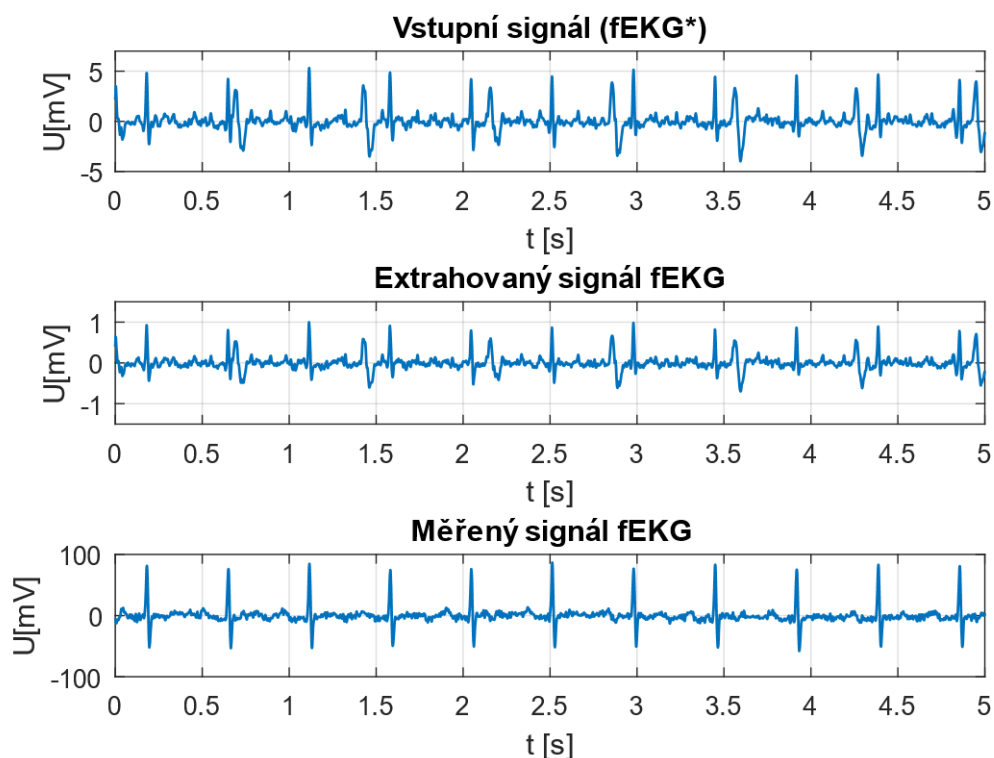
5.5.2 BLMS

Chyba! Nenalezen zdroj odkazů. zobrazuje testovaný HA využívající kombinace metod ICA a BLMS. Tento algoritmus využívá rozkladu vstupního signálu aEKG na jednotlivé komponenty (mEKG* a fEKG*) prostřednictvím metody ICA. Následně je na tyto odhadnuté signály aplikována metoda BLMS, jejímž cílem je úplné potlačení mEKG komponenty v extrahovaném fEKG signálu. Výsledky kombinace metod ICA a BLMS jsou popsány níže.




Obr. 31: Testovaný HA využívající metodu BLMS.

Subjektivní hodnocení výsledků testovaného HA využívající metodu BLMS proběhlo obdobným způsobem jako v předchozím případě při hodnocení kombinace ICA-LMS. Na **Chyba! Nenalezen zdroj odkazů.** je zobrazeno porovnání vstupního a výstupního signálu z filtru, navíc doplněno o signál fEKG snímáný prostřednictvím skalpové elektrody. Jak již bylo zmíněno výše, extrahovaný a měřený signál fEKG nelze porovnávat z hlediska amplitudy signálů, ale pouze v pozicích plodových QRS komplexů, které by po filtraci měly zůstat totožné. Při porovnání signálu fEKG* vstupujícího do bloku BLMS a signálu fEKG vystupujícího jako konečný extrahovaný signál je patrné snížení amplitudy výstupního signálu a zmenšení QRS komplexů matky. Nedošlo sice k úplnému odstranění mateřské složky, nicméně došlo k jejímu úspěšnému potlačení ve výstupním signálu.



Obr. 32: Porovnání vstupního a výstupního signálu spolu se signálem fEKG snímáným pomocí skalpové elektrody (záznam r01).

Potlačení nežádoucího rušení v podobě mEKG signálu je patrné nejen z časových průběhů signálu, ale také z tvaru amplitudového spektra zobrazeného na Obr. 33. I zde je zobrazeno porovnání vstupního (kontaminovaného) a výstupního (extrahovaného) signálu fEKG na ukázkou pro záznam r01. Pro ostatní datové soubory jsou časové i frekvenční grafické výstupy součástí Příloha CD.



Obr. 33: Amplitudové spektrum vstupního a výstupního signálu pro záznam r01.


Tab. 20: Statistické hodnocení navrženého HA při použití metody BLMS.

Záznam	TP	FP	FN	ACC [%]	SE [%]	PPV [%]	F1 [%]
r01	643	4	1	99,23	99,85	99,38	99,61
r02	655	24	5	95,76	99,24	96,47	97,83
r03	184	766	500	12,69	26,90	19,37	22,52
r04	368	284	264	40,18	58,23	56,44	57,32
r05	638	11	7	97,25	98,92	98,31	98,61
r06	326	649	348	24,64	48,37	33,44	39,54
r07	397	235	230	46,06	63,32	62,82	63,07
r08	650	5	1	99,09	99,85	99,24	99,54
r09	633	19	24	93,64	96,35	97,09	96,72
r10	573	76	64	80,37	89,95	88,29	89,11

Statistické vyhodnocení parametrů určujících kvalitu dosažených výsledků je shrnuto v Tab. 20. Extrakce signálu fEKG je tím úspěšnější, čím jsou hodnoty statistických parametrů ACC, SE, PPV a F1 vyšší. Na základě výsledků uvedených v Tab. 20 lze usoudit, že kombinace metod ICA-BLMS vykazuje

vynikajících výsledků, kdy jsou hodnoty všech pozorovaných parametrů $\geq 90\%$, u datových souborů r01, r02, r05, r08 r09 a r10. U záznamů r03, r04, r06 a r07 vykazuje testovaná kombinace metod neuspokojivých výsledků, neboť ani jeden z pozorovaných statistických parametrů nepřekročil hranici 75 %. Nejhorších výsledků bylo dosaženo u záznamu r03, kde bylo dosaženo výsledků $ACC=12,69\%$ a $F1=22,52\%$.

I pro metodu BLMS bylo vykresleno porovnání průběhů fHR referenčního a extrahovaného signálu na ukázkou pro záznam r01. Z grafu zobrazeném na Obr. 34 je vidět, že i v tomto případě je dosaženo poměrně dobrých výsledků a až na tři případy je trend referenční křivky poměrně přesně kopírován.

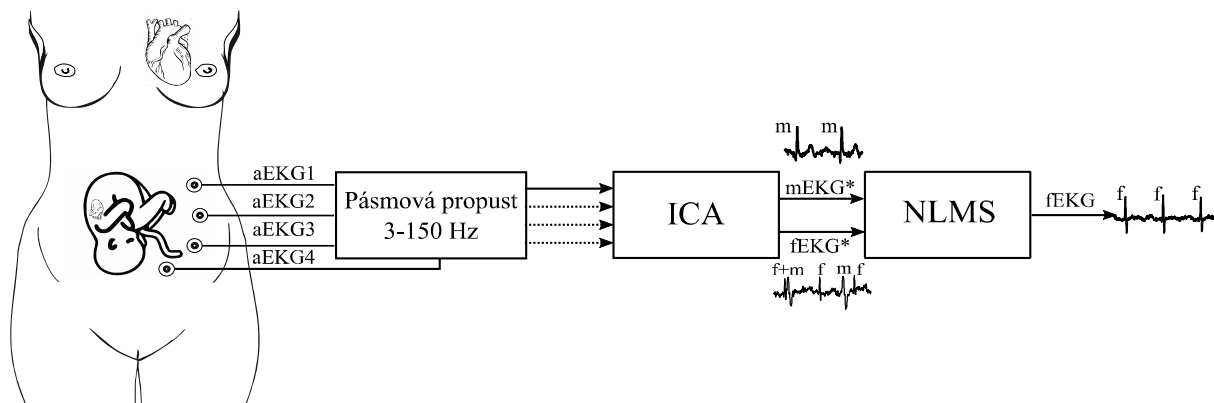


Obr. 34: Porovnání průběhů fHR pro záznam r01 (metoda BLMS).

Při porovnání statistického hodnocení u kombinací metod ICA-LMS a ICA-BLMS lze konstatovat, že HA využívající metodu LMS dosáhl mnohem lepších výsledků dle parametrů ACC i F1, kdy u všech, kromě jednoho záznamu (r06) nebyl splněn předpoklad, že hodnoty parametrů musí být vyšší než 75 %. Testovaná kombinace ICA-LMS dosáhla i lepších výsledků, co se počtu správné detekce plodových QRS komplexů (TP) týče.


5.5.3 NLMS

Na Obr. 35 je zobrazeno schéma navrženého hybridního algoritmu využívající pro extrakci fEKG signálu kombinaci metod ICA-NLMS. Vstupem do tohoto systému jsou čtyři signály aEKG snímané na povrchu břišní stěny matky. Po vyfiltrování nasnímaných signálů pásmovou propustí je na tyto signály aplikována metoda ICA, která umožní rozklad vstupního aEKG signálu na jednotlivé komponenty (mEKG* a fEKG*). Následně je na tyto odhadnuté signály aplikována metoda NLMS, jejímž cílem je úplné potlačení mEKG komponenty v extrahovaném fEKG signálu. Výsledky kombinace metod ICA a NLMS jsou popsány níže.



Obr. 35: Testovaný HA využívající metodu NLMS.


Na Obr. 36 Obr. 28 je zobrazen časový průběh vstupního signálu ($fEKG^*$) v porovnání s výstupním signálem, který představuje extrahovaný $fEKG$ signál. Navíc je toto porovnání doplněno o signál $fEKG$ snímáný tzv. skalpovou elektrodou. Tento signál slouží k vymezení časových intervalů mezi plodovými QRS komplexy. Pozice $fQRS$ by měla být před i po aplikaci metody NLMS stejná. Při porovnání $fEKG^*$ a $fEKG$ signálů je patrné, že došlo k úspěšnému potlačení mateřské komponenty v původním zarušeném signálu. Ve výstupním $fEKG$ jsou stále ještě patrné mateřské QRS komplexy. Jejich amplituda je však nižší než amplituda QRS komplexů plodu.



Obr. 36: Porovnání vstupního a výstupního signálu spolu se signálem $fEKG$ snímáným pomocí skalpové elektrody (záznam r01).


Potlačení nežádoucího rušení v podobě $mEKG$ signálu je patrné nejen z časových průběhů signálu, ale také z tvaru amplitudového spektra zobrazeného na Obr. 37 Obr. 33. I zde je zobrazeno

porovnání vstupního (kontaminovaného) a výstupního (extrahovaného) signálu fEKG na ukázkou pro záznam r01. Pro ostatní datové soubory jsou časové i frekvenční grafické výstupy součástí Příloha CD.



Obr. 37: Amplitudové spektrum vstupního a výstupního signálu pro záznam r01.

Následně bylo provedeno porovnání průběhů fHR referenčního a extrahovaného signálu po aplikaci HA využívajícího metodu NLMS. Výsledky jsou zaznamenány na Obr. 38. Zde je patrné, že v případě extrahovaného signálu touto metodou již dochází k častějším nepřesnostem při extrakci, a proto i trendy fHR křivek se v určitých intervalech liší.



Obr. 38: Porovnání průběhů fHR pro záznam r01 (metoda NLMS).

V Tab. 21 je shrnuto statistické vyhodnocení parametrů určujících kvalitu dosažených výsledků. Podle parametrů ACC, SE, PPV a F1, pracuje testovaná kombinace metod ICA-NLMS s 50% úspěšností. U záznamu r01, r02, r05, r08 a r09 vykazuje navržený HA vynikající výsledky jak v celkové přesnosti metody (ACC) a ve kvalitě filtrace (F1), tak i v počtu správně detekovaných fQRS komplexů.

Naopak u ostatních záznamů se hodnoty parametrů pohybují mezi 20 % a 70 % a nesplňují tak předem definovanou podmínku hranice pro přijetí (75 %).

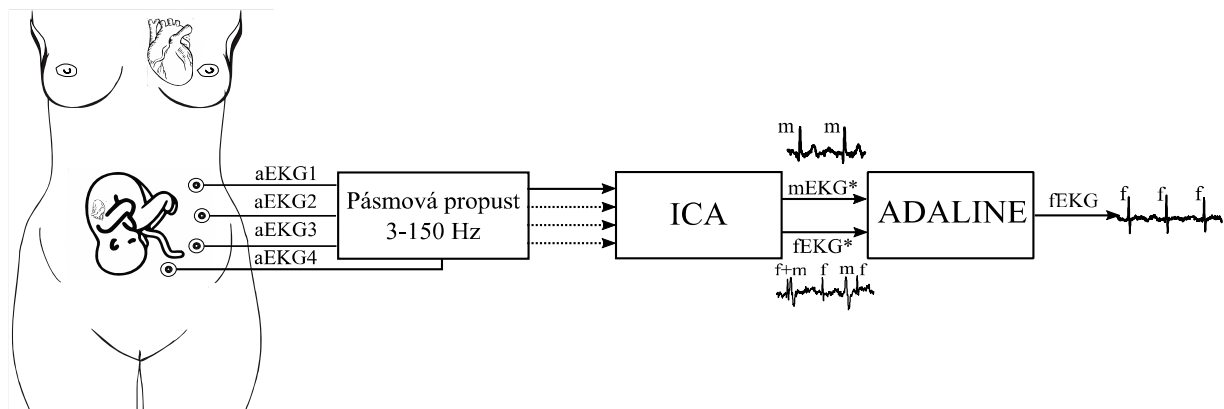
Tab. 21: Statistické hodnocení navrženého HA při použití metody NLMS.

Záznam	TP	FP	FN	ACC [%]	SE [%]	PPV [%]	F1 [%]
r01	635	20	9	95,63	98,60	96,95	97,77
r02	656	20	4	96,47	99,39	97,04	98,20
r03	354	138	330	43,07	51,75	71,95	60,20
r04	345	348	287	35,20	54,59	49,78	52,08
r05	639	16	6	96,67	99,07	97,56	98,31
r06	291	545	383	23,87	43,18	34,81	38,54
r07	368	281	259	40,53	58,69	56,70	56,68
r08	649	17	2	97,16	99,69	97,45	98,56
r09	636	17	21	94,36	96,81	97,40	97,10
r10	344	334	293	35,43	54,00	50,74	53,32

Při porovnání statistických výsledků všech kombinací využívajících metodu ICA a nějakou metodu z rodiny LMS, dosahuje jednoznačně nejlepších výsledků kombinace ICA-LMS, kde je parametr $F1 > 90\%$ u všech kromě jednoho z testovaných datových souborů. Naopak nejhorších výsledků dosáhla kombinace ICA-NLMS, která pracovala správně pouze u poloviny testovaných záznamů.


5.5.4 ADALINE

Poslední testovanou kombinací metod je ICA-ADALINE. Na základě teoretických poznatků lze předpokládat, že takto navržený HA bude dosahovat nejlepších výsledků (ze čtyř testovaných), neboť metoda ADALINE pro své učení využívá LMS algoritmus. Obr. 39 zobrazuje testovaný HA využívající kombinace metod ICA-ADALINE. Stejně jako předchozí případy, i tento algoritmus využívá rozkladu vstupního signálu aEKG na jednotlivé komponenty (mEKG* a fEKG*) prostřednictvím metody ICA. Následně je na tyto odhadnuté signály aplikována metoda ADALINE, která má za cíl úplné potlačení mateřské komponenty v extrahovaném fEKG signálu. Výsledky kombinace metod ICA-ADALINE jsou popsány níže.




Obr. 39: Testovaný HA využívající metodu ADALINE.

Subjektivní hodnocení výsledků testovaného HA využívající metodu ADALINE proběhlo obdobným způsobem jako v předchozích. Na Obr. 40 je zobrazeno porovnání časových průběhů vstupního a výstupního signálu z filtru, navíc doplněno o signál fEKG snímáný prostřednictvím skalpové elektrody, který slouží pouze k porovnání pozic plodových QRS komplexů před a po aplikaci metody ADALINE. Při porovnání signálu fEKG* vstupujícího do bloku ADALINE a signálu fEKG z něj vystupujícího jako konečný extrahovaný signál je patrné snížení amplitudy výstupního signálu a zmenšení QRS komplexů matky. Na rozdíl od předchozích kombinací je zde vidět téměř úplné odstranění materské komponenty zejména v kladné polaritě signálu




Obr. 40: Porovnání vstupního a výstupního signálu spolu se signálem fEKG snímáným pomocí skalpové elektrody (záznam r01).

Potlačení nežádoucího rušení v podobě mEKG signálu je patrné nejen z časových průběhů signálu, ale také z tvaru amplitudového spektra zobrazeného na Obr. 41. I zde je zobrazeno porovnání vstupního (kontaminovaného) a výstupního (extrahovaného) signálu fEKG na ukázkou pro záznam r01. Pro ostatní datové soubory jsou časové i frekvenční grafické výstupy součástí Příloha CD.



Obr. 41: Amplitudové spektrum vstupního a výstupního signálu pro záznam r01.

Po subjektivním vyhodnocení kvality filtrace navrženého HA porovnáním vstupních a extrahovaných signálů v časové a frekvenční oblast, bylo dále přikročeno k posouzení hodnoty fHR. Obr. 42 obsahuje porovnání průběhů signálů referenčního snímaného skalpovou elektrodou a signálu extrahovaného navrženým algoritmem na ukázkou pro datový soubor r01. Z obrázku je patrné, že z extrahovaného signálu metodou ADALINE došlo k velice přesnému určení průběhu fHR, který téměř přesně kopíruje trend referenční křivky.



Obr. 42: Porovnání průběhů fHR pro záznam r01 (metoda ADALINE).

Tab. 22: Statistické hodnocení navrženého HA při použití metody ADALINE.

Záznam	TP	FP	FN	ACC [%]	SE [%]	PPV [%]	F1 [%]
r01	643	2	1	99,54	99,85	99,69	99,77
r02	655	19	5	96,47	99,24	97,18	98,20
r03	669	25	15	94,36	97,81	96,39	97,10
r04	481	129	151	63,21	76,11	78,85	77,46
r05	644	6	1	98,93	99,85	99,08	99,46
r06	377	424	297	34,34	55,94	47,07	51,12
r07	433	166	194	54,61	69,06	72,29	70,64
r08	650	1	1	99,69	99,85	99,85	99,85
r09	643	4	14	97,28	97,87	99,38	98,62
r10	612	66	25	87,06	96,08	90,27	93,08

Tab. 22 obsahuje shrnutí statistického hodnocení navrženého HA při použití metody ADALINE. Kvalita extrahovaného systému byla posuzována, stejně jako v předchozích případech, na základě velikostí hodnot parametrů ACC, SE, PPV a F1. Aby bylo možno říci, že metoda pracuje správně, neměly by tyto parametry dosahovat nižších hodnot než 75 %. Největší důraz při hodnocení kvality filtrace byl kladen zejména na hodnotu F1 označující kvalitu filtrace a parametru ACC, který představuje přesnost daného algoritmu. Podle výsledků zaznamenaných v Tab. 22 lze usoudit, že metoda ADALINE dosahuje vynikajících výsledků ($F1 \geq 90\%$) u většiny testovaných záznamů. U záznamů r04 jsou hodnoty parametru F1 okolo 75 %. Nejhorších výsledků všech určených parametrů bylo dosaženo u datového souboru r06.

6 Provádění experimentů na datech z databáze Challenge 2013

V dalším bodě zpracování diplomové práce došlo k testování navrženého algoritmu na skupině dat označených jako Dataset B. Jedná se o data z databáze Computing Cardiology Challenge 2013, která jsou dostupná na webu PhysioNet (viz [83]). Data jsou složena ze sbírky jednodominutových fetálních EKG záznamů. Každý záznam obsahuje čtyři neinvazivní břišní signály. Jednotlivé záznamy pocházejí z různých zdrojů s různou frekvenční odezvou, rozlišením a konfigurací. Všechny signály však mají vzorkovací frekvenci 1000 Hz a obsahují 59950 hodnot. Součástí každého záznamu jsou navíc referenční anotace, které obsahují označení pozice každého fetálního QRS komplexu. Databáze rozděluje data do tří sad (Učební, Otevřená testovací a Skrytá testovací). Pro testování navrženého algoritmu byla využita pouze Učební sada, která obsahuje 25 záznamů s označením a01 až a25.

Při provádění níže uvedených experimentů bylo využito podobných postupů jako v případě testování Datasetu A. Výsledků je tedy dosaženo následujícím způsobem. V první iteraci byly testovány vhodné kombinace abdominálních elektrod přivádějících signály neinvazivního aEKG do bloku ICA. Dalším krokem bylo nalézt optimální nastavení parametrů, které ovlivňují kvalitu dosažených výsledků pro všechny čtyři testované metody. Nakonec opět došlo ke statistickému zhodnocení extrahovaných výsledků.

6.1 Kombinace elektrod vstupujících do ICA

Při hledání vhodné kombinace vstupních signálů bylo využito stejných postupů jako při analýze Datasetu A. Opět bylo vytvořeno 11 možných kombinací elektrod, z nichž byla vybrána pouze ta, při které vykazoval parametr ACC nejvyšší hodnotu. Shrnutí nejvhodnějších kombinací pro každý záznam je zaznamenáno v Tab. 23.

Tab. 23: Shrnutí kombinací elektrod pro jednotlivé záznamy.

Záznam	a1	a2	a3	a4	a5	a6	a7	a8	a9	a10
Kombinace elektrod	1,3,4	1,4	1,4	1,4	1,4	2,4	1,2,3,4	1,4	1,3,4	1,2,3,4

Záznam	a11	a12	a13	a14	a15	a16	a17	a18	a19	a20
Kombinace elektrod	1,4	1,2,3,4	2,4	1,2,3,4	1,4	1,4	3,4	3,4	2,3	2,3

Záznam	a21	a22	a23	a24	a25
Kombinace elektrod	1,3,4	1,4	2,4	1,4	2,3

6.2 Optimalizace parametrů filtru

Při testování rozsahu metod LMS, NLMS a BLMS bylo vycházeno z výsledků dosažených při optimalizaci prováděné na Datasetu A. Počáteční rozsah všech metod byl pro první iteraci zvolen pro M od 0 do 100 a pro μ od 0,001 do 0,1. Při hodnocení vhodného nastavení parametrů byl opět největší důraz kladen na hodnotu parametru kvality filtrace F1. Výsledné hodnoty parametrů M a μ , při kterých bylo dosaženo nejvyšší hodnoty F1, jsou zaznamenány v Tab. 24, Tab. 25 a Tab. 26 pro všechny tři testované metody.

Tab. 24: Optimální nastavení parametrů pro algoritmus LMS.

Záznam	M [-]	μ [-]	F1 [%]	Čas [s]
a01	10	0,002	94,48	0,98
a02	1	0,001	21,05	0,47
a03	50	0,003	91,83	0,39
a04	1	0,01	100	0,52
a05	1	0,004	100	0,42
a06	1	0,04	59,41	0,36
a07	1	0,1	49,83	0,44
a08	1	0,002	100	0,37
a09	10	0,004	40,29	0,56
a10	10	0,002	90,06	2,91
a11	30	0,1	25,00	2,59
a12	20	0,004	82,81	2,31
a13	90	0,05	78,76	2,29
a14	30	0,001	80,62	2,46
a15	10	0,008	100	2,43
a16	1	0,001	17,27	2,49
a17	70	0,01	100	2,46
a18	90	0,008	20,51	2,43
a19	50	0,05	92,91	2,49
a20	40	0,07	85,71	2,47
a21	10	0,003	77,13	2,42
a22	1	0,03	100	2,48
a23	20	0,1	60,68	2,51
a24	60	0,006	87,16	2,56
a25	40	0,03	88,62	2,64

Tab. 24 obsahuje shrnutí nejlepších dosažených výsledků při hledání vhodné pracovní oblasti metody LMS. Pro každý ze záznamů je zde uvedeno nastavení parametru M a μ , výsledná hodnota parametru F1 a výpočetní náročnost prováděného výpočtu. Průměrná doba výpočtu se pohybuje okolo 1,78 s. Z tabulky je patrné, že u více než poloviny záznamů došlo k překročení hraniční hodnoty 75 % u parametru F1. U 8 z 25 záznamů je hodnota F1 pod 60 %, u pěti záznamů je naopak rovna 100 %.

V případě metody BLMS bylo nutno kromě rozsahu M a μ nastavit také velikost bloku, která by měla mít hodnotu celočíselného násobku délky signálu. V tomto experimentu byly testovány velikosti BS =5, 25, 50 a 550. Nejlepší výsledky, kdy byly hodnoty F1 nejvyšší, jsou zaznamenány v Tab. 25.

Tab. 25: Optimální nastavení parametrů pro algoritmus BLMS.

Záznam	M [-]	μ [-]	BS [-]	F1 [%]	Čas [s]
a01	1	0,001	50	89,33	5,13
a02	60	0,09	25	31,46	0,52
a03	40	0,006	50	88,43	0,36
a04	1	0,009	25	100	0,35
a05	1	0,005	25	100	0,43
a06	70	0,07	5	59,87	0,76
a07	1	0,002	50	46,10	0,48
a08	1	0,002	25	100	0,36
a09	40	0,01	50	38,26	0,41
a10	1	0,001	550	80,47	0,54
a11	20	0,09	25	34,55	3,24
a12	1	0,01	550	55,72	5,78
a13	20	0,008	50	51,59	4,51
a14	10	0,003	550	61,87	3,03
a15	50	0,001	25	99,63	2,62
a16	70	0,07	50	43,67	2,21
a17	100	0,008	50	98,87	2,24
a18	30	0,07	25	26,40	2,43
a19	40	0,002	50	76,07	2,29
a20	70	0,004	50	63,21	2,25
a21	1	0,001	50	74,48	2,23
a22	1	0,05	50	100	2,24
a23	20	0,009	50	59,29	2,36
a24	50	0,003	550	75,0	2,29
a25	20	0,006	550	61,11	2,32

Při porovnání Tab. 24 a Tab. 25 je patrné, že u metody BLMS došlo k poklesu maximálních hodnot parametru F1, zatímco průměrná výpočetní náročnost vzrostla na 2,05 s. Dále Tab. 26 obsahuje shrnutí nejlepších dosažených výsledků při hledání vhodné pracovní oblasti metody NLMS. Pro každý ze záznamů je zde uvedeno nastavení parametru M a μ , výsledná hodnota parametru F1 navíc doplněná o výpočetní náročnost prováděného výpočtu.

Tab. 26: Optimální nastavení parametrů pro algoritmus NLMS.

Záznam	M [-]	μ [-]	F1 [%]	Čas [s]
a01	80	0,002	90,07	3,34
a02	20	0,07	23,16	0,46
a03	1	0,04	43,14	0,36
a04	10	0,001	95,09	0,36
a05	10	0,001	96,92	0,43
a06	90	0,001	58,36	0,37
a07	60	0,001	47,89	0,37
a08	10	0,001	100	0,41
a09	1	0,07	25,22	0,33
a10	90	0,001	80,71	0,39
a11	20	0,01	22,13	2,04
a12	20	0,03	56,23	2,07
a13	40	0,02	53,64	2,12
a14	30	0,03	49,07	2,17
a15	100	0,001	96,38	2,14
a16	1	0,001	23,68	2,28
a17	70	0,002	98,49	2,29
a18	1	0,001	21,58	2,49
a19	50	0,05	56,57	2,36
a20	50	0,1	55,85	2,67
a21	100	0,001	73,89	2,52
a22	10	0,001	98,44	2,54
a23	40	0,09	49,61	2,54
a24	10	0,009	59,26	2,46
a25	40	0,009	55,91	2,47

Při hledání pracovní oblasti parametrů p a η byly experimenty prováděny stejným způsobem jako byl popsán v kapitole 5.4.4. V Tab. 27 je zaznamenáno konečné nastavení parametrů pro každý záznam, které bude dále použito pro statistickou analýzu navrženého filtru, spolu s jejich výpočetní náročností.

Tab. 27: Optimální nastavení parametrů pro algoritmus ADALINE

Záznam	p [-]	η [-]	F1 [%]	Čas [s]
a01	10	0,003	94,19	1,29
a02	70	0,1	35,39	0,86
a03	70	0,1	91,73	0,84
a04	1	0,001	100	0,26
a05	1	0,001	100	0,31
a06	40	0,001	61,13	0,76
a07	1	0,003	49,18	0,26
a08	1	0,001	100	0,28
a09	10	0,005	36,64	0,70
a10	10	0,004	89,21	0,68
a11	30	0,1	56,73	2,39
a12	40	0,001	90,93	2,43
a13	50	0,005	91,02	2,59
a14	60	0,001	84,73	2,53
a15	50	0,001	100	2,54
a16	60	0,02	40,97	2,56
a17	50	0,008	99,62	2,58
a18	60	0,1	21,05	2,60
a19	90	0,004	92,97	2,73
a20	40	0,09	87,97	2,59
a21	10	0,005	76,23	2,56
a22	1	0,001	100	2,15
a23	80	0,002	91,60	2,77
a24	60	0,008	86,25	2,75
a25	10	0,08	92,66	2,71

6.3 Statistická analýza a hodnocení dosažených výsledků

Stejně jako u hodnocení kvality experimentů u záznamů z Datasetu A, i v této skupině bylo po nalezení optimálního nastavení pro každou metodu a každý záznam přikročeno ke Statistické analýze dosažených výsledků. Při hodnocení kvality filtrace bylo kromě objektivního hodnocení prostřednictvím

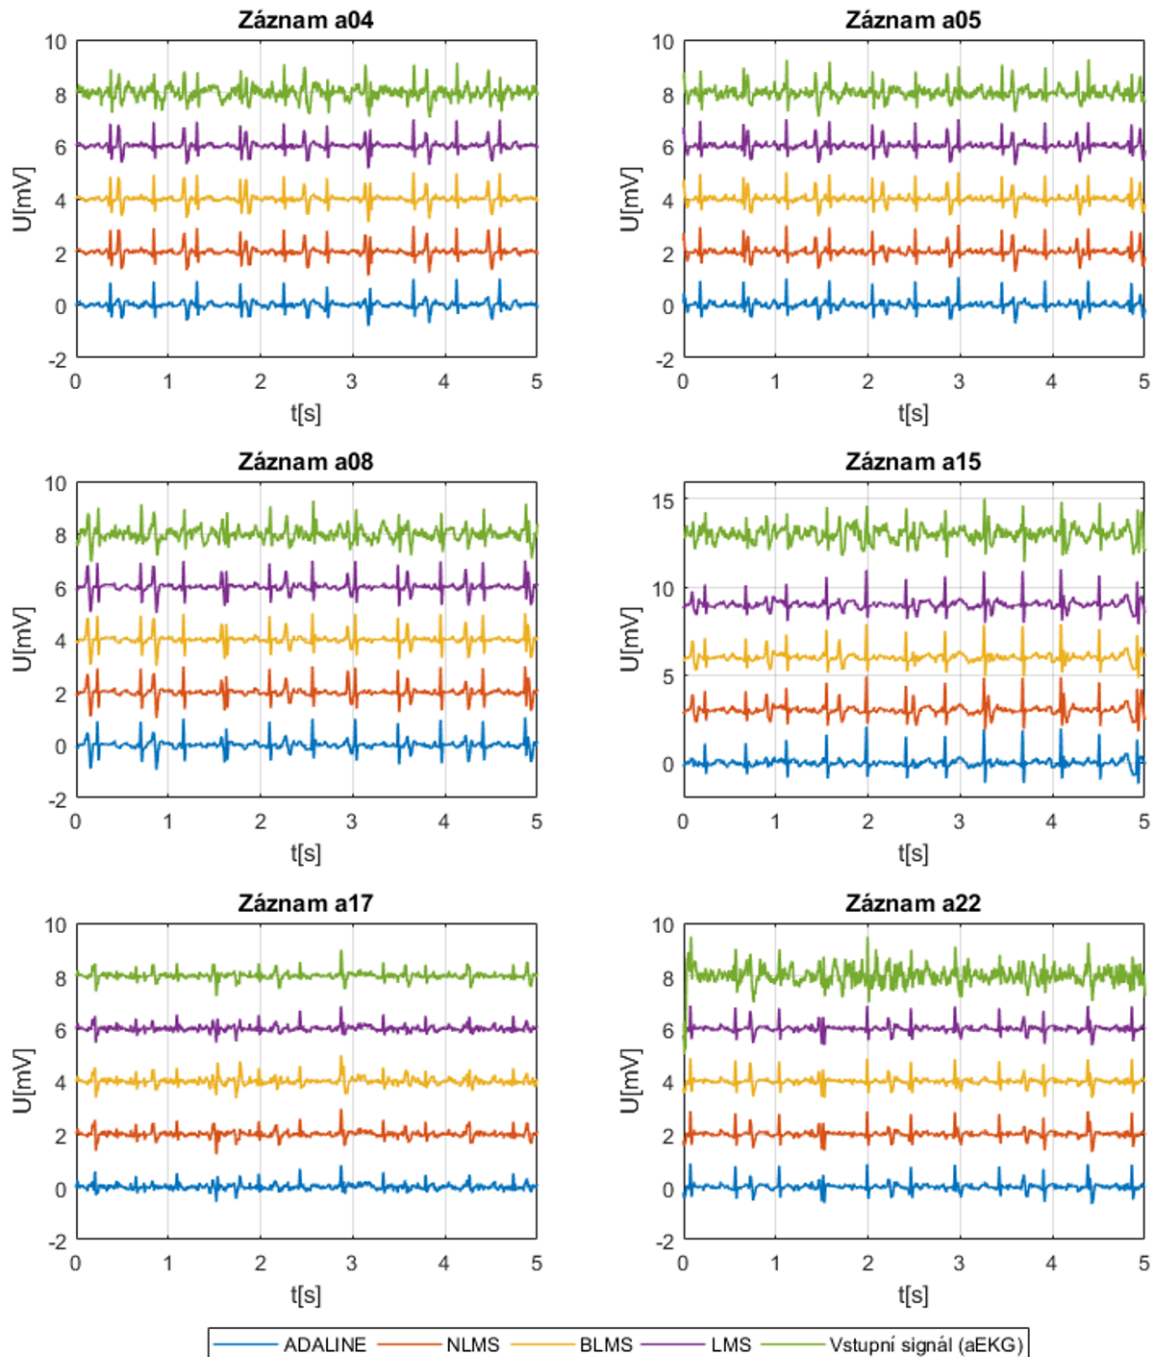
parametrů F1, SE a PPV využito také subjektivní srovnávací metody signálů před filtrací a po filtraci nejen v časové, ale také ve frekvenční oblasti. Zhodnocení dosažených výsledků pro zvolené záznamy je popsáno níže.

Tab. 28: Shrnutí nejlepších výsledků pro všechny testované algoritmy.

	LMS			NLMS			BLMS			ADALINE		
	F1 [%]	SE [%]	PPV [%]	F1 [%]	SE [%]	PPV [%]	F1 [%]	SE [%]	PPV [%]	F1 [%]	SE [%]	PPV [%]
a01	94,48	94,48	94,48	90,07	93,79	86,62	89,33	92,41	86,45	94,19	95,17	93,24
a02	21,05	18,75	24,00	23,16	20,63	26,40	31,46	36,88	27,44	35,39	27,50	51,16
a03	91,83	92,19	91,47	43,14	42,97	43,31	88,43	83,59	93,86	91,73	95,31	88,41
a04	100	100	100	95,09	97,67	92,65	100	100	100	100	100	100
a05	100	100	100	96,92	97,67	96,18	100	100	100	100	100	100
a06	59,41	56,25	62,94	58,36	55,63	61,38	59,87	56,88	63,19	61,13	56,88	64,09
a07	49,83	56,92	44,31	47,89	56,92	41,34	46,10	54,62	39,89	49,18	57,69	42,86
a08	100	100	100	100	100	100	100	100	100	100	100	100
a09	40,29	41,54	39,13	25,22	22,31	29,00	38,26	50,77	30,70	36,64	36,92	36,36
a10	90,06	88,00	92,22	80,71	77,71	83,95	80,47	77,71	83,44	89,21	87,43	91,07
a11	25,00	16,43	52,27	22,13	18,57	27,39	34,55	40,71	30,00	56,73	54,29	56,30
a12	82,81	85,51	80,27	56,23	57,25	55,25	55,72	68,84	46,80	90,93	88,41	88,41
a13	78,76	70,64	89,00	53,64	55,56	51,85	51,59	51,59	51,59	91,02	88,09	82,84
a14	80,62	84,55	77,04	49,07	53,66	45,21	61,87	69,92	55,48	84,73	90,24	79,86
a15	100	100	100	96,38	99,25	93,66	99,63	100	99,26	100	99,25	99,25
a16	17,27	14,62	21,11	23,68	20,77	27,55	43,67	53,08	37,10	40,97	43,85	36,08
a17	100	100	100	98,49	99,24	97,76	98,87	99,24	98,50	99,62	100	98,51
a18	20,51	18,67	22,76	21,58	20,00	23,44	26,40	31,33	22,82	21,05	18,00	23,08
a19	92,91	92,91	92,91	56,57	55,91	57,26	76,07	70,08	83,18	92,97	85,04	78,83
a20	85,71	84,73	86,72	55,85	56,49	55,22	63,21	51,15	82,72	87,97	89,31	86,68
a21	77,13	77,93	76,35	73,89	75,17	72,67	74,48	74,78	74,48	76,23	76,55	76,03
a22	100	100	100	98,44	100	96,92	100	100	100	100	100	100
a23	60,68	56,35	65,74	49,61	50,79	48,49	59,29	59,52	59,06	91,60	91,27	83,33
a24	87,16	91,06	83,58	59,26	65,04	54,42	75,0	63,42	91,77	86,25	91,87	75,84
a25	88,62	87,20	90,08	55,91	56,80	55,04	61,11	61,60	60,63	92,66	96,00	89,55

V Tab. 28 je zaznamenán souhrn výsledků statistických parametrů pro všechny testované algoritmy. Dle zobrazených výsledků lze říci, že nejlepších výsledků dosáhla metoda ADALINE, která vykazuje vynikající výkon u většiny testovaných datových souborů. Naopak nejhorších výsledků

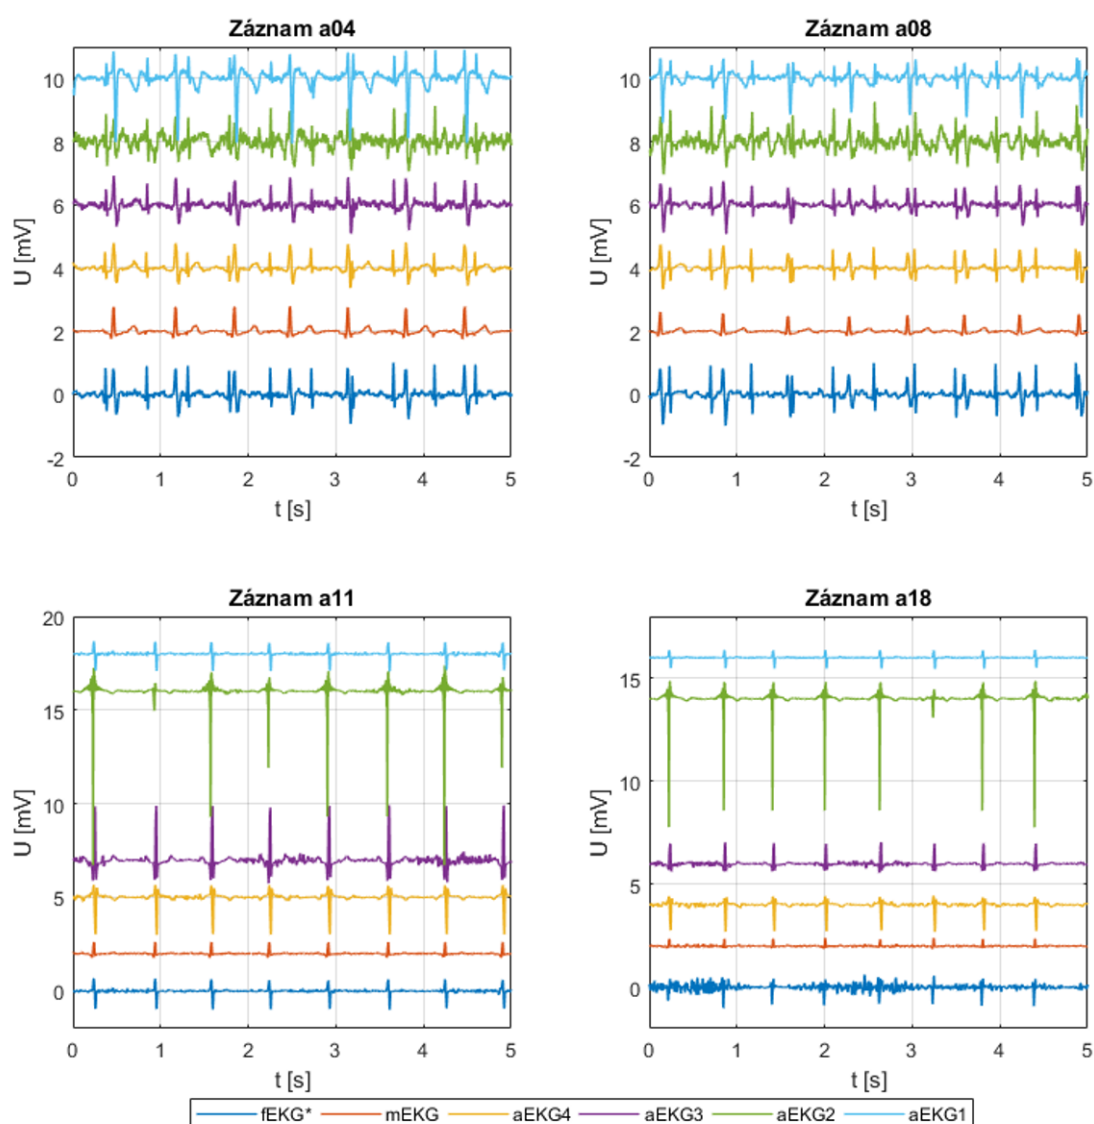
extrakce bylo dosaženo po aplikaci metody NLMS, neboť tato metoda nedokázala u většiny z 25 testovaných záznamů dostatečně potlačit mateřskou komponentu. Dále stojí za povšimnutí, že u záznamů a04, a05, a08, a15, a17 a a22 dosahuje parametr kvality filtrace F1 hodnot velice blízkých nebo rovných 100 %. Grafické výstupy porovnání vstupních a výstupních signálů pro těchto nejlepších šest záznamů jsou zobrazeny na Obr. 43. Ostatní časové průběhy shrnující porovnání signálů pře a po aplikaci testovaného HA jsou součástí Příloha CD.



Obr. 43: Porovnání vstupního a výstupních signálů pro 6 signálů s nejlepším výsledkem.

Naopak u záznamů a02, a06, a07, a09, a11, a16 a a18 hodnoty statistických parametrů nepřekročily 65 % ani u jedné z testovaných metod. Hodnoty parametrů, které nepřesáhly hodnotu 65 %, jsou v tabulce barevně podbarveny.

Jak již bylo zmíněno výše, kvalita extrakce, a tím i výkon adaptivního systému, silně koreluje s kvalitou vstupních signálů. Některé odhady mateřské komponenty (signály mEKG*) prostřednictvím metody ICA dosahovaly nízké kvality (obsahovaly pozůstatky plodových QRS komplexů a šumu), což vedlo k následnému snížení přesnosti extrakce fEKG signálů. Morfologie referenčního signálu mEKG* by navíc měla odpovídat tvaru mateřské složky v fEKG*. Obr. 44 zobrazuje porovnání abdominálních signálů z testované databáze spolu se signály odhadovanými prostřednictvím algoritmu ICA na ukázkou pro dva záznamy s nejlepšími (a04 a a08) a dva záznamy s nejhoršími (a11 a a18) výsledky, které byly dále použity jako referenční a primární vstupy do adaptivního systému v navrženém hybridním algoritmu.

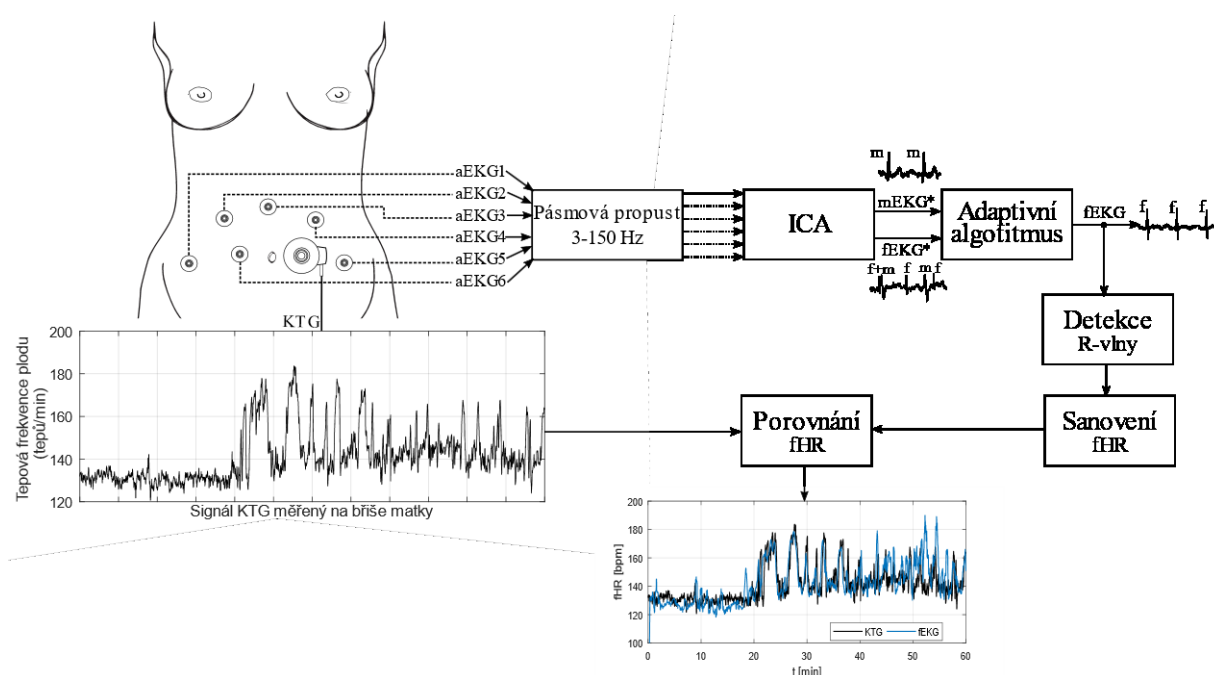


Obr. 44: Porovnání vstupních signálů snímaných z povrchu břišní stěny matky (aEKG1 – aEKG4) s výstupem metody ICA (fEKG* a mEKG).

Na Obr. 44 je zaznamenáno porovnání vstupních signálů aEKG snímaných pomocí čtyř elektrod umístěných na břicho matky a dvou odhadovaných signálů metodou ICA. Signál mEKG představuje odhadnutou mateřskou komponentu a signál fEKG* je signál abdominální, ve kterém je ale oproti původnímu aEKG signálu mateřská komponenta potlačena. Toto porovnání je zde zaznamenáno pro čtyři různé záznamy. U záznamů a04 a a08 ale pozorovat, že snímané signály vykazují poměrně vysokou kvalitu, a proto i odhadovaný signál fEKG* obsahuje poměrně velkou plodovou komponentu, zatím co mateřská komponenta je potlačena a odhadovaný mEKG signál je čistý, bez jakéhokoliv ovlivnění rušivými signály. U záznamů a11 a a18 už je kvalita snímaných aEKG signálů mnohem nižší. Není zde totiž ani v jednom ze snímaných signálů patrná plodová komponenta. Tudíž odhadovaný fEKG* signál odpovídá také více mateřské komponentě, než aby nesl nějakou informaci o srdeční činnosti plodu.

7 Provádění experimentů na reálných datech z laboratoře

Pro testování výkonnosti navrženého hybridního algoritmu v průběhu těhotenství byla využita data z měření provedeného u těhotné ženy v 34. týdnu těhotenství. Tato data jsou v Tab. 2 označena jako Dataset C a obsahují v sobě nejen neinvazivní signály aEKG, ale také signál referenční. Z důvodu měření v laboratoři a nikoli v průběhu porodu zde nemůže být použit referenční signál v podobě fEKG signálu snímaného pomocí skalpové elektrody (tak jako tomu bylo v předchozích případech při testování Datasetu A a Datasetu B). Jako referenční signál zde slouží záznam KTG, který byl snímán ve stejném okamžiku jako signály aEKG. Celková délka záznamu je 60 minut a vzorkovací frekvence signálů f_{vz} je 600 Hz.




Obr. 45: Blokové schéma hybridního algoritmu, který jako referenční signál využívá záznam z KTG.

Signály aEKG byly snímány pomocí šesti elektrod s označením (aEKG1 – aEKG6) umístěných na břiše matky. Z těchto šesti naměřených aEKG signálů bylo následně vytvořeno 57 možných kombinací pro vstup do algoritmu ICA, ze kterých byla následně vybrána jedna, která podle subjektivního hodnocení autorky dosahovala nejlepších výsledků. Poté, co byla nalezena optimální kombinace elektrod, bylo přikročeno k testování navrženého hybridního algoritmu s různými bloky adaptivního systému.


Jako první byl testován HA s extrakčním blokem využívající metodu ADALINE. Nejprve, stejně jako tomu bylo u testování Datasetu A a Datasetu B, bylo potřeba zvolit počáteční pracovní nastavení parametrů p a η . V prvním kroku byla zvolena pracovní oblast parametru p v rozmezí od 1 do 100 a pro hodnotu η od 0,001 do 0,1, přičemž pro každý extrahovaný signál byla vypočtena průměrná tepová frekvence plodu a vykreslen časový průběh extrahovaného signálu. Na základě subjektivního hodnocení autorky byla tato pracovní oblast zúžena a to následovně. Pro hodnoty p bylo zvoleno rozpětí od 10 do 40 a po hodnotu η od 0,001 do 0,005. Nakonec bylo jako nevhodnější nastavení pro metodu ADALINE zvoleno p je rovno 20 a η je 0,004. Výsledky ukázaly, že navrhovaný hybridní systém je schopen extrahovat fEKG signál dostatečně přesně, aby určil fHR stopu podobné kvality jako u metody KTG.

Obr. 46 zobrazuje porovnání trendů fHR křivky získané prostřednictvím KTG a extrahovaného signálu získaného pomocí navrženého HA, který využívá jako adaptivní algoritmus metodu ADALINE.




Obr. 46: Porovnání trendů signálu fHR získaného pomocí KTG se signálem fHR stanoveného z extrahovaného fEKG signálu pomocí HA systému využívající metodu ADALINE (nastavení: $p=20$, $\eta=0,004$).


Dále byly testovány HA s extrakčním blokem využívající metody LMS, NLMS a BLMS. Jako v předchozím případě, i zde bylo nutno nejprve stanovit vhodné nastavení parametrů M a μ . Nejprve byla zvolena pracovní oblast pro $M = 1-100$ a $\mu = 0,001-0,1$. Následně byla dle subjektivního hodnocení dosažených výsledků (grafických výstupů porovnání signálu před a po filtraci) zvolena úprava nastavení hodnoty obou parametrů. Pro metody LMS a BLMS byla pracovní oblast zúžena pro M od 10 do 30 a pro μ od 0,001 o 0,008 a pro metodu NLMS byla zvolena konstantní hodnota parametru μ na hodnotu 0,00, zatím co hodnota parametru M byla proměnná od 50 do 300. Nakonec bylo jako nejlepší nastavení pro metodu LMS zvoleno $M = 20$ a $\mu = 0,004$, pro BLMS $M = 20$ a $\mu = 0,001$ a pro NLMS $M = 250$ a $\mu = 0,001$. Grafické výstupy porovnání průběhu křivky fHR získané prostřednictvím KTG a extrahovaného signálu metodami LMS, BLMS a NLMS jsou zaznamenány níže.



Obr. 47: Porovnání trendů signálu fHR získaného pomocí KTG se signálem fHR stanoveného z extrahovaného fEKG signálu pomocí HA systému využívající metodu LMS (nastavení: $M=20$, $\mu=0,004$).



Obr. 48: Porovnání trendů signálu fHR získaného pomocí KTG se signálem fHR stanoveného z extrahovaného $fEKG$ signálu pomocí HA systému využívající metodu NLMS (nastavení: $M=250$, $\mu=0,001$).



Obr. 49: Porovnání trendů signálu fHR získaného pomocí KTG se signálem fHR stanoveného z extrahovaného $fEKG$ signálu pomocí HA systému využívající metodu BLMS (nastavení: $M=20$, $\mu=0,001$).

Z výše uvedených grafických výstupů (Obr. 46 až Obr. 49) lze pozorovat, že všechny průběhy fHR extrahovaných signálů sledují stejný trend jako průběh signálu KTG, až na určité odchylky, které jsou způsobené nepřesnou extrakcí. Navíc signál KTG také prochází několika úpravami, jako například autokorelace nebo průměrování, a proto porovnávané fHR signály nebudou mít nikdy úplně stejný průběh.

8 Diskuse dosažených výsledků

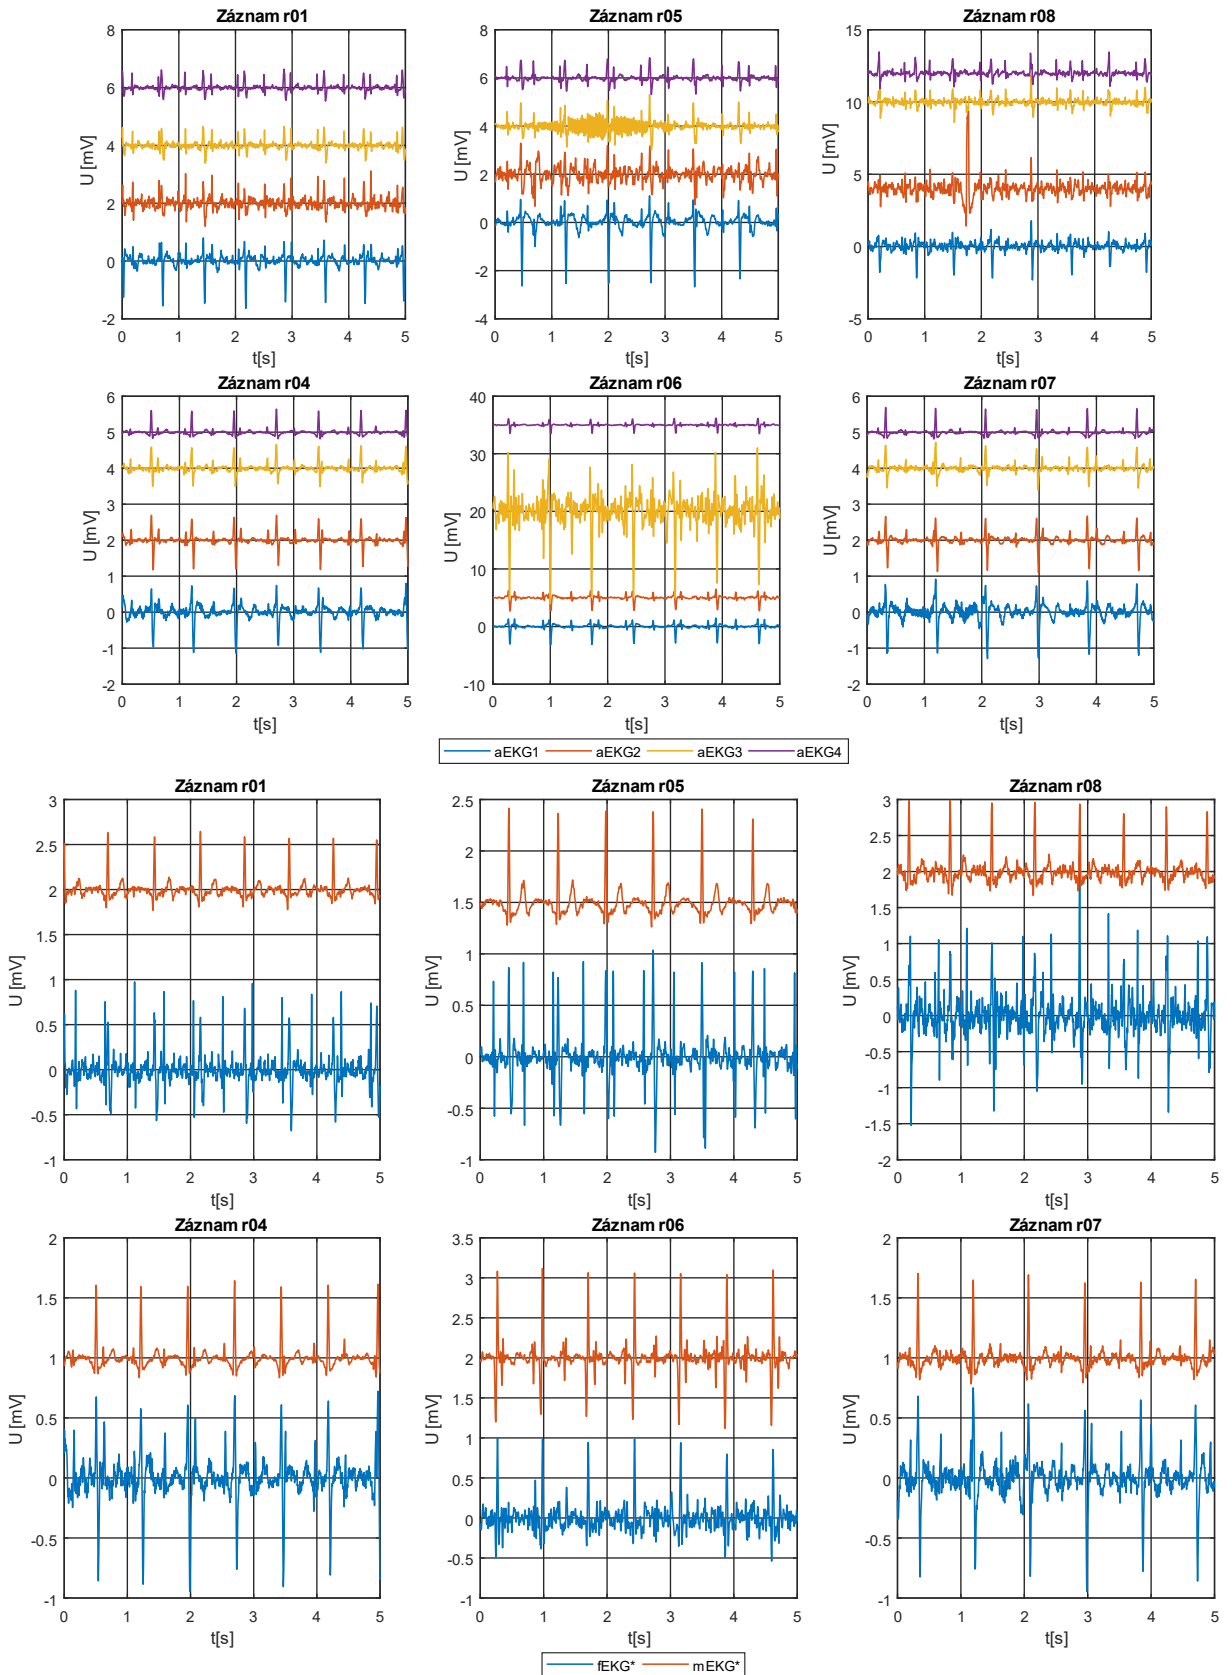
Tato kapitola se věnuje závěrečnému shrnutí a diskusi dosažených výsledků, které byly získány při provádění experimentů uvedených výše. Dále jsou zde také uvedena porovnání dosažených výsledků s některými veřejně dostupnými odbornými publikacemi.

Z výsledků dosažených při testování hybridního algoritmu na reálných datech z Datasetu A lze usoudit, že tento systém umožňuje extrakci signálu dostatečné kvality signálu téměř pro všechny záznamy obsažené v tomto datovém souboru. Tab. 29 ukazuje souhrn hodnot statistického parametru F1 pro každou z kombinací testovaných metod a pro každý záznam.

Tab. 29: Porovnání výsledků parametru F1 pro všechny testované kombinace metod.

Záznam	F1 [%]			
	ICA-LMS	ICA-NLMS	ICA-BLMS	ICA-ADALINE
r01	99,77	97,77	99,61	99,77
r02	98,35	98,20	97,83	98,20
r03	91,68	60,20	22,52	97,10
r04	75,42	52,08	57,32	77,46
r05	99,61	98,31	98,61	99,46
r06	54,24	38,54	39,54	51,12
r07	77,61	56,68	63,07	70,64
r08	99,85	98,56	99,54	99,85
r09	98,62	97,10	96,72	98,62
r10	94,32	53,32	89,11	93,08


Dle výsledků zaznamenaných v Tab. 29 ukazují algoritmy LMS a ADALINE vynikající výkonů (F1 > 90 %) u většiny testovaných datových souborů. Hlavním předpokladem pro dosažení kvalitních výsledků je správný odhad mEKG pomocí metody ICA. Odhad jednotlivých komponent je založen na statistických metodách, které vedou k nepředvídatelnosti výsledků. Na Obr. 50 jsou zobrazeny příklady aEKG signálů z Datasetu A spolu se signály odhadnutými pomocí metody ICA. Tyto signály byly dále použity jako primární a referenční vstupy do adaptivního algoritmu. Výkon adaptivního algoritmu silně koreluje s kvalitou jeho vstupů, zejména s referenčním signálem mEKG*.



Obr. 50: Porovnání vstupních a odhadovaných signálů pro 6 vybraných záznamů z Datasetu A.

Pro ukázkou bylo vybráno celkem šest testovaných záznamů. Záznamy r01, r05 a r08, které dosáhly nejlepších výsledků u všech testovaných kombinací metod, a záznamy r04, r06 a r07, které naopak dosáhly nejhorších výsledků extrakce fEKG. Hlavním rozdílem mezi vybranými záznamy je kvalita snímaných aEKG signálů a poměr mezi mateřskou a plodovou komponentou. Z Obr. 50 je patrné, že některé odhady mEKG * algoritmem ICA byly nízké kvality, což vedlo ke snížení přesnosti extrakce fEKG. Pro dosažení co nejpřesnější extrakce fEKG je důležitá také morfologie signálu mEKG*. Toto je vidět např. u záznamů r01, r05 nebo r08. Naopak u záznamů r04 a r07 mají mateřské QRS komplexy pouze kladnou polaritu, zatím co v odhadnutém signálu fEKG* mají polaritu kladnou i zápornou. Tyto rozdíly morfologie mateřské komponenty v jednotlivých signálech jsou způsobeny nepřesným umístěním transabdominálních svodů.

Kvalita extrahovaného signálu prostřednictvím navrženého hybridního algoritmu je také důležitá pro možnost monitorace fHR. Tento parametr je velice využíván v klinické praxi k vyhodnocení zdravotního stavu plodu. Obr. 51 ukazuje časové průběhy variability fHR pro tři zvolené záznamy v porovnání pro každou z testovaných kombinací metod. Referenční stopa fHR byla stanovena pomocí signálu snímaného skalpovou elektrodou. Na všechny průběhy fHR byl aplikován klouzavý průměr o velikosti okna 30, které se v klinické praxi reálně využívá. Výsledky ukazují, že všechny testované kombinace algoritmů s optimalizovaným nastavením vykazují výsledky dostatečné kvality. Tudiž získané průběhy fHR téměř přesně kopírují trend referenční křivky. Na základě tepové frekvence tedy byly shledány jen minimální rozdíly mezi testovanými algoritmy.



Obr. 51: Porovnání průběhů; fHR referenčního a extrahovaných signálů pro tři zvolené záznamy.

Pro ověření relevantnosti dosažených výsledků bylo dále přikročeno k porovnání výsledků s jinými veřejně dostupnými odbornými publikacemi zabývajícími se sledovanou problematikou. K těmto účelům byly vybrány studie, ve kterých autoři k hodnocení využívají stejně statistické parametry, jako byly využity v této práci. R. Martinek a spol. v [84] testují algoritmus využívající metody ICA a PCA na dvou datových souborech obsahující data z klinické praxe. Průměrné výsledky statistických parametrů, kterých bylo dosaženo pro obě datové skupiny, jsou zaznamenány v Tab. 30.

Tab. 30: Shrnutí výsledků prováděných experimentů uvedených ve studii [84].

Testovaná metoda	Použitá databáze	Se [%]	PPV [%]	ACC [%]	F1 [%]
ICA	ADFECGDB	98,23	98,87	97,13	98,55
PCA		98,27	98,68	97,17	98,56
ICA	Challenge 2013	84,45	99,7	84,26	91,16
PCA		82,05	99,45	81,86	59,63

Dále F. Andrenotti a kol. v [85] testovali funkčnost algoritmu TA (adaptace vzoru – template adaptation) na datovém souboru z databáze Challenge 2013. Autoři uvádějí následující dosažené výsledky (viz Tab. 31).

Tab. 31: Shrnutí výsledků prováděných experimentů uvedených ve studii [85].

Testovaná metoda	Použitá databáze	Se [%]	PPV [%]	ACC [%]	F1 [%]
TA	Challenge 2013	97,4	97,2	96,0	97,3

Behar a spol v [86] testují nejrůznější metody a jejich kombinace na reálných datech dostupných na webu Physionet. Nejlepších výsledků dosáhla kombinace ICA-TS. V Tab. 32 je zaznamenáno shrnutí průměrných hodnot, pro některé vybrané kombinace metod, testovaných ve zmíněné publikaci.

Tab. 32: Shrnutí výsledků prováděných experimentů uvedených ve studii [86].

Testovaná metoda	Použitá databáze	Se [%]	PPV [%]	F1 [%]
TS	ADFECGDB	81.8	81.7	81.6
ICA		69.1	60.0	63.7
PCA		57.4	47.9	51.6
TS-ICA		93.0	91.1	92.0
ICA-TS-ICA		93.8	92.2	93.0

V níže uvedené tabulce je pro srovnání doplněno shrnutí průměrných výsledků dosažených v této práci pro oba datové soubory obsahující data z webu Physionet (Dataset A a Dataset B).

Tab. 33 Shrnutí výsledků prováděných experimentů uvedených v této práci.

Testovaná metoda	Použitá databáze	Se [%]	PPV [%]	F1 [%]
ICA	ADFECGDB	93,82	88,19	90,93
ICA-LMS		91,93	93,83	92,80
ICA-NLMS		82,25	83,22	82,52
ICA-BLMS		86,98	84,38	85,50
ICA-ADALINE		92,86	92,55	92,69
ICA-LMS	Challenge 2013	80,76	82,66	81,15
ICA-NLMS		69,81	67,46	68,46
ICA-BLMS		74,05	74,43	73,60
ICA-ADALINE		82,81	79,75	82,53

Před porovnáváním je důležité zmínit, že všechny uvedené parametry, které shrnují výsledky experimentů popsaných ve výše zmíněných studiích, byly počítány z celkového počtu TP, FP a FN hodnot, nikoliv z průměru hodnot u jednotlivých signálů jako bylo provedeno v této práci. Dále je nutné podotknout, že žádný z uvedených článků netestuje stejné kombinace metod, jaké zde byly testovány.

Závěr

Monitorování zdravotního stavu plodu během porodu, ale i v průběhu celého těhotenství, je nezbytnou součástí dnešního moderního porodnictví. V současnosti je nejvíce používanou metodou EFM je metoda KTG, která umožňuje záznam průběhu tepové frekvence plodu a děložních kontrakcí. Tato metoda má však řadu nedostatků a nevýhod, které do jisté míry ovlivňují její přesnost. Také proto se čím dál více výzkumných pracovníků věnuje problematice neinvazivní monitorace fEKG plodu, která byla hlavním tématem této práce. Mnoho autorů odborných studií uvádí, že tato metoda monitoringu je velice slibnou metodou a v budoucnu by mohla v klinické praxi nahradit v současnosti nejvyužívanější KTG.

Doposud nejvyužívanější parametr pro hodnocení zdravotního stavu plodu v klinické praxi je fHR. Aby bylo možno přesně stanovit variabilitu tohoto parametru, musí být neinvazivně snímán signál vysoké kvality. Dále je pro určení fHR nezbytná přesná detekce plodové R-vlny. Ta je ovšem značně ovlivněna přesností extrakce fEKG signálu. V poslední době se však většina autorů odborných publikací zaměřujících se na danou problematiku zabývá vhodností nejrůznějších extrakčních metod a jejich kombinací. Tato práce představila hybridní extrakční systém složený z kombinace vybraných neadaptivních a adaptivních algoritmů. Celkem bylo na základě rešeršní části práce vybráno pět jednotlivých metod, a to metoda ICA, LMS, NLMS, BLMS a ADALINE. U všech z těchto metod byly uvedeny principy a využití v jiných studiích a následně byly matematicky popsány. Ve většině výše zmíněných studií byly tyto metody použity samostatně. Avšak pro zvýšení přesnosti extrakce fEKG došlo k vytvoření čtyř dále testovaných kombinací.

Hlavním cílem experimentální části práce byl návrh a softwarová realizace hybridního systému pro extrakci fEKG signálu z transabdominálního záznamu a následné hodnocení dosažených výsledků na reálných datech. Celkem byly experimenty prováděny na třech různých skupinách dat (Datasey A, B a C). Na základě testovaných datových souborů lze experimentální část rozdělit do tří bloků, z nichž v každém byla testovaná jiná datová skupina. V každém z těchto bloků je řešeno vhodné zvolení kombinací elektrod snímajících aEKG signál, které dále vstupují do metody ICA. Dále je řešeno hledání pracovní oblasti každé z testovaných adaptivních metod a následně optimalizace nastavení parametrů extrakčního adaptivního systému. Nakonec je pro experimenty s Datasey A a B provedeno hodnocení kvality dosažených výsledků prostřednictvím statistických parametrů porovnáním časových a frekvenčních průběhů signálů před a po filtraci a také na základě stanovené variability tepové frekvence plodu. Pro Dataset C, ve kterém je funkčnost navrženého algoritmu ověřována přímo na datech měřených v laboratoři, nemohlo být využito statistické vyhodnocení jako u předchozích dvou skupin dat, neboť se zde nejedná o data měřená v průběhu porodu a nemůže zde být snímán referenční signál fEKG pomocí skalpové elektrody. Výsledky reálných dat pro stanovení variability fHR, byly u většiny výsledků uspokojivé. V ostatních případech došlo alespoň ke zvýraznění plodové komponenty, včetně velikosti plodových R-vln.

V budoucnu by dosavadní práce mohla být rozšířena o další kombinace metod, jako např. ICA-ANFIS, anebo kombinace více adaptivních metod, jako např. KF-ANFIS. Zajímavé by také mohlo být využití algoritmu WT, avšak některé práce uvádějí, že po aplikaci tohoto algoritmu dochází k jistému zkreslení požadovaného signálu. Užitečné by dále mohlo být provádění analýzy morfologie ST úseku, ze kterého se dá předpokládat možný stav hypoxie plodu, nebo analýza délky QT intervalu.

Použitá literatura

- [1] SAMENI, Reza; CLIFFORD, Gari D. A review of fetal ECG signal processing; issues and promising directions. *The open pacing, electrophysiology & therapy journal*, 2010, 3: 4.
- [2] JANKŮ, Petr. Analýza ST úseku fetálního EKG v intrapartální diagnostice hypoxie plodu u rizikových gravidit. 2007. PhD Thesis. Masarykova univerzita, Lékařská fakulta.
- [3] SPONG, Catherine Y., et al. *Williams obstetrics*. New York: McGraw-Hill Education, 2009.
- [4] BEHAR, Joachim A., et al. Noninvasive fetal electrocardiography for the detection of fetal arrhythmias. *Prenatal diagnosis*, 2019, 39.3: 178-187.
- [5] SYMONDS, Edwin Malcolm; CHANG, Allan; SAHOTA, Daljit. *Fetal electrocardiography*. World Scientific, 2001.
- [6] RAJESH, A. V.; GANESAN, R. Comprehensive study on fetal ECG extraction. In: 2014 International Conference on Control, Instrumentation, Communication and Computational Technologies (ICCICCT). IEEE, 2014. p. 1187-1192.
- [7] SWEHA, Amir; HACKER, Trevor W.; NUOVO, Jim. Interpretation of the electronic fetal heart rate during labor. *American family physician*, 1999, 59: 2487-2506.
- [8] PETERS, Maria J., et al. Fetal magnetocardiography. In: *Advances in electromagnetic fields in living systems*. Springer, Boston, MA, 2005. p. 1-40.
- [9] MARCHON, Niyam; NAIK, Gourish; PAI, Radhakrishna. ECG Electrode Configuration to Extract Real Time FECG Signals. *Procedia Computer Science*, 2018, 125: 501-508.
- [10] GORENBERG, David M., et al. Fetal pulse oximetry: correlation between oxygen desaturation, duration, and frequency and neonatal outcomes. *American journal of obstetrics and gynecology*, 2003, 189.1: 136-138.
- [11] STILLER, Ruth, et al. How well does reflectance pulse oximetry reflect intrapartum fetal acidosis?. *American journal of obstetrics and gynecology*, 2002, 186.6: 1351-1357.
- [12] Intrapartální fetální pulsní oxymetrie [online]. [cit. 2017-10-20]. Dostupné z: <http://lekari.porodnice.cz/intrapartalni-fetalni-pulsni-oxymetrie>
- [13] ROZTOČIL, Aleš et al. *Moderní porodnictví*. Praha: Grada Publishing, 2008, 408 s. ISBN 97880-247-1941-2
- [14] SÄNGER, N., et al. Prenatal Foetal Non-invasive ECG instead of Doppler CTG—A Better Alternative?. *Geburtshilfe und Frauenheilkunde*, 2012, 72.07: 630-633.
- [15] COHEN, Wayne R.; HAYES-GILL, Barrie. Influence of maternal body mass index on accuracy and reliability of external fetal monitoring techniques. *Acta obstetrica et gynecologica Scandinavica*, 2014, 93.6: 590-595.
- [16] JAROS, Rene; MARTINEK, Radek; KAHANKOVA, Radana. Non-adaptive methods for fetal ECG signal processing: A review and appraisal. *Sensors*, 2018, 18.11: 3648.

- [17] JIRČÍKOVÁ, Jitka. Detekce parametrů vlny T z vícesvodového signálu EKG. Brno, 2012. Diplomová práce. Masarykova univerzita. Vedoucí práce Pavel Jurák.
- [18] JADHAV, Mrs Sonali H.; DHANG, Mrs DN. Extraction of Fetal ECG from Abdominal Recordings Combining BSS-ICA & WT Techniques. *International Journal of Engineering Research and Technology*, 2017, 10.1.
- [19] CLIFFORD, Gari D., et al. Non-invasive fetal ECG analysis. *Physiological measurement*, 2014, 35.8: 1521.
- [20] PENHAKER, Marek a Martin AUGUSTYNEK. Zdravotnické elektrické přístroje 1. 1. vyd. Ostrava: Vysoká škola báňská - Technická univerzita Ostrava, 2013, 411 s. ISBN 978-80-24831077.
- [21] MARTINEK, Radek. Využití komplexních adaptivních metod zpracování signálů pro zpřesnění diagnostické kvality abdominálního fetálního elektrokardiogramu. [online]. 2014 [cit. 2018-06-20]. Disertační práce. VŠB - Technická univerzita Ostrava, Fakulta elektrotechniky a informatiky. Vedoucí práce Jan Židek. Dostupné z: <http://theses.cz/id/imn429/>
- [22] JAGANNATH, D. J.; SELVAKUMAR, A. Immanuel. Issues and research on foetal electrocardiogram signal elicitation. *Biomedical signal processing and control*, 2014, 10: 224-244.
- [23] DATIAN, Ye; XUEMEI, Ouyang. Application of wavelet analysis in detection of fetal ECG. In: *Proceedings of 18th Annual International Conference of the IEEE Engineering in Medicine and Biology Society*. IEEE, 1996. p. 1043-1044.
- [24] ECHEVERRIA, Juan C., et al. Fetal QRS extraction based on wavelet analysis and pattern matching. In: *Engineering in Medicine and Biology Society, 1996. Bridging Disciplines for Biomedicine. Proceedings of the 18th Annual International Conference of the IEEE*. IEEE, 1996. p. 1656-1657.
- [25] KHAMENE, Ali; NEGAHDARIPOUR, Shahriar. a new method for the extraction of fetal ECG from the composite abdominal signal. *Biomedical Engineering, IEEE Transactions on*, 2000, 47.4: 507-516.
- [26] MOCHIMARU, F.; FUJIMOTO, Y.; ISHIKAWA, Y. Detecting the fetal electrocardiogram by wavelet theory-based methods. *Progress in Biomedical Research*, 2002, 7: 185-193.
- [27] KARVOUNIS, E. C., et al. Fetal heart rate extraction from composite maternal ECG using complex continuous wavelet transform. In: *Computers in Cardiology, 2004. IEEE, 2004*. p. 737740.
- [28] SARGOLZAEI, Saman; FAEZ, Karim; SARGOLZAEI, Arman. Signal processing based for fetal electrocardiogram extraction. In: *2008 International Conference on BioMedical Engineering and Informatics*. IEEE, 2008. p. 492-496.
- [29] CHOURASIA, V. S.; MITTRA, A. K. Selection of mother wavelet and denoising algorithm for analysis of foetal phonocardiographic signals. *Journal of medical engineering & technology*, 2009, 33.6: 442-448.
- [30] VAN BEMMEL, J. H. Detection of weak foetal electrocardiograms by autocorrelation and crosscorrelation of envelopes. *IEEE Transactions on Biomedical Engineering*, 1968, 1: 17-23.

- [31] SHI, Zhenwei; ZHANG, Changshui. Semi-blind source extraction for fetal electrocardiogram extraction by combining non-Gaussianity and time-correlation. *Neurocomputing*, 2007, 70.7-9: 1574-1581.
- [32] HON, E. H.; LEE, S. T. Averaging techniques in fetal electrocardiography. *Medical electronics and biological engineering*, 1964, 2.1: 71-76.
- [33] RANGAYYAN, Rangaraj M. *Biomedical signal analysis*. John Wiley & Sons, 2015.
- [34] KAM, Amit; COHEN, Arnon. Detection of fetal ECG with IIR adaptive filtering and genetic algorithms. In: 1999 IEEE International Conference on Acoustics, Speech, and Signal Processing. Proceedings. ICASSP99 (Cat. No. 99CH36258). IEEE, 1999. p. 2335-2338.
- [35] ALCARAZ, R.; RIETA, J. J. Adaptive singular value QRST cancellation for the analysis of short single lead atrial fibrillation electrocardiograms. In: 2007 Computers in Cardiology. IEEE, 2007. p. 513-516.
- [36] CHMELKA, L.; KOZUMPLIK, J. Wavelet-based wiener filter for electrocardiogram signal denoising. In: *Computers in Cardiology*, 2005. IEEE, 2005. p. 771-774.
- [37] SUN, Yan; CHAN, Kap Luk; KRISHNAN, Shankar Muthu. ECG signal conditioning by morphological filtering. *Computers in biology and medicine*, 2002, 32.6: 465-479.
- [38] RAVINDRAKUMAR, S.; RAJA, K. Bommanna. Fetal ECG extraction and enhancement in prenatal monitoring—Review and implementation issues. In: *Trendz in Information Sciences & Computing (TISC2010)*. IEEE, 2010. p. 16-20.
- [39] BACHARAKIS, E.; NANDI, Asoke K.; ZARZOSO, Vicente. Foetal ECG extraction using blind source separation methods. In: 1996 8th European Signal Processing Conference (EUSIPCO 1996). IEEE, 1996. p. 1-4.
- [40] DE LATHAUWER, Lieven; DE MOOR, Bart; VANDEWALLE, Joos. Fetal electrocardiogram extraction by blind source subspace separation. *IEEE transactions on biomedical engineering*, 2000, 47.5: 567-572.
- [41] YE, Yalan, et al. A fast and adaptive ICA algorithm with its application to fetal electrocardiogram extraction. *Applied Mathematics and Computation*, 2008, 205.2: 799-806.
- [42] LUO, Dongfang. Research and application of fetal electrocardiogram blind signal separation technology. *Res J Appl Sci Eng Technol*, 2012, 4.14: 2231-2235.
- [43] ROMERO, Inaki. PCA-based noise reduction in ambulatory ECGs. In: 2010 Computing in Cardiology. IEEE, 2010. p. 677-680.
- [44] ZAHUTA, Ondřej. *Adaptivní filtry v praxi* [online]. Ostrava, 2018 [cit. 2019-11-24]. Dostupné z: <http://hdl.handle.net/10084/129705>. Bakalářská práce. Vysoká škola báňská - Technická univerzita Ostrava.
- [45] Comparing linear versus nonlinear filters in image processing. *Embedded computing design* [online]. 1. 5. 2012 [cit. 2019-01-30]. Dostupné z: <http://www.embeddedcomputing.com/embedded-computing-design/comparing-linear-versus-nonlinear-filters-in-imageprocessing>

- [46] Cvičení 7 - Lineární a nelineární filtrace [online]. [cit. 2019-01-30]. Dostupné z: http://midas.uamt.feec.vutbr.cz/ZVS/Exercise07/content_cz.php
- [47] MIKOLÁŠOVÁ, Martina. Extrakce plodového elektrokardiogramu pomocí adaptivního lineárního neuronu [online]. Ostrava, 2018 [cit. 2019-01-30]. Dostupné z: <http://hdl.handle.net/10084/128623>. Bakalářská práce. Vysoká škola báňská - Technická univerzita Ostrava.
- [48] MARTINEK, Radek, Radana KAHÁNKOVÁ, Homer NAZERAN, et al. Non-invasive fetal monitoring: a maternal surface ECG electrode placement-based novel approach for optimization of adaptive filter control parameters using the LMS and RLS algorithms [online]. 2017 [cit. 2019-07-18]. DOI: 10.3390/s17051154. ISSN 1424-8220. Dostupné z: <http://hdl.handle.net/10084/117188>
- [49] ŁĘSKI, Jacek. ZASTOSOWANIE NIELINIOWEJ FILTRACJI KALMANA DO TŁUMIENIA ZAKŁÓCEŃ SYGNAŁU EKG [online]. 1991 [cit. 2019-02-03]. Dostupné z: http://delibra.bg.polsl.pl/Content/39752/BCPS_43684_1992_Zastosowanie-nielini.pdf
- [50] LAINIOTIS, D.G. Partitioning: A unifying framework for adaptive systems, I. Proceedings of the IEEE [online]. 1976, 64(8), 1126-1143 [cit. 2019-02-03]. DOI: 10.1109/PROC.1976.10284. ISSN 0018-9219. Dostupné z: <http://ieeexplore.ieee.org/document/1454553/>
- [51] LAINIOTIS, D.G. Partitioning: A unifying framework for adaptive systems, II. Proceedings of the IEEE [online]. 1976, 64(8), 1182-1198 [cit. 2019-02-03]. DOI: 10.1109/PROC.1976.10289. ISSN 0018-9219. Dostupné z: <http://ieeexplore.ieee.org/document/1454558/>
- [52] SAMENI, Reza, et al. Filtering noisy ECG signals using the extended Kalman filter based on a modified dynamic ECG model. In: Computers in Cardiology, 2005. IEEE, 2005. p. 10171020.
- [53] NIKNAZAR, Mohammad; RIVET, Bertrand; JUTTEN, Christian. Fetal ECG extraction by extended state Kalman filtering based on single-channel recordings. Biomedical Engineering, IEEE Transactions on, 2013, 60.5: 1345-1352.
- [54] AMIN, M. S., et al. Separation of fetal electrocardiography (ECG) from composite ECG using adaptive linear neural network for fetal monitoring. International Journal of Physical Sciences, 2011, 6.24: 5871-5876.
- [55] BIN IBNE REAZ, M. a LEE SZE WEI. Adaptive linear neural network filter for fetal ECG extraction. International Conference on Intelligent Sensing and Information Processing, 2004. Proceedings of [online]. IEEE, 2004, 321-324 [cit. 2017-05-30]. DOI: 10.1109/ICISIP.2004.1287675. ISBN 0-7803-8243-9.
- [56] JIA, Wenjuan, Chunlan YANG, Guocheng ZHONG, Mengying ZHOU a Shuicai WU. Fetal ECG extraction based on adaptive linear neural network. 2010 3rd International Conference on Biomedical Engineering and Informatics [online]. IEEE, 2010, 899-902 [cit. 2017-06-01]. DOI: 10.1109/BMEI.2010.5639886. ISBN 978-1-4244-6498-2.
- [57] SHADAYDEH, Maha; XIAO, Yegui; WARD, Rabab Kriedieh. Extraction of fetal ECG using adaptive Volterra filters. In: Proceedings of the EUSIPCO. 2008.

- [58] VERULKAR, N. M.; ZOPE, P. H.; SURALKAR, S. R. Filtering techniques for reduction of power line interference in electrocardiogram signals. *International Journal of Engineering Research and Technology*, 2012
- [59] MATEO, J., et al. Robust volterra filter design for enhancement of electroencephalogram signal processing. *Circuits, Systems, and Signal Processing*, 2013, 32.1: 233-253.
- [60] ZGALLAI, W. A. The application of adaptive LMF quadratic and cubic Volterra filters to ECG signals. *International Journal of Computer Theory and Engineering*, 2015, 7.5: 337.
- [61] ASSALEH, Khaled. Extraction of fetal electrocardiogram using adaptive neuro-fuzzy inference systems. *IEEE Transactions on Biomedical Engineering*, 2007, 54.1: 59-68.
- [62] ASSALEH, Khaled. Adaptive neuro-fuzzy inference systems for extracting fetal electrocardiogram. In: *Signal Processing and Information Technology, 2006 IEEE International Symposium on*. IEEE, 2006. p. 122-126.
- [63] VIJILA, C. Kezi Selva; KANAGASABAPATHY, P.; JOHNSON, Stanley. Adaptive neuro fuzzy inference system for extraction of FECG. In: *INDICON, 2005 Annual IEEE*. IEEE, 2005. p. 224-227.
- [64] NAZMY, T. M.; EL-MESSIRY, H.; AL-BOKHITY, B. Adaptive neuro-fuzzy inference system for classification of ECG signals. In: *Informatics and Systems (INFOS), 2010 The 7th International Conference on*. IEEE, 2010. p. 1-6.
- [65] NAZARPOUR, Kianoush; EBADI, Siamak; SANEI, Saeid. Fetal electrocardiogram signal modelling using genetic algorithm. In: *Medical Measurement and Applications, 2007. MEMEA'07. IEEE International Workshop on*. IEEE, 2007. p. 1-4.
- [66] NASIRI, Maryam; FAEZ, Karim. Extracting fetal electrocardiogram signal using ANFIS trained by genetic algorithm. In: *Biomedical Engineering (ICoBE), 2012 International Conference on*. IEEE, 2012. p. 197-202.
- [67] SARGOLZAEI, A.; FAEZ, K.; SARGOLZAEI, S. a new method for Foetal Electrocardiogram extraction using Adaptive Nero-Fuzzy Interference System trained with PSO algorithm. In: *Electro/Information Technology (EIT), 2011 IEEE International Conference on*. IEEE, 2011. p. 15.
- [68] GODFREY, ACRMDOG, et al. Direct measurement of human movement by accelerometry. *Medical engineering & physics*, 2008, 30.10: 1364-1386.
- [69] LÁDROVÁ, Martina. Implementace modulárního zpracování biologických signálů. Ostrava, 2018. Diplomová práce. VŠB – Technická univerzita Ostrava. Vedoucí práce Doc. Ing. Radek Martinek, Ph.D.
- [70] BARNOVÁ, Kateřina. Hybridní metody pro extrakci plodového elektrokardiogramu [online]. Ostrava, 2019 [cit. 2019-11-30]. Dostupné z: <http://hdl.handle.net/10084/136184>. Diplomová práce. Vysoká škola báňská - Technická univerzita Ostrava.
- [71] HORÁK, David. Diskrétní transformace. Ostrava, 2012. Učební text. Vysoká škola báňská – Technická univerzita Ostrava.

- [72] MARTINEK, Radek, Radana KAHANKOVA, Janusz JEZEWSKI, et al. Comparative Effectiveness of ICA and PCA in Extraction of Fetal ECG From Abdominal Signals: Toward Noninvasive Fetal Monitoring. *Frontiers in Physiology* [online]. 2018, 9, 1-25 [cit. 2019-01-27]. DOI: 10.3389/fphys.2018.00648. ISSN 1664-042X. Dostupné z: <https://www.frontiersin.org/article/10.3389/fphys.2018.00648/full>
- [73] WALCZYSKO, M. Analýza EEG signálu pomocí analýzy hlavních komponent (PCA). Brno, 2008. Bakalářská práce. Vedoucí práce Ing. Milan Rychtárik.
- [74] VASEGHI, Saeed V. *Advanced digital signal processing and noise reduction*. 4th ed. Chichester, U.K.: J. Wiley, 2008. ISBN 978-0-470-75406-1.
- [75] CHINABOINA, Radhika, et al. Adaptive algorithms for acoustic echo cancellation in speech processing. *International Journal of Research and Reviews in Applied Sciences*, 2011, 7.1: 38-42.
- [76] MARTINEK, Radek, et al. Adaptive signal processing techniques for extracting abdominal fetal electrocardiogram. In: *2016 10th International Symposium on Communication Systems, Networks and Digital Signal Processing (CSNDSP)*. IEEE, 2016. p. 1-6.
- [77] MARTINEK, Radek, et al. Comparison of the LMS, NLMS, RLS, and QR-RLS algorithms for vehicle noise suppression. In: *Proceedings of the 10th International Conference on Computer Modeling and Simulation*. ACM, 2018. p. 23-27
- [78] CAPMAN, François; BOUDY, Jérôme; LOCKWOOD, Philip. Acoustic echo cancellation using a fast QR-RLS algorithm and multirate schemes. In: *1995 International Conference on Acoustics, Speech, and Signal Processing*. IEEE, 1995. p. 969-972.
- [79] KATHURIA, Arjun. Adaptive linear neuron (ADALINE) [online]. [cit. 2020-01-07]. Dostupné z: <https://arjunkathuria.com/ml/Adaline/>
- [80] ŠKUTOVÁ, Hana. Extrakce plodového elektrokardiogramu metodami soft computingu [online]. Ostrava, 2016 [cit. 2020-01-07]. Dostupné z: <http://hdl.handle.net/10084/115918>. Diplomová práce. Vysoká škola báňská - Technická univerzita Ostrava.
- [81] CHANG, Fi-John; CHANG, Ya-Ting. Adaptive neuro-fuzzy inference system for prediction of water level in reservoir. *Advances in water resources*, 2006, 29.1: 1-10.
- [82] PHYSIONET. Abdominal and Direct Fetal Electrocardiogram Database. dostupné [online]. 2012 [cit. 2020-01-26]. Dostupné z: <https://physionet.org/physiobank/database/adfecgdb/>
- [83] *Noninvasive Fetal ECG: the PhysioNet/Computing in Cardiology Challenge 2013* [online]. [cit. 2020-03-04]. Dostupné z: <https://archive.physionet.org/challenge/2013/#ref-ann>
- [84] MARTINEK, Radek, et al. Comparative effectiveness of ICA and PCA in extraction of fetal ECG from abdominal signals: Toward non-invasive fetal monitoring. *Frontiers in physiology*, 2018, 9: 648.
- [85] ANDREOTTI, Fernando, et al. Robust fetal ECG extraction and detection from abdominal leads. *Physiological measurement*, 2014, 35.8: 1551.

- [86] BEHAR, Joachim; OSTER, Julien; CLIFFORD, Gari D. Combining and benchmarking methods of foetal ECG extraction without maternal or scalp electrode data. *Physiological measurement*, 2014, 35.8: 1569.

Seznam příloh

- Příloha A: Výsledky experimentů prováděných na datech z databáze ADFECGDB
– nalezení optimální kombinace vstupních elektrod.
- Příloha B: Výsledky experimentů prováděných na datech z databáze ADFECGDB
– nalezení optimálních hodnot parametrů testovaných adaptivních algoritmů.
- CD příloha: Softwarová část diplomové práce.

Příloha A

Tato přílohová část obsahuje všechny dosažené výsledky experimentů prováděných na reálných datech z klinické praxe z databáze ADFECGDB dostupných na webu Physionet. V této přílohové části jsou obsaženy tabulky shrnující výsledky statistických parametrů při hledání optimální kombinace elektrod pro všechny záznamy testovaného datového souboru.

Tab. 34: Výsledky statistických parametrů pro každou z kombinací elektrod pro záznam r01.

r01	TP	FP	FN	ACC	SE	PPV	F1
1,2	606	78	38	83,93	94,09	88,59	91,27
1,3	547	134	97	70,31	84,94	80,32	82,57
1,4	632	55	12	90,42	98,14	91,99	94,96
2,3	574	109	70	76,23	89,13	84,04	86,51
2,4	627	56	17	89,57	97,36	91,80	94,49
3,4	575	116	69	75,66	89,29	83,21	86,14
1,2,3	576	107	68	76,69	89,44	84,33	86,81
1,2,4	634	52	10	91,09	98,44	92,42	95,34
1,3,4	630	56	14	90	97,82	91,84	94,74
2,3,4	615	71	29	86,01	95,49	89,65	92,48
1,2,3,4	631	55	13	90,27	97,98	91,98	94,89

Tab. 35: Výsledky statistických parametrů pro každou z kombinací elektrod pro záznam r02.

r02	TP	FP	FN	ACC	SE	PPV	F1
1,2	498	186	162	58,87	75,46	72,81	74,11
1,3	375	322	285	38,19	56,82	53,80	55,27
1,4	547	140	113	68,38	82,88	79,62	81,22
2,3	360	340	300	36	54,55	51,43	52,94
2,4	511	177	149	61,05	77,42	74,27	75,82
3,4	345	356	315	33,86	52,27	49,22	50,69
1,2,3	480	196	180	56,08	72,73	71,01	71,86
1,2,4	546	141	114	68,17	82,73	79,48	81,07
1,3,4	534	151	126	65,85	80,91	77,96	79,41
2,3,4	516	166	144	62,47	78,18	75,66	76,90
1,2,3,4	540	148	120	66,83	81,82	78,48	80,12

Tab. 36: Výsledky statistických parametrů pro každou z kombinací elektrod pro záznam r03.

r03	TP	FP	FN	ACC	SE	PPV	F1
1,2	158	375	526	14,92	23,09	29,64	25,97
1,3	69	367	615	6,57	10,09	15,83	12,32
1,4	78	3687	606	7,41	11,40	17,49	13,81
2,3	123	367	561	11,70	17,98	25,10	20,95
2,4	59	376	625	5,57	8,63	13,56	10,55
3,4	63	384	621	5,89	9,21	14,09	11,14
1,2,3	153	374	531	14,46	22,37	29,03	25,27
1,2,4	97	446	587	8,58	14,18	17,86	15,81
1,3,4	55	366	629	5,24	8,04	13,06	9,96
2,3,4	57	375	627	5,38	8,33	13,19	10,22
1,2,3,4	53	376	631	5	7,75	12,35	9,52

Tab. 37: Výsledky statistických parametrů pro každou z kombinací elektrod pro záznam r04.

r04	TP	FP	FN	ACC	SE	PPV	F1
1,2	213	334	419	22,05	33,70	38,94	36,13
1,3	248	343	384	25,44	39,24	41,96	40,56
1,4	274	378	358	27,13	43,35	42,03	42,68
2,3	198	336	434	20,46	31,33	37,08	33,96
2,4	204	336	428	21,07	32,28	37,78	34,81
3,4	231	367	401	23,12	36,55	38,63	37,56
1,2,3	192	341	440	19,73	30,38	36,02	32,96
1,2,4	187	339	445	19,26	29,59	35,55	32,29
1,3,4	215	418	417	20,48	34,02	33,97	33,99
2,3,4	204	336	428	21,07	32,28	37,78	34,81
1,2,3,4	196	339	436	20,19	31,01	36,64	33,59

Tab. 38: Výsledky statistických parametrů pro každou z kombinací elektrod pro záznam r05.

r05	TP	FP	FN	ACC	SE	PPV	F1
1,2	442	170	203	54,23	68,53	72,22	70,33
1,3	405	259	240	44,80	62,79	60,99	61,88
1,4	578	114	67	76,15	89,61	83,53	86,46
2,3	415	258	230	45,96	64,34	61,66	62,97
2,4	549	120	96	71,77	85,12	82,06	83,56
3,4	434	217	211	50,35	67,29	66,67	66,98
1,2,3	407	272	238	44,38	63,10	56,94	61,48
1,2,4	574	113	71	75,73	88,99	83,55	86,19
1,3,4	563	128	82	72,83	87,29	81,48	84,28
2,3,4	455	198	190	53,97	70,54	69,68	70,11
1,2,3,4	552	128	93	71,41	85,58	81,18	83,32

Tab. 39: Výsledky statistických parametrů pro každou z kombinací elektrod pro záznam r06.

r06	TP	FP	FN	ACC	SE	PPV	F1
1,2	114	407	560	10,55	16,91	21,88	19,08
1,3	100	389	574	9,41	14,84	20,45	17,19
1,4	63	390	611	5,92	3,35	13,91	11,18
2,3	132	388	542	12,43	19,59	25,39	22,11
2,4	63	390	611	5,92	3,35	13,91	11,18
3,4	84	451	590	7,48	12,46	15,70	13,89
1,2,3	109	405	565	10,10	16,17	21,21	18,35
1,2,4	68	389	606	6,39	10,09	14,88	12,03
1,3,4	63	390	611	5,92	9,35	13,91	11,18
2,3,4	63	390	611	5,92	9,35	13,91	11,18
1,2,3,4	173	680	501	12,78	25,67	20,28	22,66

Tab. 40: Výsledky statistických parametrů pro každou z kombinací elektrod pro záznam r07.

r07	TP	FP	FN	ACC	SE	PPV	F1
1,2	278	314	349	29,54	44,34	46,96	45,61
1,3	261	326	366	27,39	41,63	44,46	42,99
1,4	288	337	339	29,88	45,93	46,08	46,01
2,3	265	315	362	28,13	42,27	46,69	43,91
2,4	318	311	309	33,90	50,72	50,56	50,64
3,4	237	326	390	24,87	37,79	42,09	39,83
1,2,3	284	314	343	30,18	45,29	47,49	46,37
1,2,4	289	315	338	30,68	46,09	47,85	46,95
1,3,4	219	341	408	22,62	34,93	39,11	36,90
2,3,4	286	313	341	30,43	45,61	47,75	46,66
1,2,3,4	279	316	348	29,59	44,49	46,89	45,66

Tab. 41: Výsledky statistických parametrů pro každou z kombinací elektrod pro záznam r08.

r08	TP	FP	FN	ACC	SE	PPV	F1
1,2	623	32	28	91,22	95,69	95,12	95,41
1,3	415	243	236	46,42	63,75	63,07	63,41
1,4	649	10	2	98,19	99,69	98,48	99,08
2,3	599	58	52	84,49	92,01	91,17	91,59
2,4	584	49	67	83,43	89,71	92,26	90,97
3,4	602	36	49	87,63	92,47	94,36	93,41
1,2,3	588	97	63	78,61	90,32	85,84	88,02
1,2,4	649	7	2	98,63	99,69	98,93	99,31
1,3,4	650	16	1	97,45	99,84	97,59	98,71
2,3,4	628	30	23	92,22	96,47	95,44	95,95
1,2,3,4	587	55	64	83,14	90,17	91,43	90,79

Tab. 42: Výsledky statistických parametrů pro každou z kombinací elektrod pro záznam r09.

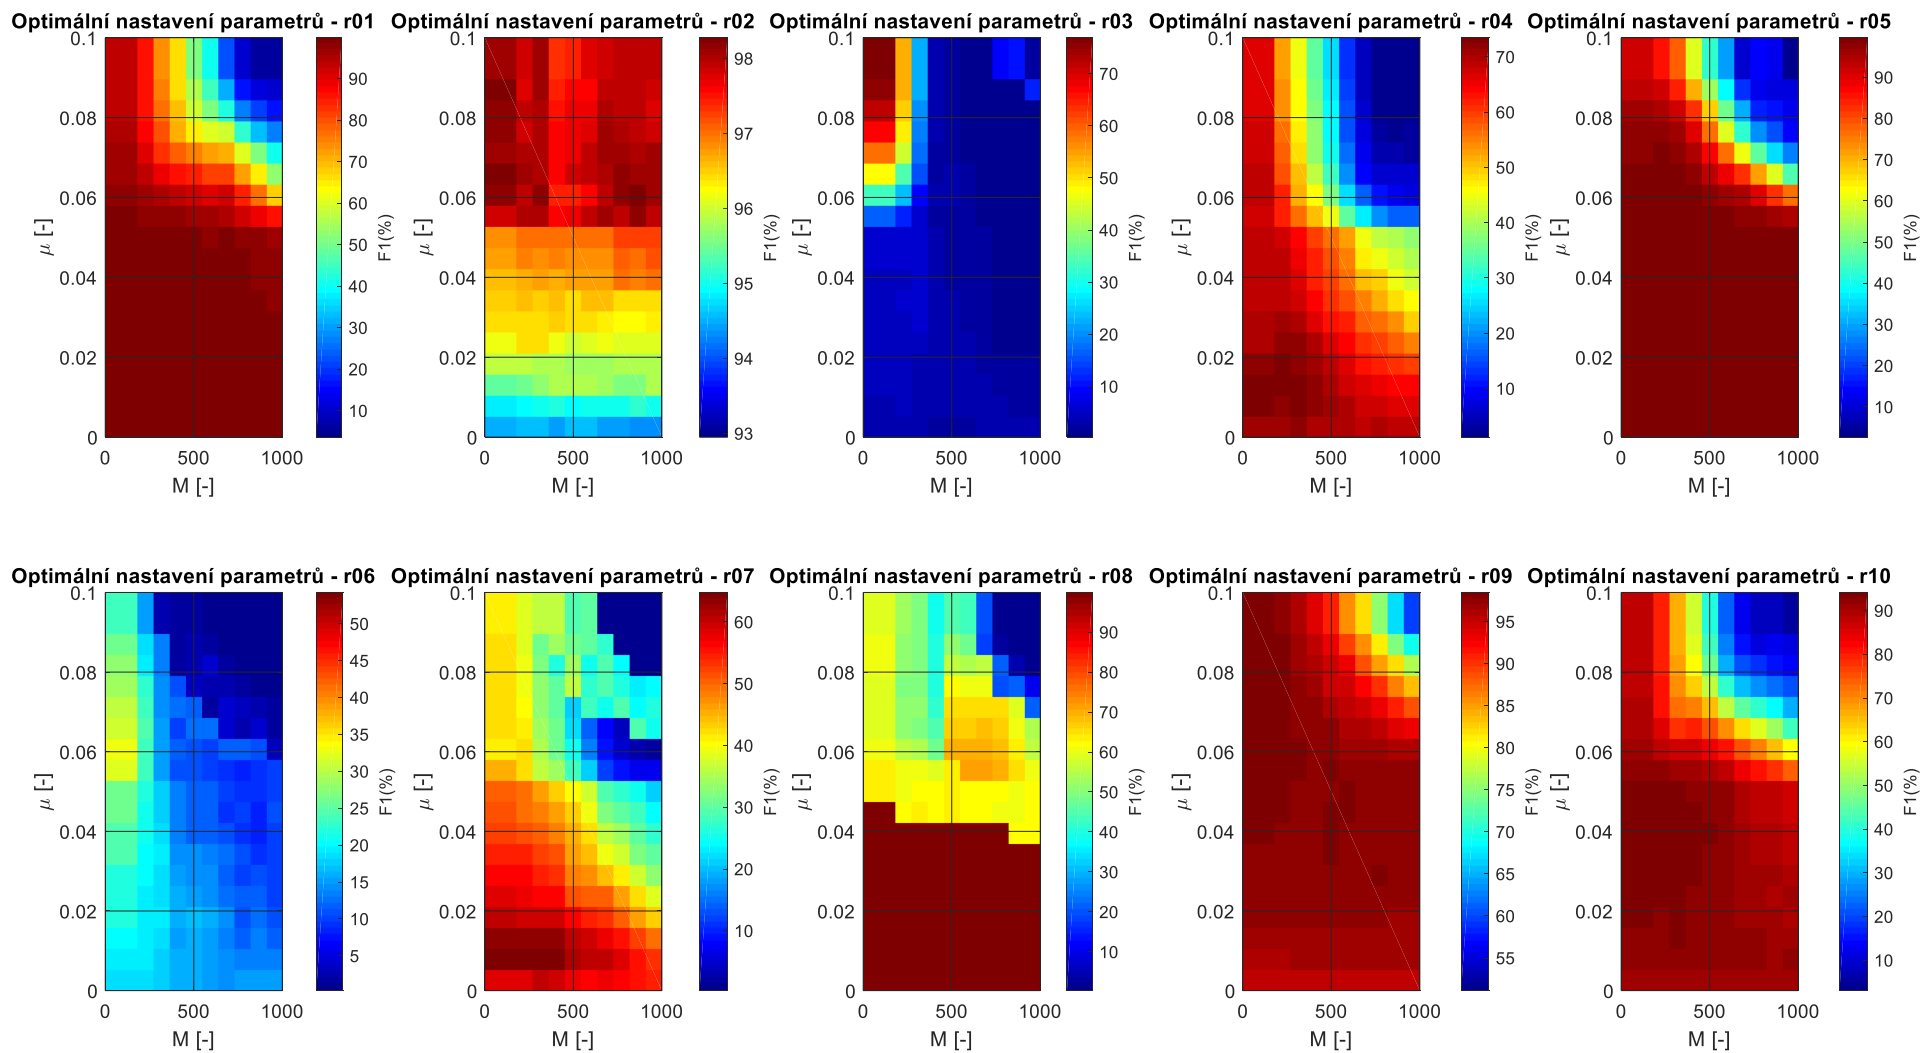
r09	TP	FP	FN	ACC	SE	PPV	F1
1,2	303	482	354	26,60	46,12	38,59	42,03
1,3	415	242	242	46,16	63,17	63,17	63,17
1,4	557	103	100	73,29	84,78	84,39	84,59
2,3	415	243	242	46,11	63,17	63,07	63,12
2,4	498	171	159	60,15	75,79	74,44	75,11
3,4	478	174	179	57,52	72,76	73,31	73,03
1,2,3	443	209	214	51,16	67,43	67,95	67,69
1,2,4	476	220	181	54,28	72,45	68,39	70,36
1,3,4	549	112	108	71,39	83,56	83,06	83,31
2,3,4	528	122	129	67,78	80,37	81,23	80,79
1,2,3,4	552	110	105	71,97	84,02	83,38	83,70

Tab. 43: Výsledky statistických parametrů pro každou z kombinací elektrod pro záznam r10.

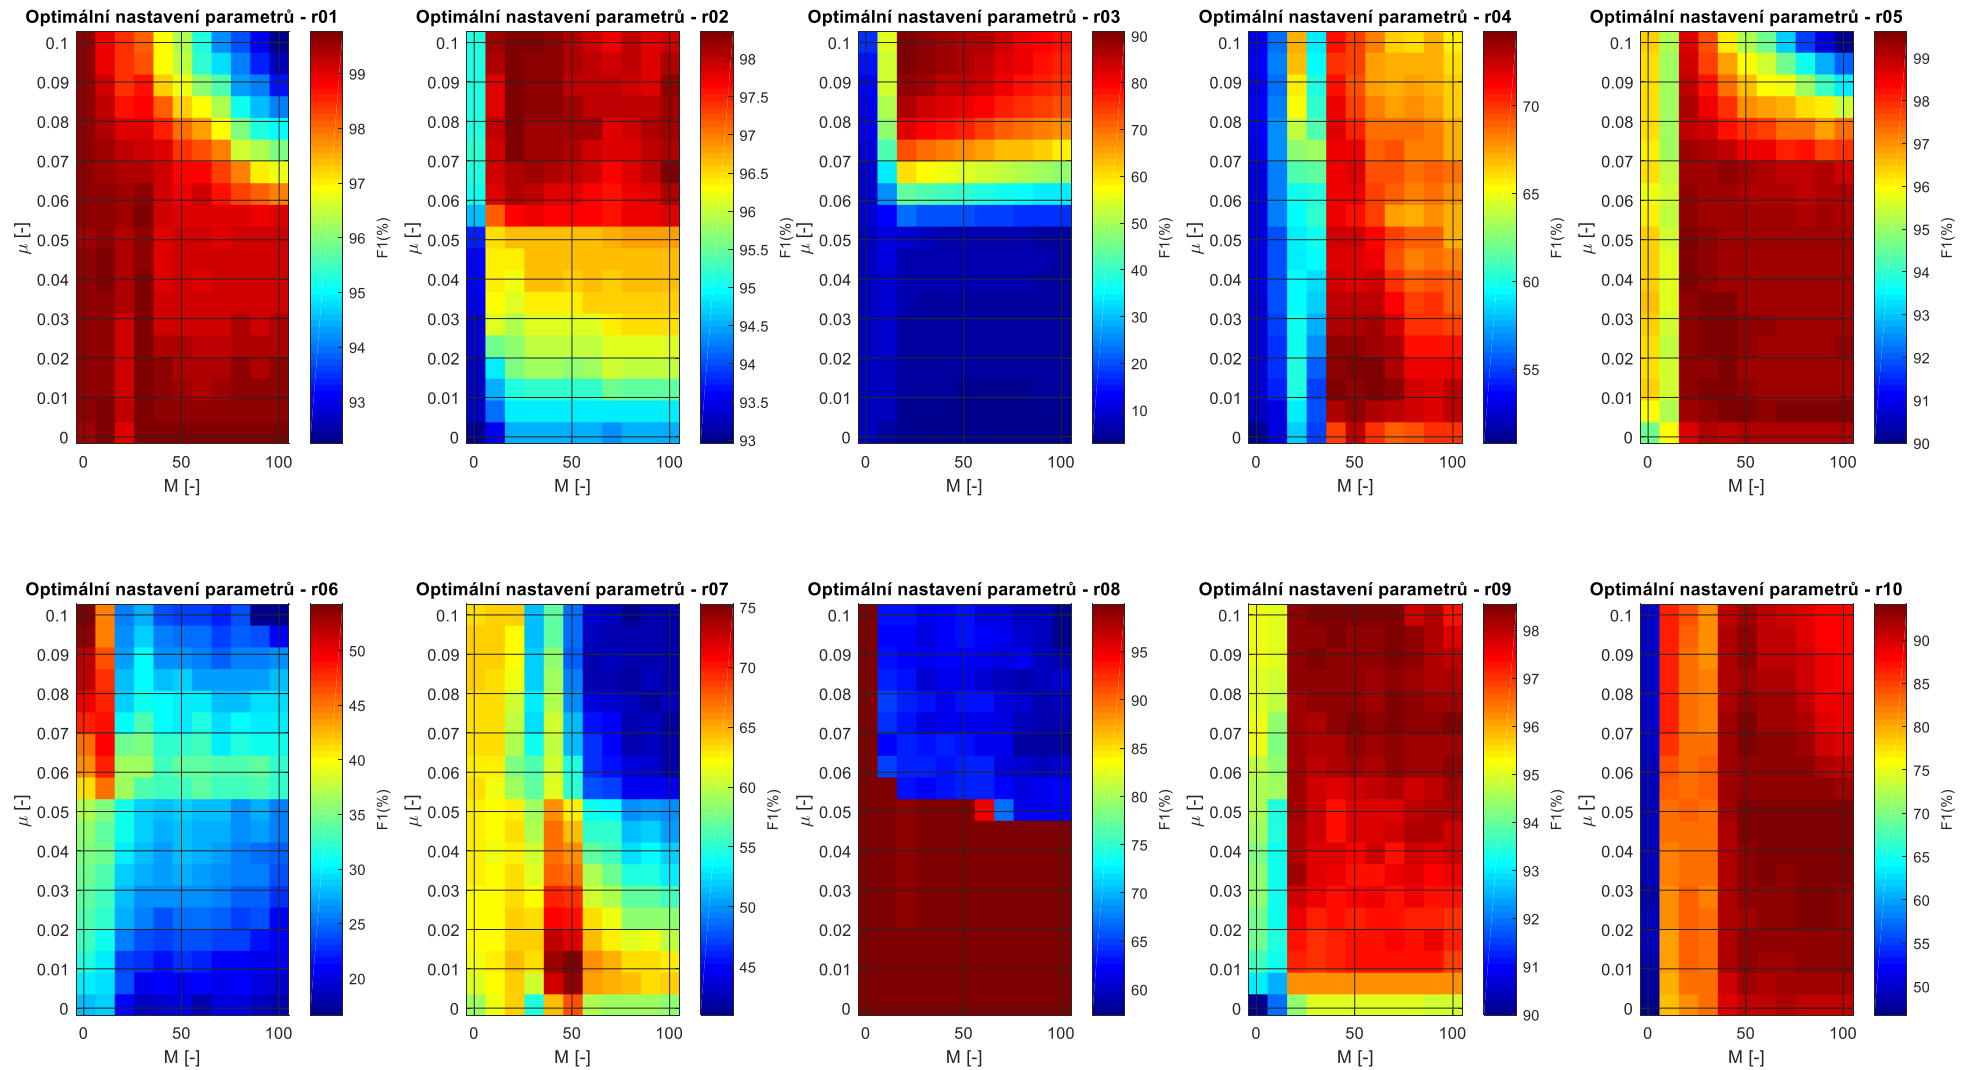
r10	TP	FP	FN	ACC	SE	PPV	F1
1,2	285	419	352	26,99	44,74	40,48	42,51
1,3	378	449	259	34,81	59,34	45,71	51,64
1,4	188	411	449	17,94	29,51	31,39	30,42
2,3	296	404	341	28,44	46,47	42,29	44,28
2,4	175	410	462	16,71	27,47	29,92	28,64
3,4	266	558	371	22,26	41,76	32,28	36,41
1,2,3	399	437	238	37,15	62,64	47,73	54,18
1,2,4	240	659	397	18,52	37,68	26,69	31,25
1,3,4	172	409	465	16,44	27,00	29,60	28,24
2,3,4	220	411	417	20,99	34,54	34,87	34,70
1,2,3,4	391	467	246	35,42	61,38	45,57	52,31

Příloha B


Tato příloha obsahuje grafické výstupy dosažené při optimalizaci nastavení všech čtyř testovaných typů adaptivních algoritmů pro data z databáze ADFECGDB. Tyto grafy shrnují závislost velikosti parametru F1 na parametrech adaptivního algoritmu, které ovlivňují kvalitu filtrace.



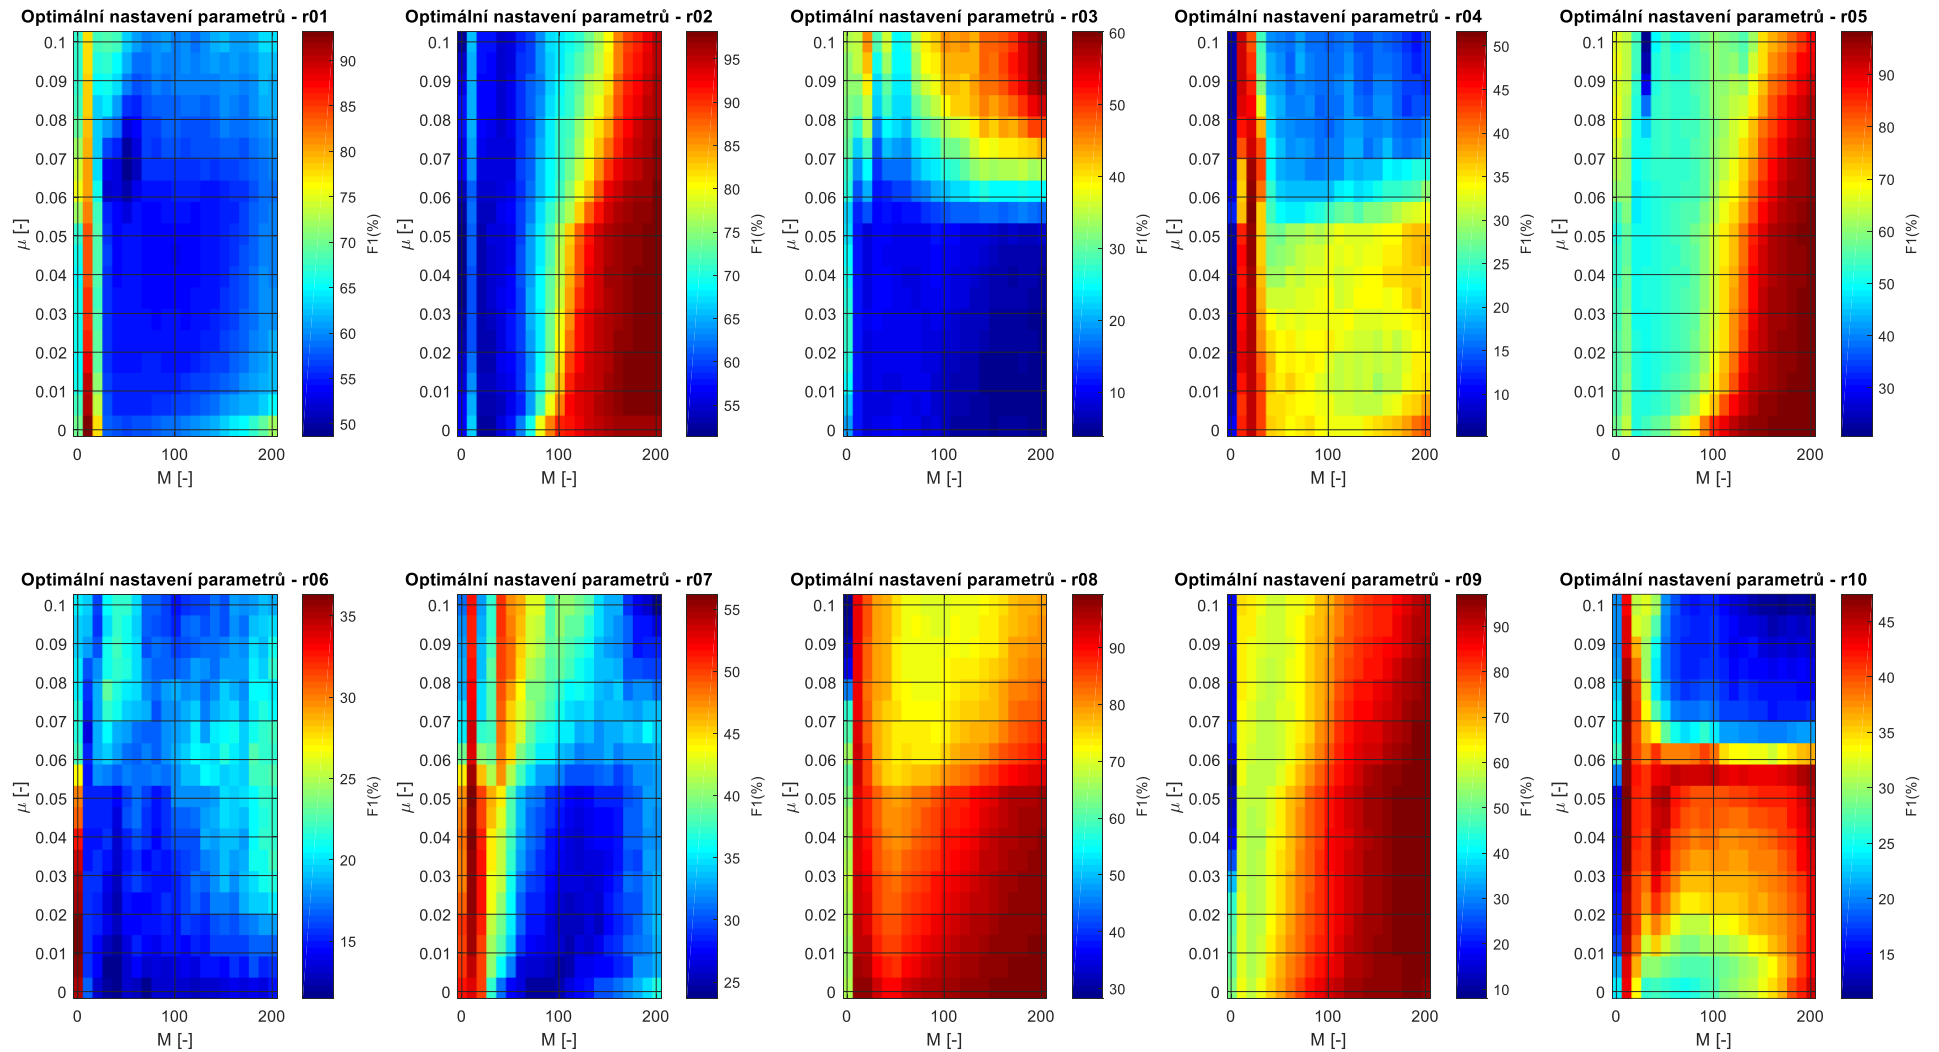
Obr. 52: Hledání optimálního nastavené parametrů metody LMS (krok 1) – nastavení: $M=0-1000$, $\mu=0,001-0,1$.



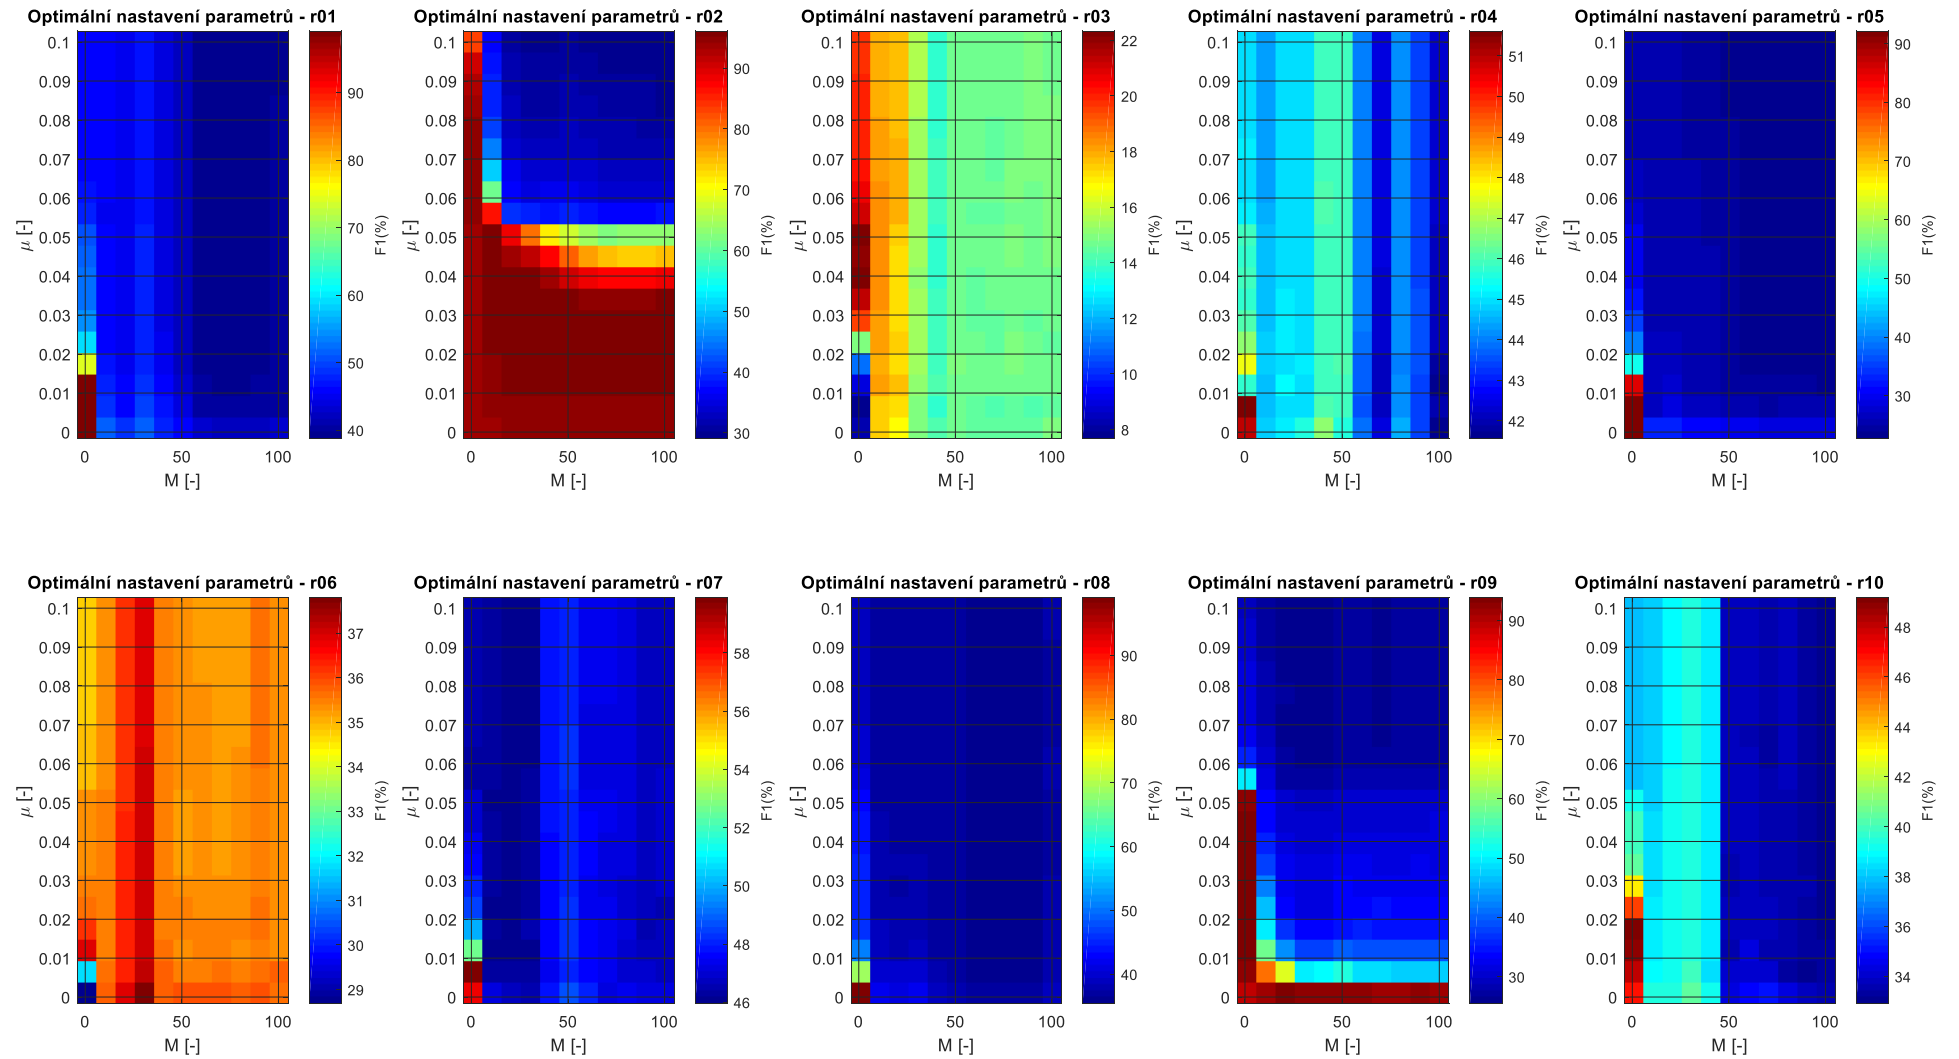
Obr. 53: Hledání optimálního nastavené parametrů metody LMS (krok 2) – nastavení: $M=0-100$, $\mu=0,001-0,1$.




Obr. 54: Hledání optimálního nastavené parametrů metody NLMS – nastavení: $M=0-100$, $\mu=0,001-0,1$.




Obr. 55: Hledání optimálního nastavené parametrů metody NLMS – nastavení: $M=0-200$, $\mu=0,001-0,1$.



Obr. 56: Hledání optimálního nastavení parametrů metody BLMS – nastavení: $M=0-100$, $\mu=0,001-0,1$, $BS=5$.



Obr. 57: Hledání optimálního nastavení parametrů metody BLMS – nastavení: $M=0-100$, $\mu=0,001-0,1$, $BS=25$.



Obr. 58: Hledání optimálního nastavené parametrů metody ADALINE – nastavení: $p=0-100$, $\eta=0,001-0,1$.

Příloha CD

Tato příloha je tvořena CD obsahujícím veškerá data, která byla v této diplomové práci použita k testování navrženého HA, dále výsledky extrakce prováděné na Datasetu A (časové průběhy, spektra a grafy fHR pro každou metodu a každý záznam) a veškeré funkce a kódy, které byly k experimentům použity.

Tab. 44: Shrnutí obsahu přílohy na CD.

Název souboru	Popis souboru
Dataset A	Složka obsahující 4 aEKG signály (aECG_1 až aECG_4), 1 signál snímaný skalpovou elektrodou (fECG_sk) a 1 anotace obsahující pozice fQRS komplexů pro každý z deseti záznamu z databáze ADFECGDB.
Dataset B	Složka obsahující 4 aEKG signály (aECG_1 až aECG_4), 1 anotaci a odhadnuté signály ICA_mEKG a ICA_aEKG pro každý z 25 testovaných záznamů z databáze Challenge 2013.
Dataset C	Složka obsahující 6 aEKG záznamů a 1 signál KTG.
Výsledky Dataset A	Složka obsahující porovnání časových průběhů vstupního a výstupního signálu navíc doplněné o porovnání s referenční elektrodou pro každý záznam. Dále tato složka obsahuje amplitudová spektra signálů před a po filtraci taktéž pro každý záznam.
Výsledky Dataset B	Složka obsahující grafy časových průběhů signálů před a po filtraci pro každý z testovaných záznamů (a01-a25)
ADALINE.m	Funkce algoritmu ADALINE.
detektor_CWT.m	Funkce pro hledání R vlny plodu.
filtry_LMS.m	Hlavní funkce provádějící algoritmy LMS, NLMS a BLMS
KONECNEvykresleni.m	Program umožňující vykreslení časových průběhů a amplitudových spekter.
main_ICA.m	Program umožňující rozklad vstupního signálu pomocí metody ICA na 3 dílčí komponenty, jejich vykreslení a statistické hodnocení.
main_pracovni_oblast_LMS.m	Program pro hledání optimálního nastavení metod rodiny LMS a následnou extrakci fEKG podle nastavených filtračních parametrů a výpočet statistických parametrů.
main_pracovnioblast_ADALINE.m	Program pro hledání optimálního nastavení metody ADALINE a následnou extrakci fEKG podle nastavených filtračních parametrů a výpočet statistických parametrů.
metoda_ICA.m	Hlavní funkce umožňující provedení algoritmu ICA.

movingmean.m	Funkce pro výpočet klouzavého průměru.
nove_urceni_TP_FP_FN.m	Funkce pro výpočet hodnotících statistických parametrů.
predzpracovani.m	Funkce provádějící předzpracování signálu.
vykresleni_fHR.m	Program sloužící pro vykreslení průběhů fHR.
vystup_grafy.m	Program sloužící pro vykreslení grafických výstupů při testování Datasetu B.
MIK0329_Diplomová_práce	Soubor obsahující textovou část diplomové práce ve formátu PDF/A.