

VŠB – Technická univerzita Ostrava
Fakulta elektrotechniky a informatiky
Katedra kybernetiky a biomedicínského inženýrství

Využití hybridních metod pro zpracování plodového elektrokardiogramu

Hybrid Methods for Processing of Fetal Electrocardiogram

VŠB – Technická univerzita Ostrava

Fakulta elektrotechniky a informatiky
Katedra kybernetiky a biomedicínského inženýrství

VŠB TECHNICKÁ
UNIVERZITA
OSTRAVA

FAKULTA
ELEKTROTECHNIKY
A INFORMATIKY

KATEDRA KYBERNETIKY
A BIOMEDICÍNSKÉHO
INŽENÝRSTVÍ

Využití hybridních metod pro zpracování plodového elektrokardiogramu

Hybrid Methods for Processing of Fetal Electrocardiogram

Doktorská disertační práce

Autor: Ing. René Jaroš, FEI VŠB-TU v Ostravě
Studijní program: Elektrotechnika
Studijní obor: Technická kybernetika
Školitel: doc. Ing. Radek Martinek, Ph.D., FEI VŠB-TU v Ostravě
Oponenti: prof. Ing. Jiří Mišurec, CSc., FEKT VUT v Brně
doc. MUDr. Petr Krupa, CSc., FNO a LF OU v Ostravě
doc. Ing. Petr Čermák, Ph.D., FPF SU v Opavě

VŠB-TU Ostrava, říjen 2019

Prohlašuji, že jsem tuto disertační práci vypracoval samostatně. Uvedl jsem všechny literární prameny a publikace, ze kterých jsem čerpal.

V Ostravě 14. října 2019

.....

Poděkování

Rád bych především poděkoval panu doc. Ing. Radku Martinkovi, Ph.D, který byl mým školitelem, za všechny rady, poskytnuté materiály a čas strávený nad problematikou této doktorské disertační práce.

Dále bych rád poděkoval mé snoubence Bc. Zuzaně Kodrlové, DiS. za podporu v náročných chvílích, které provázely vytvoření této doktorské disertační práce.

Abstrakt

Tato doktorská disertační práce se zaměřuje na návrh, realizaci a následnou verifikaci nového typu hybridního extrakčního systému pro zpracování neinvazivního plodového elektrokardiogramu (NI-fEKG). Navržený systém sdružuje výhody jednotlivých adaptivních a neadaptivních metod. Tato práce ověřuje dva inovativní hybridní systémy s názvem ICA-ANFIS-WT a ICA-RLS-WT. Jedná se o kombinaci analýzy nezávislých komponent (ICA), adaptivního neuro-fuzzy inferenčního systému (ANFIS) nebo algoritmu založeném na rekurzivní optimální adaptaci (RLS) a vlnkové transformace (WT). Studie byla realizována na datech z klinické praxe (rozšířená databáze abdominálního a přímého fetálního elektrokardiogramu (ADFECGDB) a databáze EKG physionet challenge 2013) z pohledu neinvazivního monitorování fetální tepové frekvence (fHR) na základě stanovení celkové pravděpodobnosti správné detekce (ACC), senzitivity (SE), pozitivní prediktivní hodnoty (PPV) a harmonického průměru mezi SE a PPV (F1). Funkcionalita systému byla verifikována vůči relevantní referenci dané anotacemi. Tato práce ukázala, že hybridní systém ICA-RLS-WT dosáhl lepších výsledků než ICA-ANFIS-WT. Při experimentu na záznamech z databáze ADFECGDB dosáhla hybridní metoda ICA-RLS-WT hodnoty $ACC > 80\%$ u 10 z 12 záznamů a hybridní metoda ICA-ANFIS-WT hodnoty $ACC > 80\%$ pouze u 6 z 12 záznamů. Při experimentu na záznamech z databáze EKG physionet challenge 2013 dosáhla hybridní metoda ICA-RLS-WT hodnoty $ACC > 80\%$ u 13 z 25 záznamů a hybridní metoda ICA-ANFIS-WT hodnoty $ACC > 80\%$ pouze u 7 z 25 záznamů. Oba navržené hybridní systémy dosáhly prokazatelně lepších výsledků než jednotlivé metody v předchozích studiích.

Klíčová slova: plodová elektrokardiografie; extrahování; neadaptivní filtrace; externí monitorování plodu; analýza nezávislých komponent; adaptivní neuro-fuzzy inferenční systém; algoritmus založený na rekurzivní optimální adaptaci; vlnková transformace; slepá separace zdrojů; plodová srdeční frekvence; morfologická analýza; Bland-Altmanův graf

Abstract

This dissertation focuses on the design, implementation and subsequent verification of a new type of hybrid extraction system for noninvasive fetal electrocardiogram (NI-fECG) processing. The designed system combines the advantages of individual adaptive and non-adaptive methods. This thesis reviews two innovative hybrid systems called ICA-ANFIS-WT and ICA-RLS-WT. This is a combination of independent component analysis (ICA), adaptive neuro-fuzzy inference system (ANFIS) or recursive least squares (RLS) algorithm and wavelet transform (WT). The study was conducted on clinical practice data (extended abdominal and direct fetal electrocardiogram database (ADFECGDB) and Physionet Challenge 2013 database) from the perspective of non-invasive fetal heart rate (fHR) monitoring based on the determination of the overall probability of correct detection (ACC), sensitivity (SE), positive predictive value (PPV) and harmonic mean between SE and PPV (F1). System functionality was verified against a relevant reference obtained by annotations. The study showed that ICA-RLS-WT hybrid system achieve better results than ICA-ANFIS-WT. During experiment on ADFECGDB database, the ICA-RLS-WT hybrid system reached ACC > 80 % on 10 recordings out of 12 and the ICA-ANFIS-WT hybrid system reached ACC > 80 % only on 6 recordings out of 12. During experiment on Physionet Challenge 2013 database the ICA-RLS-WT hybrid system reached ACC > 80 % on 13 recordings out of 25 and the ICA-ANFIS-WT hybrid system reached ACC > 80 % only on 7 recordings out of 25. Both hybrid systems achieve provably better results than the individual methods tested in previous studies.

Keywords: fetal electrocardiography; extraction; non-adaptive filtration; external fetal monitoring; independent component analysis; adaptive neuro fuzzy inference system; recursive least square; wavelet transform; blind source separation; fetal heart rate; morphological analysis; Bland-Altman plot

Obsah

Seznam použitých zkratk a symbolů	9
Seznam obrázků	16
Seznam tabulek	20
1 Úvod	31
2 Techniky monitorování plodu	34
2.1 Fetální echokardiografie	34
2.2 Fetální magnetokardiografie	34
2.3 Kardiotokografie	35
2.4 Fetální fonokardiografie	38
2.5 Fetální elektrokardiografie	40
2.6 Srovnání technik monitorování plodu	44
3 Základní rozdělení metod zpracování fEKG signálu	47
3.1 Jednokanálové neadaptivní metody	47
3.2 Vícekanálové neadaptivní metody	54
3.3 Hybridní metody	64
3.4 Shrnutí metod zpracování signálů	69
4 Cíle doktorské disertační práce	74
5 Metody	76
5.1 Frekvenčně selektivní filtr s konečnou impulzní odezvou	76
5.2 Analýza nezávislých komponent	78
5.3 Metoda založená na rekurzivní optimální adaptaci	83
5.4 Adaptivní neuro-fuzzy inferenční systém	87
5.5 Vlnková transformace	96
5.6 Databáze	101
5.7 Hodnotící parametry	102
6 Hybridní systém	106
6.1 Popis hybridního systému	106
6.2 Příprava dat	113

7 Experimenty a výsledky	116
7.1 Experimenty na reálných datech z databáze ADFECGDB	116
7.2 Experimenty na reálných datech z databáze EKG physionet challenge 2013 . . .	123
8 Diskuze	131
9 Závěr	136
Přílohy	162
A Experimenty na reálných datech z databáze ADFECGDB	163
B Experimenty na reálných datech z databáze EKG physionet challenge 2013	176
C Softwarová aplikace	204

Seznam použitých zkratek a symbolů

ACC	– Celková pravděpodobnost správné detekce tepů
ADALINE	– Adaptivní lineární neuron (Adaptive Linear Neuron)
ADFECGDB	– Databáze abdominálního a přímého plodového (fetálního) elektrokardiogramu (Abdominal and Direct Fetal Electrocardiogram Database)
aEKG	– Břišní (abdominální) elektrokardiografie
aEKG*	– Odhadnutý břišní elektrokardiogram
AFE	– Adaptivní zesilovač plodového (fetálního) elektrokardiogramu (Adaptive Fetal Electrocardiogram Enhancer)
ANFIS	– Adaptivní neuro-fuzzy inferenční systém (Adaptive Neuro Fuzzy Inference System)
ANN	– Umělé neuronové sítě (Artificial Neural Networks)
AT	– Průměrovací technika (Averaging Technique)
BM	– Barrosova metoda (Barros's Method)
BMI	– Index tělesné hmotnosti (Body Mass Index)
bpm	– Počet tepů za minutu (beats per minute)
BSE	– Slepá extrakce zdrojů (Blind Source Extraction)
BSS	– Slepá separace zdrojů (Blind Source Separation)
BW	– Butterworthův filtr (Butterworth Filter)
CS	– Stlačené snímání (Compressed Sensed)
CT	– Korelační technika (Correlation Technique)
CWT	– Spojitá vlnková transformace (Continuous Wavelet Transform)
DP	– Filtr dolní propusti
DWT	– Diskrétní vlnková transformace (Discrete Wavelet Transform)
EEMD	– Soubor empirického režimu rozkladu (Ensemble Empirical Mode Decomposition)
EHG	– Elektrohysterografie
EKG	– Elektrokardiografie, elektrokardiogram
EMD	– Empirický režim rozkladu (Empirical Mode Decomposition)
EVD	– Metoda rozkladu vlastních hodnot (Eigenvalue Decomposition)
F1	– Harmonický průměr mezi senzitivitou a pozitivní prediktivní hodnotou
FAMC	– Adaptivní metoda čtyřkanálového odstranění mateřského elektrokardiogramu (Four channel Adaptive Maternal Electrocardiogram Cancellor)

FastAdaptOgICA	– Rychlá a adaptivní analýza nezávislých komponent založená na plně multiplikatívni ortogonální skupině (Fast and Adaptive Independent Component Analysis method based on fully-multiplicative Orthogonal-group)
FastICA	– Rychlá analýza nezávislých komponent (Fast Independent Component Analysis)
FCM	– Fuzzy C-means shlukování (Fuzzy C-means Clustering)
FECGSYNDB	– Databáze simulovaných signálů fetální elektrokardiografie (Fetal Electrocardiogram Synthetic Database)
fECHO	– Fetální echokardiografie (fetal Echocardiography)
fEKG	– Plodová (fetální) elektrokardiografie
fFKG	– Plodová (fetální) fonokardiografie
fHR	– Plodová (fetální) tepová frekvence (Fetal Heart Rate)
fHRV	– Variabilita plodové (fetální) tepové frekvence (Fetal Heart Rate Variability)
fHS	– Plodové (fetální) srdeční zvuky (Fetal Heart Sounds)
FIR	– Frekvenčně selektivní filtr s konečnou impulzní odezvou (Finite Impulse Response)
FlexiICA	– Flexibilní analýza nezávislých komponent (Flexible Independent Component Analysis)
fMKG	– Fetální magnetokardiografie
FN	– Falešně negativní hodnota (False Negative)
FP	– Falešně pozitivní hodnota (False Positive)
fQRS	– Plodový (fetální) QRS komplex
Fs	– Vzorkovací frekvence (Sampling Frequency)
FSE	– Fetální skalpová elektroda (Fetal Scalp Electrode)
FT	– Filtrační technika (Filtering Technique)
GA	– Gestační věk (Gestational age)
HNN	– Hybridní neuronové sítě (Hybrid Neural Networks)
HP	– Filtr horní propusti
I-fEKG	– Invazivní plodová (fetální) elektrokardiografie
ICA	– Analýza nezávislých komponent (Independent Component Analysis)
IIR	– Frekvenčně selektivní filtr s nekonečnou impulzní odezvou (Infinite Impulse Response)
IMF	– Funkce vnitřního režimu (Intrinsic Mode Function)
InfoMax	– Maximalizování informace analýzy nezávislých komponent
JADE	– Přibližné diagonalizované spojení vlastních matic (Joint Approximate Diagonalization of Eigen matrices)

KF	– Kalmanova filtrace (Kalman Filtering)
KTG	– Kardiokardiografie
LMS	– Algoritmus založený na stochasticky gradientní adaptaci (Least Mean Square)
MA	– Klouzavé průměrování (Moving Average)
mEKG	– Mateřská elektrokardiografie
mEKG*	– Mateřský elektrokardiogram zpožděný o jeden vzorek
MEMD	– Multivariační empirický režim rozkladu (Multivariate Empirical Mode Decomposition)
MeRMaId	– Minimální Renyiho vzájemná informace (Minimum Renyi's Mutual Information)
mHR	– Mateřská tepová frekvence (Maternal Heart Rate)
mHS	– Mateřské srdeční zvuky (Maternal Heart Sounds)
MICA	– Multidimenzionální analýza nezávislých komponent (Multidimensional Independent Component Analysis)
MIT-BIH	– Databáze arytmii vytvořená institucí technologií v Massachusetts a nemocnicí v Beth Israel (Massachusetts Institute of Technology and Beth Israel Hospital)
mQRS	– Mateřský QRS komplex
MSE	– Střední kvadratická odchylka (Mean Square Error)
NI-fEKG	– Neinvazivní plodová (fetální) elektrokardiografie
NIFECGDB	– Databáze neinvazivní plodové (fetální) elektrokardiografie (Non-Invasive Fetal Electrocardiogram Database)
NM	– Nelokální mediánová metoda (Nonlocal Median)
NpICA	– Neparаметrická analýza nezávislých komponent (Nonparametric Independent Component Analysis)
OgICA	– Neurální ortogonální skupina analýzy nezávislých komponent (Orthogonal-group Independent Component Analysis neural method)
PC	– Polynomiální klasifikátory (Polynomial Classifiers)
PCA	– Analýza hlavních komponent (Principal Component Analysis)
PDF	– Funkce hustoty pravděpodobnosti (Probability Density Function)
PEVD	– Polynomiální maticový rozklad vlastních hodnot (Polynomial Matrix Eigenvalue Decomposition)
PF	– Projektivní filtrování (Projective Filtering)
PP	– Filtr typu pásmová propust
PPV	– Pozitivní prediktivní hodnota (Positive Predictive Value)
PSWT	– Vlnková transformace založená na dvouprůchodovém stupni synchronizace (Pitch Synchronous Wavelet Transform)

PZ	– Filtr typu pásmová zádrž
QIO	– Optimalizovaná kvalita indexu (Quality Index Optimization)
res	– Amplitudové rozlišení (amplitude resolution)
RLS	– Algoritmus založený na rekurzivní optimální adaptaci (Recursive Least Square)
RMSE	– Relativní střední kvadratická odchylka (Root Mean Square Error)
S1	– První srdeční zvuk (Sound 1)
S2	– Druhý srdeční zvuk (Sound 2)
SA	– Sekvenční analýza (Sequential Analysis)
SCBSS	– Jednokanálová slepá separace zdrojů (Single Channel Blind Source Separation)
SCICA	– Jednokanálové analýza nezávislých komponent (Single Channel Independent Component Analysis)
SDR	– Odstup signálu od deformace (Signal-to-Distortion Ratio)
SE	– Sensitivita (Sensitivity)
SGSF	– Savitzky-Golayův vyhlazovací filtr (Savitzky-Golay Smoothing Filter)
SM	– Metoda šikmosti (Skewness method)
SNR	– Odstup signálu od šumu (Signal-to-noise Ratio)
SQUID	– Supravodivé kvantové interferenční zařízení (Superconducting Quantum Interference Device)
STFT	– De-shape krátko časová Fourierova transformace (Short Time Fourier Transform)
STVD	– Metoda sekvenčního totálního variačního odstranění šumu (Sequential Total Variation Denoising)
ST	– Odčítací technika (Subtraction Technique)
SVD	– Rozklad singulárních hodnot (Singular Value Decomposition)
T	– Délka záznamu (Time)
TP	– Skutečný počet srdečních úderů v záznamu (True Positive)
TS	– Šablonové odčítání (Template Subtraction)
TS _{PCA}	– Šablonové odčítání využívající analýzu hlavních komponent (Template Subtraction with Principal Component Analysis)
TVD	– Metoda totálního variačního odstranění šumu (Total Variation Denoising)
WF	– Wienerovo filtrování
WS	– Vlnkové zmenšení (Wavelet Shrinkage)
WT	– Vlnková transformace (Wavelet Transform)
ZM	– Zhangova metoda (Zhang's Method)
π CA	– Analýza periodických komponent (Period Component Analysis)

A	– Fuzzy množina
\mathbf{A}_{mix}	– Směšovací matice
$\tilde{\mathbf{A}}_{\text{mix}}$	– Vybělená ortogonální směšovací matice
AE_0	– Referenční elektroda
AE_1 až AE_n	– Aktivní abdominální elektrody
a	– Parametr související se vzdáleností srdce od elektrod
\overrightarrow{aEKG}	– Vektor obsahující signál abdominálního elektrokardiogramu
CWT	– Výpočet spojitě vlnkové transformace
CWT^{-1}	– Výpočet zpětné spojitě vlnkové transformace
c	– Signál složený z detailních složek a poslední aproximační složky
cA	– Aproximační složka
cD	– Detailní složka
\mathbf{D}	– Diagonální matice vlastních hodnot
\vec{D}	– Vektor diferencí mezi odhadnutými a referenčními hodnotami fetální tepové frekvence
DWT	– Výpočet diskrétní vlnkové transformace
DWT^{-1}	– Výpočet zpětné diskrétní vlnkové transformace
d	– Požadovaný výstup
E	– Střední hodnota
\mathbf{E}	– Ortogonální matice vlastních vektorů
e	– Stanovená chyba mezi požadovaným a reálným výstupem
f	– Fetální R kmit
f_{FIR_H}	– Horní mezní frekvence frekvenčně selektivního filtru s konečnou impulzní odezvou
f_{FIR_L}	– Dolní mezní frekvence frekvenčně selektivního filtru s konečnou impulzní odezvou
\overrightarrow{fEKG}	– Vektor obsahující signál fetálního elektrokardiogramu
\overrightarrow{fHR}	– Vektor aktuálních hodnot fetální tepové frekvence
fs	– Vzorkovací frekvence
G	– Kvadratická funkce
$G(\omega)$	– Frekvenční charakteristika frekvenčně selektivního filtru s konečnou impulzní odezvou
g	– Derivace
H	– Entropie
$H(z)$	– Přenosová funkce frekvenčně selektivního filtru s konečnou impulzní odezvou
h	– Impulzní odezva frekvenčně selektivního filtru s konečnou impulzní odezvou
\vec{i}	– Vektor excitací vstupní vrstvy

J	– Negentropie
K_{WT}	– Empirická konstanta
k	– Pozitivní konstanta
\vec{k}	– Vektor zisků
k_{ANF}	– Počet epoch adaptivního neuro-fuzzy inferenčního systému
k_{ICA}	– Maximální počet iterací cyklu analýzy nezávislých komponent
$kurt$	– Špičatost
L	– L tvar funkce příslušnosti
LP	– Jazyková proměnná
l_{WT}	– Délka okna pro adaptivní prahování vlnkové transformace
\vec{M}	– Vektor průměrů mezi odhadnutými a referenčními hodnotami fetální tepové frekvence
m	– Mateřský R kmit
Me	– Medián
$\vec{mEK\vec{G}}$	– Vektor obsahující signál mateřského elektrokardiogramu
N	– Aktivní zem
N_{FIR}	– Řád frekvenčně selektivního filtru s konečnou impulzní odezvou
N_{RLS}	– Řád filtru založeném na rekurzivní optimální adaptaci
n_{ANF}	– Počet funkcí příslušnosti adaptivního neuro-fuzzy inferenčního systému
n_{ICA}	– Počet výstupních komponent analýzy nezávislých komponent
n_{WT}	– Úroveň rozkladu
$\vec{\sigma}$	– Vektor excitací výstupní vrstvy
P	– Pravděpodobnost
\mathbf{P}	– Permutační matice
P_1 až P_n	– Mikrofony umístěné v břišní oblasti pro fetální fonokardiografii
p	– Funkce hustoty pravděpodobnosti
QRS	– Amplituda QRS komplexu
R	– Počet pravidel expertního systému
$ST_{\text{analýza}}$	– Výpočet ST analýzy
\vec{s}	– Vektor zdrojového signálu
s	– Dilatační škálovací parametr
$s_1(t)$ až $s_n(t)$	– Zdrojové signály
$\vec{\text{šum}}$	– Vektor obsahující signál šumu
T	– Amplituda T vlny
\vec{T}	– Vektor intervalů
T_1 až T_n	– Hrudní elektrody
t	– Index času
U	– Univerzum

v	– Proměnná pocházející z normálního rozdělení dat
\mathbf{W}	– Inverzní matice ke směšovací matici
w	– Koeficient vah
\vec{w}	– Vektor vah
$\vec{\bar{w}}$	– Vektor vah z předešlé iterace
\vec{X}	– Vektor náhodných veličin získaných z referenční křivky fetální te- pové frekvence
x	– Vstupní signál
\vec{x}	– Vektor smíšeného signálu
$\vec{\bar{x}}$	– Vycentrovaný a vybělený vektor smíšeného signálu
$x_1(t)$ až $x_n(t)$	– Naměřené signály
\vec{Y}	– Vektor náhodných veličin získaných z odhadnuté křivky fetální te- pové frekvence
y	– Reálný výstup
z	– Vnitřní potenciál neuronu
z^{-1}	– Zpoždění
Δw_i	– Změna synaptické váhy po předešlém stavu
δ_{ICA}	– Kritérium konvergence analýzy nezávislých komponent
η	– Koeficient učení
θ	– Prahová hodnota neuronu
λ	– Strmost sigmoidu
λ_{RLS}	– Faktor zapomínání algoritmu založeném na rekurzivní optimální adaptaci
λ_{WT}	– Koeficient prahování
μ	– Střední hodnota
μ_{ANF}	– Tvar funkcí příslušnosti adaptivního neuro-fuzzy inferenčního sys- tému
μ_{ANF_A} (μ_{ANF_B})	– Míra příslušnosti prvku do fuzzy množiny A (B)
μ_{NS}	– Koeficient vlivu změny synaptických vah po předešlém stavu
ξ	– Účelová funkce
Π	– Lichoběžníkový tvar funkce příslušnosti
$\rho^{měkké}$	– Měkké prahování
$\rho^{tvrdé}$	– Tvrdé prahování
σ	– Směrodatná odchylka
τ	– Translační škálovací parametr
Φ_{WT}	– Škálovací funkce
Ψ_{WT}	– Typ mateřské vlnky
Γ	– Γ tvar funkce příslušnosti
\wedge	– Trojúhelníkový tvar funkce příslušnosti

Seznam obrázků

1	Ukázka fetální echokardiografie.	34
2	Ukázka fetální magnetokardiografie.	35
3	Ukázka kardiokardiografie.	36
4	Zařízení pro měření fetální fonokardiografie.	39
5	Ukázka rozmístění elektrod při fetální elektrokardiografii. Červené elektrody jsou aktivní elektrody, bílé elektrody jsou referenční elektrody a GND představuje zemní elektrody.	41
6	Ukázka naměřených reálných signálů z databáze ADFECGDB.	42
7	Komerčně dostupná zařízení pro měření NI-fEKG.	43
8	ST analyzátor S31.	44
9	Techniky monitorování plodu a zpracování signálu.	45
10	Blokové schéma FIR filtru.	77
11	Grafické znázornění BSS problému při zpracování fEKG signálu.	79
12	Blokové schéma funkce metody FastICA.	83
13	Schémata adaptivního algoritmu.	84
14	Principiální schéma funkce algoritmu RLS.	87
15	Blokové schéma fuzzy inferenčního systému typu Takagi-Sugeno.	89
16	Schématický model funkčního neuronu (perceptron).	90
17	Vícevrstvá neuronová síť.	91
18	Architektura metody ANFIS se dvěma vstupy a jedním výstupem.	93
19	Ukázka vybraných vlnek vygenerovaných v programu MATLAB.	97
20	Multirozklad signálu pomocí DWT se stupněm rozkladu 3.	98
21	Paketový rozklad signálu pomocí DWT se stupněm rozkladu 3.	98
22	Blokové schéma principu DWT při použití adaptivního a měkkého prahování.	100
23	Ukázka vstupních signálů ze databáze ADFECGDB (záznam r01).	101
24	Ukázka vstupních signálů ze databáze EKG physionet challenge 2013 (záznam a01).	102
25	Ukázka automatického stanovení TP, FP a FN na základě referenčních anotací pro extrahovaný signál pomocí hybridní metody ICA-RLS-WT na záznamu r06.	103
26	Hustota normálního rozdělení dat (Gaussovo rozdělení).	105
27	Zjednodušené blokové schéma hybridního systému.	106
28	Předzpracování vstupních signálů.	107
29	Aplikování ICA metody k obdržení komponent pro adaptivní metody.	108
30	Postup algoritmu automatického volení a centrování výstupních komponent z ICA metody.	108
31	Extrakce fEKG signálu z vycentrovaných signálů pomocí metody ANFIS.	109
32	Extrakce fEKG signálu z vycentrovaných signálů pomocí RLS algoritmu.	110
33	Vyhlazení fEKG signálu pomocí WT po výstupu z adaptivních filtrů.	111

34	Schéma hodnocení kvality extrakce fEKG signálu pomocí obou hybridních metod.	112
35	Průběhy fEKG signálů ze záznamu r01 s vyznačenými pozicemi R kmitů.	113
36	Ukázka postupu odhadnutí křivky fHR z extrahovaného fEKG signálu ze záznamu r01 pomocí hybridní metody ICA-ANFIS-WT.	114
37	Grafické srovnání odhadnutých a referenčních křivek fHR ze všech 12 záznamů databáze ADFECGDB.	119
38	Srovnání odhadnutých a referenčních křivek fHR ze záznamu r01 pomocí Bland-Altmanova grafu.	120
39	Srovnání odhadnutých a referenčních křivek fHR ze záznamu r08 pomocí Bland-Altmanova grafu.	121
40	Srovnání odhadnutých a referenčních křivek fHR ze záznamu r04 pomocí Bland-Altmanova grafu.	121
41	Srovnání odhadnutých a referenčních křivek fHR ze záznamu r11 pomocí Bland-Altmanova grafu.	122
42	Grafické srovnání odhadnutých a referenčních křivek fHR ze všech 25 záznamů databáze EKG physionet challenge 2013.	126
43	Srovnání odhadnutých a referenčních křivek fHR ze záznamu a05 pomocí Bland-Altmanova grafu.	127
44	Srovnání odhadnutých a referenčních křivek fHR ze záznamu a08 pomocí Bland-Altmanova grafu.	128
45	Srovnání odhadnutých a referenčních křivek fHR ze záznamu a02 pomocí Bland-Altmanova grafu.	128
46	Srovnání odhadnutých a referenčních křivek fHR ze záznamu a18 pomocí Bland-Altmanova grafu.	129
47	Odhadnutá křivka fHR pomocí metody ICA-RLS-WT na záznamu r10. Grafy (a), (b) a (c) znázorňují 3 vybrané úseky, kde filtrace nefungovala, a grafy (d), (e) a (f) znázorňují 3 vybrané úseky, kde filtrace fungovala správně.	131
48	Odhadnutá křivka fHR pomocí hybridních metod ICA-ANFIS-WT a ICA-RLS-WT na záznamu r03. Grafy (a) až (f) znázorňují vybrané úseky pro srovnání účinnosti obou metod.	132
49	Odhadnutá křivka fHR pomocí hybridních metod ICA-ANFIS-WT a ICA-RLS-WT na záznamu a08. Grafy (a) až (f) znázorňují vybrané úseky, kde filtraci obou hybridních metod fungovala správně.	133
50	Odhadnutá křivka fHR pomocí hybridních metod ICA-ANFIS-WT a ICA-RLS-WT na záznamu a18. Grafy (a) až (f) znázorňují vybrané úseky, kde filtraci obou hybridních metod nefungovala.	134
51	Srovnání odhadnutých a referenčních křivek fHR ze záznamu r02 pomocí Bland-Altmanova grafu.	172

52	Srovnání odhadnutých a referenčních křivek fHR ze záznamu r03 pomocí Bland-Altmanova grafu.	172
53	Srovnání odhadnutých a referenčních křivek fHR ze záznamu r05 pomocí Bland-Altmanova grafu.	173
54	Srovnání odhadnutých a referenčních křivek fHR ze záznamu r06 pomocí Bland-Altmanova grafu.	173
55	Srovnání odhadnutých a referenčních křivek fHR ze záznamu r07 pomocí Bland-Altmanova grafu.	174
56	Srovnání odhadnutých a referenčních křivek fHR ze záznamu r09 pomocí Bland-Altmanova grafu.	174
57	Srovnání odhadnutých a referenčních křivek fHR ze záznamu r10 pomocí Bland-Altmanova grafu.	175
58	Srovnání odhadnutých a referenčních křivek fHR ze záznamu r12 pomocí Bland-Altmanova grafu.	175
59	Srovnání odhadnutých a referenčních křivek fHR ze záznamu a01 pomocí Bland-Altmanova grafu.	193
60	Srovnání odhadnutých a referenčních křivek fHR ze záznamu a03 pomocí Bland-Altmanova grafu.	194
61	Srovnání odhadnutých a referenčních křivek fHR ze záznamu a04 pomocí Bland-Altmanova grafu.	194
62	Srovnání odhadnutých a referenčních křivek fHR ze záznamu a06 pomocí Bland-Altmanova grafu.	195
63	Srovnání odhadnutých a referenčních křivek fHR ze záznamu a07 pomocí Bland-Altmanova grafu.	195
64	Srovnání odhadnutých a referenčních křivek fHR ze záznamu a09 pomocí Bland-Altmanova grafu.	196
65	Srovnání odhadnutých a referenčních křivek fHR ze záznamu a10 pomocí Bland-Altmanova grafu.	196
66	Srovnání odhadnutých a referenčních křivek fHR ze záznamu a11 pomocí Bland-Altmanova grafu.	197
67	Srovnání odhadnutých a referenčních křivek fHR ze záznamu a12 pomocí Bland-Altmanova grafu.	197
68	Srovnání odhadnutých a referenčních křivek fHR ze záznamu a13 pomocí Bland-Altmanova grafu.	198
69	Srovnání odhadnutých a referenčních křivek fHR ze záznamu a14 pomocí Bland-Altmanova grafu.	198
70	Srovnání odhadnutých a referenčních křivek fHR ze záznamu a15 pomocí Bland-Altmanova grafu.	199

71	Srovnání odhadnutých a referenčních křivek fHR ze záznamu a16 pomocí Bland-Altmanova grafu.	199
72	Srovnání odhadnutých a referenčních křivek fHR ze záznamu a17 pomocí Bland-Altmanova grafu.	200
73	Srovnání odhadnutých a referenčních křivek fHR ze záznamu a19 pomocí Bland-Altmanova grafu.	200
74	Srovnání odhadnutých a referenčních křivek fHR ze záznamu a20 pomocí Bland-Altmanova grafu.	201
75	Srovnání odhadnutých a referenčních křivek fHR ze záznamu a21 pomocí Bland-Altmanova grafu.	201
76	Srovnání odhadnutých a referenčních křivek fHR ze záznamu a22 pomocí Bland-Altmanova grafu.	202
77	Srovnání odhadnutých a referenčních křivek fHR ze záznamu a23 pomocí Bland-Altmanova grafu.	202
78	Srovnání odhadnutých a referenčních křivek fHR ze záznamu a24 pomocí Bland-Altmanova grafu.	203
79	Srovnání odhadnutých a referenčních křivek fHR ze záznamu a25 pomocí Bland-Altmanova grafu.	203

Seznam tabulek

1	Hodnocení KTG podle klasifikace FIGO.	38
2	Tabulka srovnání technik monitorování plodu.	46
3	Tabulka srovnání neadaptivních metod využívajících jednonábový zdroj signálu.	53
4	Tabulka srovnání neadaptivních metod využívajících vícekanábový zdroj signálů.	64
5	Tabulka srovnání hybridních metod.	69
6	Srovnání popsaných metod zpracování signálů z hlediska získání klinických informací.	71
7	Nastavení parametrů metody ANFIS vzhledem k počtu funkcí příslušnosti n_{ANF}	110
8	Ideální kombinace elektrod a nastavení metody ANFIS pro jednotlivé záznamy databáze ADFECGDB. Stanovené počty TP, FP a FN na základě detekce pozic R kmitů v extrahovaných fEKG signálech pomocí hybridní metody ICA-ANFIS-WT vzhledem k referenčním pozicím R kmitů a výpočet parametrů ACC, SE, PPV a F1.	117
9	Ideální kombinace elektrod a nastavení algoritmu RLS pro jednotlivé záznamy databáze ADFECGDB. Stanovené počty TP, FP a FN na základě detekce pozic R kmitů v extrahovaných fEKG signálech pomocí hybridní metody ICA-RLS-WT vzhledem k referenčním pozicím R kmitů a výpočet parametrů ACC, SE, PPV a F1.	118
10	Zaznamenané střední hodnoty μ a hodnoty $1,96\sigma$ po provedení Bland-Altmanových grafů pro jednotlivé upravené odhadnuté křivky fHR pomocí obou hybridních metod vzhledem k referenčním křivkám fHR (databáze ADFECGDB).	123
11	Ideální kombinace elektrod a nastavení metody ANFIS pro jednotlivé záznamy databáze EKG physionet challenge 2013. Stanovené počty TP, FP a FN na základě detekce pozic R kmitů v extrahovaných fEKG signálech pomocí hybridní metody ICA-ANFIS-WT vzhledem k referenčním pozicím R kmitů a výpočet parametrů ACC, SE, PPV a F1.	124
12	Ideální kombinace elektrod a nastavení řádu filtru algoritmu RLS pro jednotlivé záznamy databáze EKG physionet challenge 2013. Stanovené počty TP, FP a FN na základě detekce pozic R kmitů v extrahovaných fEKG signálech pomocí hybridní metody ICA-RLS-WT vzhledem k referenčním pozicím R kmitů a výpočet parametrů ACC, SE, PPV a F1.	125
13	Zaznamenané střední hodnoty μ a hodnoty $1,96\sigma$ po provedení Bland-Altmanových grafů pro jednotlivé upravené odhadnuté křivky fHR pomocí obou hybridních metod vzhledem k referenčním křivkám fHR (databáze EKG physionet challenge 2013).	129

14	Ideální nastavení metody ANFIS pro všechny možné kombinace elektrod u záznamu r01. Stanovené počty TP, FP a FN na základě detekce pozic R kmitů v extrahovaných fEKG signálech pomocí hybridní metody ICA-ANFIS-WT vzhledem k referenčním pozicím R kmitů a výpočet parametrů ACC, SE, PPV a F1.	163
15	Ideální nastavení řádu filtru algoritmu RLS pro všechny možné kombinace elektrod u záznamu r01. Stanovené počty TP, FP a FN na základě detekce pozic R kmitů v extrahovaných fEKG signálech pomocí hybridní metody ICA-RLS-WT vzhledem k referenčním pozicím R kmitů a výpočet parametrů ACC, SE, PPV a F1.	164
16	Ideální nastavení metody ANFIS pro všechny možné kombinace elektrod u záznamu r02. Stanovené počty TP, FP a FN na základě detekce pozic R kmitů v extrahovaných fEKG signálech pomocí hybridní metody ICA-ANFIS-WT vzhledem k referenčním pozicím R kmitů a výpočet parametrů ACC, SE, PPV a F1.	164
17	Ideální nastavení řádu filtru algoritmu RLS pro všechny možné kombinace elektrod u záznamu r02. Stanovené počty TP, FP a FN na základě detekce pozic R kmitů v extrahovaných fEKG signálech pomocí hybridní metody ICA-RLS-WT vzhledem k referenčním pozicím R kmitů a výpočet parametrů ACC, SE, PPV a F1.	164
18	Ideální nastavení metody ANFIS pro všechny možné kombinace elektrod u záznamu r03. Stanovené počty TP, FP a FN na základě detekce pozic R kmitů v extrahovaných fEKG signálech pomocí hybridní metody ICA-ANFIS-WT vzhledem k referenčním pozicím R kmitů a výpočet parametrů ACC, SE, PPV a F1.	165
19	Ideální nastavení řádu filtru algoritmu RLS pro všechny možné kombinace elektrod u záznamu r03. Stanovené počty TP, FP a FN na základě detekce pozic R kmitů v extrahovaných fEKG signálech pomocí hybridní metody ICA-RLS-WT vzhledem k referenčním pozicím R kmitů a výpočet parametrů ACC, SE, PPV a F1.	165
20	Ideální nastavení metody ANFIS pro všechny možné kombinace elektrod u záznamu r04. Stanovené počty TP, FP a FN na základě detekce pozic R kmitů v extrahovaných fEKG signálech pomocí hybridní metody ICA-ANFIS-WT vzhledem k referenčním pozicím R kmitů a výpočet parametrů ACC, SE, PPV a F1.	165
21	Ideální nastavení řádu filtru algoritmu RLS pro všechny možné kombinace elektrod u záznamu r04. Stanovené počty TP, FP a FN na základě detekce pozic R kmitů v extrahovaných fEKG signálech pomocí hybridní metody ICA-RLS-WT vzhledem k referenčním pozicím R kmitů a výpočet parametrů ACC, SE, PPV a F1.	166

22	Ideální nastavení metody ANFIS pro všechny možné kombinace elektrod u záznamu r05. Stanovené počty TP, FP a FN na základě detekce pozic R kmitů v extrahovaných fEKG signálech pomocí hybridní metody ICA-ANFIS-WT vzhledem k referenčním pozicím R kmitů a výpočet parametrů ACC, SE, PPV a F1.	166
23	Ideální nastavení řádu filtru algoritmu RLS pro všechny možné kombinace elektrod u záznamu r05. Stanovené počty TP, FP a FN na základě detekce pozic R kmitů v extrahovaných fEKG signálech pomocí hybridní metody ICA-RLS-WT vzhledem k referenčním pozicím R kmitů a výpočet parametrů ACC, SE, PPV a F1.	166
24	Ideální nastavení metody ANFIS pro všechny možné kombinace elektrod u záznamu r06. Stanovené počty TP, FP a FN na základě detekce pozic R kmitů v extrahovaných fEKG signálech pomocí hybridní metody ICA-ANFIS-WT vzhledem k referenčním pozicím R kmitů a výpočet parametrů ACC, SE, PPV a F1.	167
25	Ideální nastavení řádu filtru algoritmu RLS pro všechny možné kombinace elektrod u záznamu r06. Stanovené počty TP, FP a FN na základě detekce pozic R kmitů v extrahovaných fEKG signálech pomocí hybridní metody ICA-RLS-WT vzhledem k referenčním pozicím R kmitů a výpočet parametrů ACC, SE, PPV a F1.	167
26	Ideální nastavení metody ANFIS pro všechny možné kombinace elektrod u záznamu r07. Stanovené počty TP, FP a FN na základě detekce pozic R kmitů v extrahovaných fEKG signálech pomocí hybridní metody ICA-ANFIS-WT vzhledem k referenčním pozicím R kmitů a výpočet parametrů ACC, SE, PPV a F1.	167
27	Ideální nastavení řádu filtru algoritmu RLS pro všechny možné kombinace elektrod u záznamu r07. Stanovené počty TP, FP a FN na základě detekce pozic R kmitů v extrahovaných fEKG signálech pomocí hybridní metody ICA-RLS-WT vzhledem k referenčním pozicím R kmitů a výpočet parametrů ACC, SE, PPV a F1.	168
28	Ideální nastavení metody ANFIS pro všechny možné kombinace elektrod u záznamu r08. Stanovené počty TP, FP a FN na základě detekce pozic R kmitů v extrahovaných fEKG signálech pomocí hybridní metody ICA-ANFIS-WT vzhledem k referenčním pozicím R kmitů a výpočet parametrů ACC, SE, PPV a F1.	168
29	Ideální nastavení řádu filtru algoritmu RLS pro všechny možné kombinace elektrod u záznamu r08. Stanovené počty TP, FP a FN na základě detekce pozic R kmitů v extrahovaných fEKG signálech pomocí hybridní metody ICA-RLS-WT vzhledem k referenčním pozicím R kmitů a výpočet parametrů ACC, SE, PPV a F1.	168

30	Ideální nastavení metody ANFIS pro všechny možné kombinace elektrod u záznamu r09. Stanovené počty TP, FP a FN na základě detekce pozic R kmitů v extrahovaných fEKG signálech pomocí hybridní metody ICA-ANFIS-WT vzhledem k referenčním pozicím R kmitů a výpočet parametrů ACC, SE, PPV a F1.	169
31	Ideální nastavení řádu filtru algoritmu RLS pro všechny možné kombinace elektrod u záznamu r09. Stanovené počty TP, FP a FN na základě detekce pozic R kmitů v extrahovaných fEKG signálech pomocí hybridní metody ICA-RLS-WT vzhledem k referenčním pozicím R kmitů a výpočet parametrů ACC, SE, PPV a F1.	169
32	Ideální nastavení metody ANFIS pro všechny možné kombinace elektrod u záznamu r10. Stanovené počty TP, FP a FN na základě detekce pozic R kmitů v extrahovaných fEKG signálech pomocí hybridní metody ICA-ANFIS-WT vzhledem k referenčním pozicím R kmitů a výpočet parametrů ACC, SE, PPV a F1.	169
33	Ideální nastavení řádu filtru algoritmu RLS pro všechny možné kombinace elektrod u záznamu r10. Stanovené počty TP, FP a FN na základě detekce pozic R kmitů v extrahovaných fEKG signálech pomocí hybridní metody ICA-RLS-WT vzhledem k referenčním pozicím R kmitů a výpočet parametrů ACC, SE, PPV a F1.	170
34	Ideální nastavení metody ANFIS pro všechny možné kombinace elektrod u záznamu r11. Stanovené počty TP, FP a FN na základě detekce pozic R kmitů v extrahovaných fEKG signálech pomocí hybridní metody ICA-ANFIS-WT vzhledem k referenčním pozicím R kmitů a výpočet parametrů ACC, SE, PPV a F1.	170
35	Ideální nastavení řádu filtru algoritmu RLS pro všechny možné kombinace elektrod u záznamu r11. Stanovené počty TP, FP a FN na základě detekce pozic R kmitů v extrahovaných fEKG signálech pomocí hybridní metody ICA-RLS-WT vzhledem k referenčním pozicím R kmitů a výpočet parametrů ACC, SE, PPV a F1.	170
36	Ideální nastavení metody ANFIS pro všechny možné kombinace elektrod u záznamu r12. Stanovené počty TP, FP a FN na základě detekce pozic R kmitů v extrahovaných fEKG signálech pomocí hybridní metody ICA-ANFIS-WT vzhledem k referenčním pozicím R kmitů a výpočet parametrů ACC, SE, PPV a F1.	171
37	Ideální nastavení řádu filtru algoritmu RLS pro všechny možné kombinace elektrod u záznamu r12. Stanovené počty TP, FP a FN na základě detekce pozic R kmitů v extrahovaných fEKG signálech pomocí hybridní metody ICA-RLS-WT vzhledem k referenčním pozicím R kmitů a výpočet parametrů ACC, SE, PPV a F1.	171

38	Ideální nastavení metody ANFIS pro všechny možné kombinace elektrod u záznamu a01. Stanovené počty TP, FP a FN na základě detekce pozic R kmitů v extrahovaných fEKG signálech pomocí hybridní metody ICA-ANFIS-WT vzhledem k referenčním pozicím R kmitů a výpočet parametrů ACC, SE, PPV a F1.	176
39	Ideální nastavení řádu filtru algoritmu RLS pro všechny možné kombinace elektrod u záznamu a01. Stanovené počty TP, FP a FN na základě detekce pozic R kmitů v extrahovaných fEKG signálech pomocí hybridní metody ICA-RLS-WT vzhledem k referenčním pozicím R kmitů a výpočet parametrů ACC, SE, PPV a F1.	177
40	Ideální nastavení metody ANFIS pro všechny možné kombinace elektrod u záznamu a02. Stanovené počty TP, FP a FN na základě detekce pozic R kmitů v extrahovaných fEKG signálech pomocí hybridní metody ICA-ANFIS-WT vzhledem k referenčním pozicím R kmitů a výpočet parametrů ACC, SE, PPV a F1.	177
41	Ideální nastavení řádu filtru algoritmu RLS pro všechny možné kombinace elektrod u záznamu a02. Stanovené počty TP, FP a FN na základě detekce pozic R kmitů v extrahovaných fEKG signálech pomocí hybridní metody ICA-RLS-WT vzhledem k referenčním pozicím R kmitů a výpočet parametrů ACC, SE, PPV a F1.	177
42	Ideální nastavení metody ANFIS pro všechny možné kombinace elektrod u záznamu a03. Stanovené počty TP, FP a FN na základě detekce pozic R kmitů v extrahovaných fEKG signálech pomocí hybridní metody ICA-ANFIS-WT vzhledem k referenčním pozicím R kmitů a výpočet parametrů ACC, SE, PPV a F1.	178
43	Ideální nastavení řádu filtru algoritmu RLS pro všechny možné kombinace elektrod u záznamu a03. Stanovené počty TP, FP a FN na základě detekce pozic R kmitů v extrahovaných fEKG signálech pomocí hybridní metody ICA-RLS-WT vzhledem k referenčním pozicím R kmitů a výpočet parametrů ACC, SE, PPV a F1.	178
44	Ideální nastavení metody ANFIS pro všechny možné kombinace elektrod u záznamu a04. Stanovené počty TP, FP a FN na základě detekce pozic R kmitů v extrahovaných fEKG signálech pomocí hybridní metody ICA-ANFIS-WT vzhledem k referenčním pozicím R kmitů a výpočet parametrů ACC, SE, PPV a F1.	178
45	Ideální nastavení řádu filtru algoritmu RLS pro všechny možné kombinace elektrod u záznamu a04. Stanovené počty TP, FP a FN na základě detekce pozic R kmitů v extrahovaných fEKG signálech pomocí hybridní metody ICA-RLS-WT vzhledem k referenčním pozicím R kmitů a výpočet parametrů ACC, SE, PPV a F1.	179

46	Ideální nastavení metody ANFIS pro všechny možné kombinace elektrod u záznamu a05. Stanovené počty TP, FP a FN na základě detekce pozic R kmitů v extrahovaných fEKG signálech pomocí hybridní metody ICA-ANFIS-WT vzhledem k referenčním pozicím R kmitů a výpočet parametrů ACC, SE, PPV a F1.	179
47	Ideální nastavení řádu filtru algoritmu RLS pro všechny možné kombinace elektrod u záznamu a05. Stanovené počty TP, FP a FN na základě detekce pozic R kmitů v extrahovaných fEKG signálech pomocí hybridní metody ICA-RLS-WT vzhledem k referenčním pozicím R kmitů a výpočet parametrů ACC, SE, PPV a F1.	179
48	Ideální nastavení metody ANFIS pro všechny možné kombinace elektrod u záznamu a06. Stanovené počty TP, FP a FN na základě detekce pozic R kmitů v extrahovaných fEKG signálech pomocí hybridní metody ICA-ANFIS-WT vzhledem k referenčním pozicím R kmitů a výpočet parametrů ACC, SE, PPV a F1.	180
49	Ideální nastavení řádu filtru algoritmu RLS pro všechny možné kombinace elektrod u záznamu a06. Stanovené počty TP, FP a FN na základě detekce pozic R kmitů v extrahovaných fEKG signálech pomocí hybridní metody ICA-RLS-WT vzhledem k referenčním pozicím R kmitů a výpočet parametrů ACC, SE, PPV a F1.	180
50	Ideální nastavení metody ANFIS pro všechny možné kombinace elektrod u záznamu a07. Stanovené počty TP, FP a FN na základě detekce pozic R kmitů v extrahovaných fEKG signálech pomocí hybridní metody ICA-ANFIS-WT vzhledem k referenčním pozicím R kmitů a výpočet parametrů ACC, SE, PPV a F1.	180
51	Ideální nastavení řádu filtru algoritmu RLS pro všechny možné kombinace elektrod u záznamu a07. Stanovené počty TP, FP a FN na základě detekce pozic R kmitů v extrahovaných fEKG signálech pomocí hybridní metody ICA-RLS-WT vzhledem k referenčním pozicím R kmitů a výpočet parametrů ACC, SE, PPV a F1.	181
52	Ideální nastavení metody ANFIS pro všechny možné kombinace elektrod u záznamu a08. Stanovené počty TP, FP a FN na základě detekce pozic R kmitů v extrahovaných fEKG signálech pomocí hybridní metody ICA-ANFIS-WT vzhledem k referenčním pozicím R kmitů a výpočet parametrů ACC, SE, PPV a F1.	181
53	Ideální nastavení řádu filtru algoritmu RLS pro všechny možné kombinace elektrod u záznamu a08. Stanovené počty TP, FP a FN na základě detekce pozic R kmitů v extrahovaných fEKG signálech pomocí hybridní metody ICA-RLS-WT vzhledem k referenčním pozicím R kmitů a výpočet parametrů ACC, SE, PPV a F1.	181

54	Ideální nastavení metody ANFIS pro všechny možné kombinace elektrod u záznamu a09. Stanovené počty TP, FP a FN na základě detekce pozic R kmitů v extrahovaných fEKG signálech pomocí hybridní metody ICA-ANFIS-WT vzhledem k referenčním pozicím R kmitů a výpočet parametrů ACC, SE, PPV a F1.	182
55	Ideální nastavení řádu filtru algoritmu RLS pro všechny možné kombinace elektrod u záznamu a09. Stanovené počty TP, FP a FN na základě detekce pozic R kmitů v extrahovaných fEKG signálech pomocí hybridní metody ICA-RLS-WT vzhledem k referenčním pozicím R kmitů a výpočet parametrů ACC, SE, PPV a F1.	182
56	Ideální nastavení metody ANFIS pro všechny možné kombinace elektrod u záznamu a10. Stanovené počty TP, FP a FN na základě detekce pozic R kmitů v extrahovaných fEKG signálech pomocí hybridní metody ICA-ANFIS-WT vzhledem k referenčním pozicím R kmitů a výpočet parametrů ACC, SE, PPV a F1.	182
57	Ideální nastavení řádu filtru algoritmu RLS pro všechny možné kombinace elektrod u záznamu a10. Stanovené počty TP, FP a FN na základě detekce pozic R kmitů v extrahovaných fEKG signálech pomocí hybridní metody ICA-RLS-WT vzhledem k referenčním pozicím R kmitů a výpočet parametrů ACC, SE, PPV a F1.	183
58	Ideální nastavení metody ANFIS pro všechny možné kombinace elektrod u záznamu a11. Stanovené počty TP, FP a FN na základě detekce pozic R kmitů v extrahovaných fEKG signálech pomocí hybridní metody ICA-ANFIS-WT vzhledem k referenčním pozicím R kmitů a výpočet parametrů ACC, SE, PPV a F1.	183
59	Ideální nastavení řádu filtru algoritmu RLS pro všechny možné kombinace elektrod u záznamu a11. Stanovené počty TP, FP a FN na základě detekce pozic R kmitů v extrahovaných fEKG signálech pomocí hybridní metody ICA-RLS-WT vzhledem k referenčním pozicím R kmitů a výpočet parametrů ACC, SE, PPV a F1.	183
60	Ideální nastavení metody ANFIS pro všechny možné kombinace elektrod u záznamu a12. Stanovené počty TP, FP a FN na základě detekce pozic R kmitů v extrahovaných fEKG signálech pomocí hybridní metody ICA-ANFIS-WT vzhledem k referenčním pozicím R kmitů a výpočet parametrů ACC, SE, PPV a F1.	184
61	Ideální nastavení řádu filtru algoritmu RLS pro všechny možné kombinace elektrod u záznamu a12. Stanovené počty TP, FP a FN na základě detekce pozic R kmitů v extrahovaných fEKG signálech pomocí hybridní metody ICA-RLS-WT vzhledem k referenčním pozicím R kmitů a výpočet parametrů ACC, SE, PPV a F1.	184

62	Ideální nastavení metody ANFIS pro všechny možné kombinace elektrod u záznamu a13. Stanovené počty TP, FP a FN na základě detekce pozic R kmitů v extrahovaných fEKG signálech pomocí hybridní metody ICA-ANFIS-WT vzhledem k referenčním pozicím R kmitů a výpočet parametrů ACC, SE, PPV a F1.	184
63	Ideální nastavení řádu filtru algoritmu RLS pro všechny možné kombinace elektrod u záznamu a13. Stanovené počty TP, FP a FN na základě detekce pozic R kmitů v extrahovaných fEKG signálech pomocí hybridní metody ICA-RLS-WT vzhledem k referenčním pozicím R kmitů a výpočet parametrů ACC, SE, PPV a F1.	185
64	Ideální nastavení metody ANFIS pro všechny možné kombinace elektrod u záznamu a14. Stanovené počty TP, FP a FN na základě detekce pozic R kmitů v extrahovaných fEKG signálech pomocí hybridní metody ICA-ANFIS-WT vzhledem k referenčním pozicím R kmitů a výpočet parametrů ACC, SE, PPV a F1.	185
65	Ideální nastavení řádu filtru algoritmu RLS pro všechny možné kombinace elektrod u záznamu a14. Stanovené počty TP, FP a FN na základě detekce pozic R kmitů v extrahovaných fEKG signálech pomocí hybridní metody ICA-RLS-WT vzhledem k referenčním pozicím R kmitů a výpočet parametrů ACC, SE, PPV a F1.	185
66	Ideální nastavení metody ANFIS pro všechny možné kombinace elektrod u záznamu a15. Stanovené počty TP, FP a FN na základě detekce pozic R kmitů v extrahovaných fEKG signálech pomocí hybridní metody ICA-ANFIS-WT vzhledem k referenčním pozicím R kmitů a výpočet parametrů ACC, SE, PPV a F1.	186
67	Ideální nastavení řádu filtru algoritmu RLS pro všechny možné kombinace elektrod u záznamu a15. Stanovené počty TP, FP a FN na základě detekce pozic R kmitů v extrahovaných fEKG signálech pomocí hybridní metody ICA-RLS-WT vzhledem k referenčním pozicím R kmitů a výpočet parametrů ACC, SE, PPV a F1.	186
68	Ideální nastavení metody ANFIS pro všechny možné kombinace elektrod u záznamu a16. Stanovené počty TP, FP a FN na základě detekce pozic R kmitů v extrahovaných fEKG signálech pomocí hybridní metody ICA-ANFIS-WT vzhledem k referenčním pozicím R kmitů a výpočet parametrů ACC, SE, PPV a F1.	186
69	Ideální nastavení řádu filtru algoritmu RLS pro všechny možné kombinace elektrod u záznamu a16. Stanovené počty TP, FP a FN na základě detekce pozic R kmitů v extrahovaných fEKG signálech pomocí hybridní metody ICA-RLS-WT vzhledem k referenčním pozicím R kmitů a výpočet parametrů ACC, SE, PPV a F1.	187

70	Ideální nastavení metody ANFIS pro všechny možné kombinace elektrod u záznamu a17. Stanovené počty TP, FP a FN na základě detekce pozic R kmitů v extrahovaných fEKG signálech pomocí hybridní metody ICA-ANFIS-WT vzhledem k referenčním pozicím R kmitů a výpočet parametrů ACC, SE, PPV a F1.	187
71	Ideální nastavení řádu filtru algoritmu RLS pro všechny možné kombinace elektrod u záznamu a17. Stanovené počty TP, FP a FN na základě detekce pozic R kmitů v extrahovaných fEKG signálech pomocí hybridní metody ICA-RLS-WT vzhledem k referenčním pozicím R kmitů a výpočet parametrů ACC, SE, PPV a F1.	187
72	Ideální nastavení metody ANFIS pro všechny možné kombinace elektrod u záznamu a18. Stanovené počty TP, FP a FN na základě detekce pozic R kmitů v extrahovaných fEKG signálech pomocí hybridní metody ICA-ANFIS-WT vzhledem k referenčním pozicím R kmitů a výpočet parametrů ACC, SE, PPV a F1.	188
73	Ideální nastavení řádu filtru algoritmu RLS pro všechny možné kombinace elektrod u záznamu a18. Stanovené počty TP, FP a FN na základě detekce pozic R kmitů v extrahovaných fEKG signálech pomocí hybridní metody ICA-RLS-WT vzhledem k referenčním pozicím R kmitů a výpočet parametrů ACC, SE, PPV a F1.	188
74	Ideální nastavení metody ANFIS pro všechny možné kombinace elektrod u záznamu a19. Stanovené počty TP, FP a FN na základě detekce pozic R kmitů v extrahovaných fEKG signálech pomocí hybridní metody ICA-ANFIS-WT vzhledem k referenčním pozicím R kmitů a výpočet parametrů ACC, SE, PPV a F1.	188
75	Ideální nastavení řádu filtru algoritmu RLS pro všechny možné kombinace elektrod u záznamu a19. Stanovené počty TP, FP a FN na základě detekce pozic R kmitů v extrahovaných fEKG signálech pomocí hybridní metody ICA-RLS-WT vzhledem k referenčním pozicím R kmitů a výpočet parametrů ACC, SE, PPV a F1.	189
76	Ideální nastavení metody ANFIS pro všechny možné kombinace elektrod u záznamu a20. Stanovené počty TP, FP a FN na základě detekce pozic R kmitů v extrahovaných fEKG signálech pomocí hybridní metody ICA-ANFIS-WT vzhledem k referenčním pozicím R kmitů a výpočet parametrů ACC, SE, PPV a F1.	189
77	Ideální nastavení řádu filtru algoritmu RLS pro všechny možné kombinace elektrod u záznamu a20. Stanovené počty TP, FP a FN na základě detekce pozic R kmitů v extrahovaných fEKG signálech pomocí hybridní metody ICA-RLS-WT vzhledem k referenčním pozicím R kmitů a výpočet parametrů ACC, SE, PPV a F1.	189

78	Ideální nastavení metody ANFIS pro všechny možné kombinace elektrod u záznamu a21. Stanovené počty TP, FP a FN na základě detekce pozic R kmitů v extrahovaných fEKG signálech pomocí hybridní metody ICA-ANFIS-WT vzhledem k referenčním pozicím R kmitů a výpočet parametrů ACC, SE, PPV a F1.	190
79	Ideální nastavení řádu filtru algoritmu RLS pro všechny možné kombinace elektrod u záznamu a21. Stanovené počty TP, FP a FN na základě detekce pozic R kmitů v extrahovaných fEKG signálech pomocí hybridní metody ICA-RLS-WT vzhledem k referenčním pozicím R kmitů a výpočet parametrů ACC, SE, PPV a F1.	190
80	Ideální nastavení metody ANFIS pro všechny možné kombinace elektrod u záznamu a22. Stanovené počty TP, FP a FN na základě detekce pozic R kmitů v extrahovaných fEKG signálech pomocí hybridní metody ICA-ANFIS-WT vzhledem k referenčním pozicím R kmitů a výpočet parametrů ACC, SE, PPV a F1.	190
81	Ideální nastavení řádu filtru algoritmu RLS pro všechny možné kombinace elektrod u záznamu a22. Stanovené počty TP, FP a FN na základě detekce pozic R kmitů v extrahovaných fEKG signálech pomocí hybridní metody ICA-RLS-WT vzhledem k referenčním pozicím R kmitů a výpočet parametrů ACC, SE, PPV a F1.	191
82	Ideální nastavení metody ANFIS pro všechny možné kombinace elektrod u záznamu a23. Stanovené počty TP, FP a FN na základě detekce pozic R kmitů v extrahovaných fEKG signálech pomocí hybridní metody ICA-ANFIS-WT vzhledem k referenčním pozicím R kmitů a výpočet parametrů ACC, SE, PPV a F1.	191
83	Ideální nastavení řádu filtru algoritmu RLS pro všechny možné kombinace elektrod u záznamu a23. Stanovené počty TP, FP a FN na základě detekce pozic R kmitů v extrahovaných fEKG signálech pomocí hybridní metody ICA-RLS-WT vzhledem k referenčním pozicím R kmitů a výpočet parametrů ACC, SE, PPV a F1.	191
84	Ideální nastavení metody ANFIS pro všechny možné kombinace elektrod u záznamu a24. Stanovené počty TP, FP a FN na základě detekce pozic R kmitů v extrahovaných fEKG signálech pomocí hybridní metody ICA-ANFIS-WT vzhledem k referenčním pozicím R kmitů a výpočet parametrů ACC, SE, PPV a F1.	192
85	Ideální nastavení řádu filtru algoritmu RLS pro všechny možné kombinace elektrod u záznamu a24. Stanovené počty TP, FP a FN na základě detekce pozic R kmitů v extrahovaných fEKG signálech pomocí hybridní metody ICA-RLS-WT vzhledem k referenčním pozicím R kmitů a výpočet parametrů ACC, SE, PPV a F1.	192

86	Ideální nastavení metody ANFIS pro všechny možné kombinace elektrod u záznamu a25. Stanovené počty TP, FP a FN na základě detekce pozic R kmitů v extrahovaných fEKG signálech pomocí hybridní metody ICA-ANFIS-WT vzhledem k referenčním pozicím R kmitů a výpočet parametrů ACC, SE, PPV a F1.	192
87	Ideální nastavení řádu filtru algoritmu RLS pro všechny možné kombinace elektrod u záznamu a25. Stanovené počty TP, FP a FN na základě detekce pozic R kmitů v extrahovaných fEKG signálech pomocí hybridní metody ICA-RLS-WT vzhledem k referenčním pozicím R kmitů a výpočet parametrů ACC, SE, PPV a F1.	193

1 Úvod

Fetální elektrokardiografie (fEKG) je velice slibnou diagnostickou metodou monitorování stavu plodu. První pokusy o kontinuální monitorování fetální tepové frekvence (fHR) pomocí fEKG byly provedeny v roce 1953 [1]. Prakticky zároveň s vývojem fEKG bylo zavedeno elektrické monitorování stavu plodu pomocí kardiokografie (KTG), která umožňuje kontinuální monitorování fHR a děložních kontrakcí [2]. V následujících letech se KTG ukázala jako velice slibná diagnostická metoda a v roce 1968 byl do klinické praxe zaveden první komerčně dostupný model Hewlett-Packard 8020A. Tím došlo znatelně k poklesu počtu úmrtí plodu během porodu. Následně v 70. a 80. letech 20. století došlo k navýšení počtu provedených císařských řezů, což bylo právě přisuzováno KTG [3, 4, 5]. Tento jev lze přičíst tomu, že první KTG modely byly nespolehlivé a bylo složité vyhodnocovat naměřená data. Kromě KTG byl nárůst císařských řezů ovšem také přisuzován novým porodnickým metodologiím zavedeným na konci 70. let 20. století [6].

V roce 2007 bylo vyvinuto švédskou společností Neoventa Medical zařízení ST analyzátor S31, které umožňuje přesnější monitorování stavu plodu pomocí fEKG signálů naměřených pomocí transvaginální fetální skalp elektrody (FSE) [7]. Toto zařízení je schopné monitorovat krátkodobou variabilitu fHR (fHRV) spolu s automatickou analýzou ST segmentu, což výrazně zlepšuje možnost identifikace fetální hypoxie. Nicméně toto zařízení je možné použít pouze během porodu a nese s sebou negativní šanci na zanesení infekce do těla plodu a matky.

V dnešní době se jeví neinvazivní fEKG (NI-fEKG) jako nejslibnější alternativní diagnostickou metodou ke konvenčnímu KTG. Signál fEKG je nositelem důležitých informací o patologiích projevujících se v morfologii fEKG signálu. Navíc v porovnání s KTG se jedná o pasivní metodu, kdy nejsou matka a plod vystaveny žádnému záření. Signál naměřený v břišní oblasti těhotné ženy při NI-fEKG se nazývá abdominální EKG (aEKG). Tento signál je potřeba nejdříve zpracovat do správné formy, protože obsahuje primárně signál mateřského EKG (mEKG), poté fEKG signál a šum. Kvalitní extrakce fEKG signálu je tudíž největší výzvou pro efektivní monitorování stavu plodu.

V současné době se řada autorů po celém světě snaží otestovat stávající metody a vyvinout nové metody sloužící ke zpracování neinvazivně naměřených aEKG signálů. Metody zpracování signálu lze v základní formě rozdělit na adaptivní a neadaptivní metody. Řada metod dosáhla slibných výsledků, ale většinou na simulovaných záznamech nebo záznamech neměřených u těhotných žen těsně před porodem. V reálných aplikacích, kde by bylo možné zpracovat fEKG signál u těhotných žen v nižším týdnu těhotenství, je potřeba využít pokročilejších metod zpracování fEKG signálu. Tyto metody jsou nejčastěji vytvořeny kombinováním adaptivních a neadaptivních metod za účelem vytvoření hybridní metody.

Motivací pro tuto doktorskou disertační práci je vyvinutí nové metody, která by byla schopna extrahovat fEKG signál v takové formě, že by v budoucnu bylo možné monitorovat fHR a provádět morfologickou analýzu fEKG signálu (ST segment analýzu, QT segment analýzu, a podobně).

Pomocí provedené morfologické analýze by bylo možné zamezit falešně pozitivní diagnostice fetální hypoxie, což by vedlo ke snížení počtu operativně ukončených těhotenství z důvodu domnělé hypoxie plodu určené na základě stanovení fHR. Vyvinutá metoda by mohla přispět k možnosti vytvoření zcela nové neinvazivní diagnostické metody, která bude kombinovat stanovení fHR a provedení hlubší morfologické analýzy. Tato diagnostická metoda by mohla v budoucnu nahradit klasický ST segment analyzátor s přínosem zachování neinvazivity vyšetření.

Kapitola 2 se věnuje shrnutím současných technik monitorování stavu plodu během těhotenství. Největší důraz je kladen na popis měření a zpracování fEKG signálu, protože zpracování fEKG signálu je hlavní součástí této práce.

Primárním cílem této doktorské disertační práce je prostudování problematiky extrahování fEKG signálu pomocí neadaptivních metod, které využívají jako vstup pouze aEKG signály. Popřípadě nastudování využití tzv. hybridních metod extrakce fEKG signálu, které využívají kombinování výhod adaptivních a neadaptivních metod. Takové metody poté využívají pouze břišní elektrody jako vstup do svých systémů, ale navíc mohou využívat ve své hlavní části systémy učení. Důvodem zaměření se na využití pouze břišních elektrod je snaha zvýšit komfort a pohodlí během monitorování plodu. Toho lze dosáhnout právě využitím pouze břišních elektrod bez zbytečných elektrod přiložených na hrudi těhotné ženy. Břišní elektrody je možné v budoucnu implantovat například do speciálního pásu, ve kterém by byly zabudovány elektrody spolu se zařízením založeným na bateriovém provozu. Kapitola 3 tedy obsahuje popis a srovnání jednotlivých metod využívaných autory po celém světě. Rozdělení této kapitoly je na jednákanálové neadaptivní metody, vícekanálové neadaptivní metody a na hybridní metody využívající neadaptivní metody k odhadnutí mEKG signálu.

V následující kapitole 4 jsou na základě provedené literární rešerše stanoveny cíle doktorské disertační práce. Na základě prostudování problematiky (provedení hloubkové rešerše) a již provedených sérií experimentů pomocí různých adaptivních a neadaptivních metod, je proveden výběr vhodných metod pro kombinování za účelem vytvoření sofistikovaných hybridních metod schopných v rámci možností extrahovat přesný fEKG signál. Řada autorů testovala své metody pouze pomocí syntetických dat, kde dosáhli velice dobrých výsledků. Nicméně tyto metody při následném testování na reálných záznamech nebyly schopné extrahovat dostatečně kvalitní fEKG signál, proto nebylo možné tyto metody použít v reálných aplikacích. Zvolené a navržené hybridní metody v této práci, proto jsou verifikovány pouze na reálných datech z klinické praxe, které se nejčastěji využívají v jiných publikacích, aby bylo možné v budoucnu porovnat dosažené výsledky. Použití reálných dat z více databází je stanoveno jako jeden z hlavních cílů této doktorské disertační práce.

Na základě zvolených metod obsahuje kapitola 5 matematický popis a rozbor jednotlivých metod. Dále tato kapitola poskytuje popis již zmíněných databází reálných dat. Poslední část této kapitoly se zaměřuje na popis zvolených hodnotících parametrů. Kvalitní objektivní hodnocení úspěšnosti extrakce fEKG signálu je velice důležité. Autoři ve svých publikacích využívají rozdílné hodnocení přesnosti extrakce fEKG signálu a v některých případech nedostatečné hod-

nocení. Proto v této doktorské disertační práci je jeden z cílů zaměřen na provedení kvalitního hodnocení, které správně a objektivně posoudí přesnost extrakce fEKG signálu a přesnost stanovení fHR.

Hlavním výstupem této doktorské disertační práce by mělo být vytvoření modulární softwarové aplikace, proto se kapitola 6 zabývá popisem vytvořeného programu. V této kapitole jsou rozebrány jednotlivé části softwarové aplikace, možnost nastavení parametrů jednotlivých metod a příprava fEKG signálu po extrakci k provedení objektivního hodnocení.

Experiment provedený pomocí navržených hybridních metod zpracování fEKG signálu na zvolených reálných záznamech je proveden v kapitole 7. Kapitola se rozděluje na více částí na základě zvolených databází. Jednotlivé části obsahují objektivní hodnocení extrakcí fEKG signálů a dosažené výsledky experimentů provedených na dané databázi.

Kapitola 8 rozebírá dosažené výsledky formou diskuze. V této kapitole jsou zhodnoceny zjištěné poznatky během testování. Je zde proveden rozbor určitých částí vybraných extrakcí fEKG signálů a stanovených křivek fHR. Kapitola 9 následně shrnuje dosažené výsledky a je proveden závěr této doktorské disertační práce. Přílohy obsahují výsledky experimentů, které nebyly představeny v experimentální části.

2 Techniky monitorování plodu

Monitorování plodu během průběhu těhotenství je velice důležité pro zjištění mnoha faktorů, které mohou negativně ovlivnit zdraví plodu, mohou zabránit nitroděložnímu úmrtí nebo trvalému poškození plodu [8, 9]. Tyto faktory nemusejí být nebezpečné pouze pro zdraví plodu, ale také pro zdraví matky. Některé problémy, jako je například předčasný porod, hypoxie nebo intrauterinní retardace, jsou právě nebezpečné pro plod i pro matku. Monitorování plodu zahrnuje metody jako je fEKG [RJ1, RJ3, RJ5, RJ6, 8, 9, 10, 11, 12, 13, 14], fetální fonokardiografie (fFKG) [RJ7, RJ8, RJ9, RJ10, RJ11, RJ12, RJ13, 15, 16, 17, 18], fetální echokardiografie (fECHO) [19, 20, 21], fetální magnetokardiografie (fMKG) [22, 23, 24] a KTG [12, 25, 26, 27].

2.1 Fetální echokardiografie

Fetální ECHO, viz obrázek 1 [28], je nejinformativnější neinvazivní metoda poskytující spolehlivé údaje o morfologii srdce (včetně odchylek a rychlosti průtoku krve) a využívá se k diagnostice vrozených srdečních vývojových vad. Tato metoda je také známá jako sonografie srdce, je založena na Dopplerově ultrazvuku a používá se k monitorování stavu plodu od 18. týdne těhotenství. Nevýhodou fECHO je, že pro získání a vyhodnocení údajů je zapotřebí dobře kvalifikovaných odborníků. Další nevýhodou je, že není možné provést dlouhodobé snímání fHR [16, 19, 20, 21].



Obrázek 1: Ukázka fetální echokardiografie.

2.2 Fetální magnetokardiografie

Během srdeční činnosti vzniká díky magnetické indukci velmi malé magnetické pole, které lze zaznamenávat pomocí citlivých biomagnetometrů, což jsou supravodivé kvantové interferenční zařízení (SQUID). Fetální MKG, viz obrázek 2 [29], tedy snímá magnetickou aktivitu fetálního

srdce. Výhodou této metody je, že umožňuje monitorování stavu plodu od 20. týdne těhotenství a velmi přesné stanovení fHR. Signály získané pomocí fMKG mají v porovnání s fEKG větší hodnotu odstupů signálu od šumu (SNR), což umožňuje provedení morfologické analýzy (ST segment analýzy, QT segment analýzy, a podobně). Navíc fMKG obsahuje více informací než fECHO, protože většina srdečních abnormalit má nějaký projev na morfologii fMKG signálu [9, 16]. Nicméně přístroje pro záznam fMKG jsou složitější (vyžadují dobře vyškolený personál) a v současné době méně dostupné. Vybavení potřebné k provedení fMKG je příliš nákladné, proto neumožňuje nahrání dlouhodobých záznamů a není v klasických nemocnicích dostupné [22, 23, 24, 30].



Obrázek 2: Ukázka fetální magnetokardiografie.

2.3 Kardiotokografie

Kardiotokografie je v současnosti nejčastěji používanou a zároveň nejdůležitější metodou elektrického monitorování stavu plodu (zvláště během porodu). Zjištění stavu plodu pomocí KTG se v případě normálního průběhu těhotenství provádí pravidelně ve třetím trimestru a během porodu. Nicméně v případě potřeby je možné provést vyšetření pomocí KTG od 20. týdne těhotenství. Tato metoda umožňuje kontinuální sledování fHR pomocí ultrazvukového měniče umístěného v břišní oblasti gravidní ženy a sledování děložních kontrakcí pomocí tlakově citlivého převodníku. Tyto dva snímače jsou připevněny pomocí dvou elastických páسů v břišní oblasti gravidní ženy, viz obrázek 3 [31]. Princip je založen na Dopplerovském principu detekce pohybu srdeční stěny pomocí změny frekvence odraženého ultrazvukového paprsku. Průběh fHR je po provedení vyšetření zobrazen na 20 minutovém záznamu nazývaném kardiointervalogram. Na kardiointervalogramu se pozoruje hlavně zrychlení fHR, fluktuace (nepravidelné změny) a základní linie. Výsledné specifické parametry získané touto již klasickou metodou jsou vyhodnocovány vizuálně, proto jejich přesnost silně závisí na odborných znalostech pozorovatele.

Kardiotokografie poskytuje informace pouze o pohybu vnějšího povrchu srdce, proto neposkytuje informace o činnosti cév, turbulencích, a podobně [16]. Velkou nevýhodou KTG je provedení průměrování během stanovení fHR. Tím se ztrácí informace o krátkodobých změnách fHR mezi jednotlivými srdečními tepy z důvodu provedené aproximace skutečné křivky fHR. Sice nebyl nikdy zjištěn přesný dopad přenosu energie pomocí Dopplerovského ultrazvuku na plod,

ale ultrazvuková vlna s frekvencí 2 MHz a intenzitou okolo 10 mW/cm² je pro plod s určitostí nežádoucí a může vyvolat negativní následky [18, 32]. Další nevýhodou KTG je potřeba dobře školeného personálu při rozmístění snímačů a snížení mobility těhotné ženy z důvodu připojených elastických pásů. Kvalitu monitorování stavu plodu pomocí KTG dále snižuje pohyb matky a plodu během vyšetření a také vyšší index tělesné hmotnosti (BMI) matky. V některých případech dochází během monitorování pomocí KTG k zaznamenání mateřské tepové frekvence (mHR) místo fHR. Všechny tyto nevýhody a problémy KTG zvyšují počet operativně ukončených těhotenství z důvodu domnělé hypoxie plodu. Možnou nevýhodou KTG je, že se provádí v klinických laboratořích funkční diagnostiky, které mohou být pro mnoho těhotných žen nepřístupné a mohou vyžadovat hospitalizaci [12, 25, 26, 27].



Obrázek 3: Ukázka kardiokografie.

2.3.1 Fetální tepová frekvence

V současné době je kontinuální monitorování stavu plodu zaměřeno převážně na monitorování fHR. Během monitorování se zaměřuje na sledování základní linie fHR, variability fHR, zrychlení fHR, zpomalení fHR a kontrakce dělohy [25, 33, 34, 35].

1. Základní linie fHR se stanoví z průměrné hodnoty fHR za posledních 10 minut zaokrouhlené na nejbližších 5 tepů za minutu (bpm). Minimální délka základní linie pro hodnocení musí být aspoň 2 minuty. Rozděluje se na:
 - Normální hodnota fHR (normokardie) – pohybuje se v rozmezí 110 až 160 bpm.
 - Zvýšená hodnota fHR (tachykardie) – značí hodnoty fHR vyšší než 160 bpm a trvající déle než 10 min.
 - Snížená hodnota fHR (bradykardie) – značí hodnoty fHR nižší než 110 bpm a trvající déle než 10 min [33, 34].

2. Variabilita fHR je dána jako změna (kolísání) hodnoty fHR v čase. Krátkodobá fHRV popisuje malé změny fHR mezi jednotlivými R kmity. Změny fHR se opakují ve směru a velikosti, což vytváří určité oscilace fHR okolo střední hodnoty. Tyto oscilace se nazývají dlouhodobá fHRV, která vlivem malých výchylek zakrývá krátkodobou fHRV. Z tohoto důvodu se v praxi využívá pouze obecný termín fHRV, který značí dlouhodobou fHRV. Variabilita fHR je velmi důležitá pro hodnocení KTG, protože značí schopnost centrální nervové soustavy řídit kardiovaskulární systém. Dělí se na základě amplitudy na:
- Vynechaná fHRV – křivka fHR je prakticky rovná čára, což jasně poukazuje na patologický jev [36].
 - Minimální fHRV – rozsah amplitudy je menší než 5 bpm po dobu delší než 50 min u segmentů základní linie nebo po dobu delší než 3 min během zpomalení. Minimální fHRV může značit špatnou schopnost plodu reagovat na změny oběhu.
 - Normální fHRV – rozsah amplitudy je v rozmezí 5 až 25 bpm.
 - Zvýšená fHRV – rozsah amplitudy je větší než 25 bpm po dobu delší než 30 min.
 - Sinusová fHRV – jedná se o zvláštní typ fHRV, kdy amplituda sinusového průběhu se pohybuje v rozmezí 5 až 15 bpm a frekvence je 3 až 5 cyklů za minutu. Tento průběh trvá obvykle déle než 30 min bez rychlení fHR a může značit závažný stav vyžadující okamžitý zásah [37].
 - Pseudosinusová fHRV – tato fHRV je podobná sinusové, ale má spíše pilovitý průběh, než hladký jako je u sinusové fHRV. Velmi často je obtížné ji odlišit od sinusové fHRV. Délka trvání je více než 30 min [33, 34].
3. Zrychlení fHR značí rychlé zvýšení fHR (od začátku zvýšení po vrchol za méně než 30 s) o více než 15 bpm po dobu delší než 15 s a kratší než 10 min. Doba trvání zrychlení fHR se počítá od začátku zvyšování fHR do návratu fHR do normálního stavu. Fyziologicky zrychlení fHR trvá maximálně 10 min a je spojeno s pohyby plodu, které jsou během těhotenství běžné a neznačí hypoxii [33, 34].
4. Zpomalení fHR značí snížení fHR o více než 15 bpm po dobu delší než 15 s. Zpomalení fHR se dělí na:
- Epizodní zpomalení fHR – není spojeno s děložními kontrakcemi.
 - Periodické zpomalení fHR – je spojeno s děložními kontrakcemi.
 - Předčasné zpomalení fHR – trvá déle než 30 s a nejnižší hodnota fHR je spojená s vrcholem děložní kontrakce.
 - Pozdní zpomalení fHR – trvá déle než 30 s a nejnižší hodnota fHR je až po vrcholu děložní kontrakce.
 - Proměnné zpomalení fHR – projevuje se snížením fHR o více než 15 bpm za dobu kratší než 30 s a dobou trvání od 15 s do 2 min.
 - Opakované zpomalení fHR – zpomalení fHR se projevuje u 50 % děložních kontrakcí v 20 min záznamu.

– Prodloužené zpomalení fHR – značí snížení fHR o více než 15 bpm po dobu delší než 2 min a kratší než 10 min [33, 34].

5. Maximální počet děložních kontrakcí, které se fyziologicky opakují v 10 min okně zprůměrovaném z 30 min záznamu, je 5. Větší počet děložních kontrakcí značí tachysystolu [33, 34].

2.3.2 FIGO klasifikace

Klinické doporučení na hodnocení KTG a stanovených parametrů jsou dána podle FIGO klasifikace. Tato klasifikace je v České republice navíc uzákoněna. Aby bylo možné aplikovat FIGO klasifikaci, je nutné provést předešlé hodnocení základních funkcí KTG. Vyhodnocení je následně podle kritérií uvedených v tabulce 1 rozděleno do základních tříd [25, 33, 34, 35]:

- Fyziologické (normální).
- Suspektní (intermediární, podezřelé).
- Patologické (Abnormální).
- Preterminální.

Tabulka 1: Hodnocení KTG podle klasifikace FIGO.

Klasifikace	Základní linie	Variabilita	Zpomalení	Interpretace
Fyziologické	110 až 160 bpm	5 až 25 bpm	Bez opakovaného zpomalení	Plod bez hypoxie/acidózy
Suspektní	100 až 110 bpm, nebo 160 až 170 bpm	Pod 5 bpm po dobu delší než 40 min, nebo nad 25 bpm bez zrychlení	Proměnné zpomalení, o méně než 60 bpm po dobu kratší než 60 s	Plod má nízkou pravděpodobnost výskytu hypoxie/acidózy
Patologické	Pod 100 bpm	Pod 5 bpm po dobu delší než 60 min, nebo zrychlená, sinusová, či pseudosinusová variabilita po dobu delší než 30 min	Opakované pozdní, nebo prodloužené zpomalení o více než 50 bpm po dobu delší než 30 min	Plod má vysokou pravděpodobnost výskytu hypoxie/acidózy
Preterminální	Výnechaná variabilita, bez reaktivity (tzn. bez zvýšení základní linie o 15 bpm po dobu delší než 15 s, které se opakují dvakrát v 20 min), s nebo bez zpomalení a bradykardie, vyžaduje okamžitý zásah			

Z důvodu měnící se povahy KTG během porodu, je nutné provedení opakované klasifikace během každých 30 min. Někteří autoři ve svých pracích uvádějí, že je lepší využít jiných klasifikačních systému s více úrovněmi [38, 39].

2.4 Fetální fonokardiografie

Fetální FKG je diagnostická metoda sloužící k zaznamenání fetálních srdečních zvuků (fHS). Skládá se z akvizice, analýzy a zpracování fHS naměřených z povrchu těla gravidní ženy. Naměřené fHS mohou poskytnout kritické informace o některých srdečních selháních a vrozených srdečních onemocněních [40]. Velkou výhodou fFKG je také, že poskytuje informace o rozštěpeních,

extra systolách, šelestech, bigeminálních a trigeminálních atriálních kontrakcích, intrauterinních růstových retardacích, a dalších abnormalitách srdeční funkce [41]. Tato metoda je zcela pasivní, nízkonákladová a je velmi vhodným alternativním diagnostickým nástrojem pro stanovení fHR a popřípadě mHR. V podstatě je fFKG moderní forma auskultace, která je jednou z nejstarších medicínských nástrojů v historii [32]. Měření fFKG se provádí pomocí akustického senzoru (mikrofonního snímače), což je typicky snímač tlaku s frekvenčním pásmem 0,1 až 200 Hz, se zesilovačem s vysokým zesílením a s antialiasingovým filtrem [42]. Jedná se o přeměnu fHS (projevujících se jako vibrace) pomocí piezoelektrického krystalového mikrofonu na měnící se elektrický signál podle tlaku vyvolaného zvukovými vlnami [9]. Bylo zjištěno, že nejlepší signál lze zaznamenat tam, kde jsou záda plodu v kontaktu s mateřským břichem. Naopak horší signál je získán v případě, kdy je zvuk srdce tlumen amniotickou tekutinou, a tudíž prochází delší cestou k povrchu mateřského břicha [16]. Obrázek 4 zobrazuje ukázkou zařízení pro snímání fFKG, které bylo vytvořeno na fakultě elektrotechniky a informatiky na Vysoké škole báňské – Technické univerzitě Ostrava.



Obrázek 4: Zařízení pro měření fetální fonokardiografie.

U dospělého člověka i u plodu rozlišujeme 4 srdeční zvuky, ale třetí a čtvrtý jsou prakticky nedetekovatelné [16]. První srdeční zvuk (S1) je generován uzavřením mitrálních a trikuspidálních chlopní během systoly. Druhý srdeční zvuk (S2) je následně generován uzavřením aortálních a plicních chlopní během diastoly. Obecně platí, že S1 má větší amplitudu, nižší frekvenci a delší dobu trvání než S2. Mateřské srdeční zvuky (mHS) a fHS jsou oba periodické úzkopásmové nestacionární signály, kdy fHS leží v pásmu od 20 do 110 Hz a mHS leží v pásmu od 10 do 40 Hz [15].

V současné době se fFKG používá hlavně jako sekundární diagnostický nástroj, protože naměřené signály pomocí fFKG obsahují velké množství šumu z důvodu polohy plodu, pohybů plodu a matky, dýchání plodu, škytavkou a také kontrakcemi dělohy. Tvar získaných signálů je velmi závislý na umístění sběru dat, týdnu těhotenství, poloze plodu a na nelineárním přenosovém

médiu, které transformuje složky na úzkopásmové signály [43]. Velkou výhodou fFKG je možnost stanovení a monitorování vícečetného těhotenství [32]. Další velkou výhodou fFKG je, že má potenciál být levnou monitorovací metodou plodu do domácího prostředí, například ve spolupráci s mobilním telefonem. Tato technika také umožňuje vytvoření prototypu 24 hodinové monitorování funkčního stavu plodu a mateřského kardiovaskulárního systému při těhotenství [44, 45]. Na základě těchto výhod, lze sestavit pasivní, neškodný diagnostický nástroj s nízkou cenou sloužící k sledování fHR [44].

2.5 Fetální elektrokardiografie

Fetální EKG je diagnostická metoda zaznamenávající elektrickou aktivitu srdce plodu. Signály získané při měření neinvazivního fEKG pomocí elektrod umístěných v břišní oblasti gravidní ženy (aEKG signály) obsahují primárně mEKG signál, dále fEKG signál s několikanásobně menší amplitudou a šum. Tyto signály jsou označovány jako aEKG signály. Rovnice (1) zobrazuje složení vstupního aEKG signálu, kde n značí počet vzorků jednotlivých vektorů [RJ1, RJ2, RJ3, RJ4, RJ5].

$$\overrightarrow{aEKG}(n) = \overrightarrow{fEKG}(n) + \overrightarrow{mEKG}(n) + \overrightarrow{\text{šum}}(n). \quad (1)$$


Tato metoda umožňuje stanovení arytmií srdce, ischemie a dalších srdečních abnormalit [9]. Měření fEKG se provádí buď invazivně pomocí FSE, nebo neinvazivně pomocí elektrod umístěným v různých břišních oblastech gravidní ženy. Invazivní přístup poskytuje velice kvalitní fEKG signál díky přímému kontaktu elektrody s plodem, ale zároveň s sebou nese řadu nevýhod. Největším problémem je riziko zanesení infekce do těla matky nebo plodu [8]. Při nedostatečném kontaktu elektrody s plodem dochází k nekvalitnímu přenosu signálu a také dochází ke kolísání izolinie. Naopak neinvazivní přístup není pro matku ani plod zatěžující a může být použit i během porodu. Nicméně neinvazivně naměřený signál je potřeba správně zpracovat pro získání vhodné formy fEKG signálu, protože je primárně kontaminován mateřskou komponentou a také šumem. Mezi základní formy takového šumu patří biologické artefakty (pohyby matky a plodu, dýchání matky a plodu, svalová aktivita matky a plodu, děložní kontrakce, a podobně) a také technické artefakty (elektrostatické potenciály, síťový brum, a podobně). Hodnota SNR je velice ovlivněna vlivem umístění elektrod v břišní oblasti těhotné ženy, polohou plodu, ale také týdnem těhotenství [RJ3, 8].

V celém myokardu jsou rozložena nervová vlákna, která řídí pravidelné kontrakce a relaxace srdce, a tudíž pravidelné srdeční vlny. Začátek stimulace myokardu je v pravé horní zadní části pravé síně, kde se nachází sinoatriální uzel, který zastává funkci přirozeného kardiostimulátoru. Tento uzel obsahuje velký shluk buněk, které inicializují každý srdeční tep a stimulují atrioventrikulární uzel nacházející se v dolní zadní části pravé síně. Impuls se následně šíří přes atrioventrikulární uzel do Hisova svazku umístěném v oblasti mezikomorového septa a dělicím se na dvě Tawarova raménka. Tato raménka se na svém konci vybíhají v drobnější zakončení

nazývaná Purkyňova vlákna, kde se rozvádí podráždění po celé komorové svalovině, a tudíž je celá svalovina depolarizována. Ve směru od sinoatriálního uzlu k Purkyňovým vláknům se zmenšuje rychlost přenosu podráždění. Po celém tomto kroku nastává okamžik repolarizace, kdy je srdce ochablé a čeká na další stimul vyvolaný sinoatriálním uzlem, aby se celý cyklus mohl opakovat [9].


Na výsledném EKG lze pozorovat jednotlivé vlny a kmity. Na začátku EKG lze vidět P vlnu, která znázorňuje začátek srdeční aktivity a zároveň znázorňuje depolarizaci síní. Mezi P vlnou a následným začátkem QRS komplexu je přibližně 50 ms prodleva, která znázorňuje šíření impulzu ze sinoatriálního uzlu do atrioventrikulárního uzlu. Po prodlevě začíná QRS komplex, který je odrazem depolarizace obou komor a současné repolarizace síní. Za QRS komplexem se vyskytuje T vlna, která v EKG znázorňuje repolarizaci komor. V některých případech za T vlnou následuje ještě vlna U, která u běžného EKG vyznačuje repolarizaci Hisova svazku a Purkyňových vláken. Po skončení vlny U následuje krátký úsek nazývaný izoelektrická linie, při kterém myokard neprovádí elektrickou aktivitu až do následného impulzu (vyvolaný sinoatriálním uzlem) [9].

V současné době je hlavním cílem fEKG stanovení fHR. Z důvodu odlišné polohy plodu (polohy srdce plodu) není rozmístění elektrod v břišní oblasti těhotné ženy standardizováno, proto je automatické stanovení fHR velkým problémem. Obrázek 5 zobrazuje ukázkou rozmístění elektrod v břišní oblasti matky pro naměření aEKG signálů [10]. Nejdůležitějším krokem je správné odstranění šumu, a hlavně mateřské komponenty (mEKG signálu). Obvykle se hodnota fHR mezi dvěma R kmity pohybuje okolo 110 až 160 bpm a hodnota mHR mezi dvěma R kmity okolo 60 až 100 bpm [RJ5]. Přestože neexistuje žádné přímé spojení mezi matkou a plodem, tak hormony a placenta mohou velice ovlivnit hodnotu fHR. Amplituda u fEKG signálu a mEKG signálu se také velice liší, kdy amplituda mEKG signálu je několikanásobně větší než amplituda fEKG signálu [8].

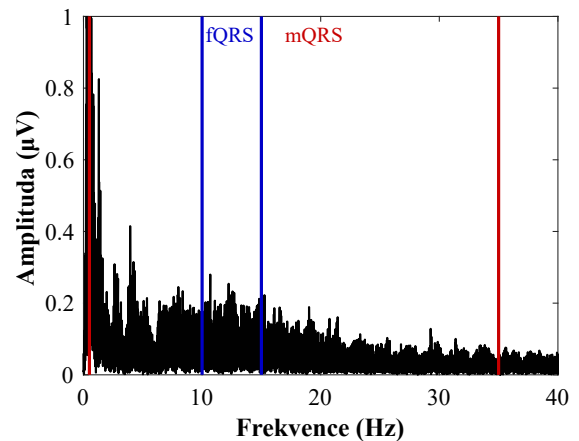


Obrázek 5: Ukázkou rozmístění elektrod při fetální elektrokardiografii. Červené elektrody jsou aktivní elektrody, bílé elektrody jsou referenční elektrody a GND představuje zemní elektrody.

Velice často dochází v jednom místě k překrytí QRS komplexu matky (mQRS) a QRS komplexu plodu (fQRS). Protože je amplituda mEKG signálu větší, tak je velice obtížné určit, zda v daném místě překrytí proběhl tep plodu. Překrytí QRS komplexů lze sledovat z průběhů na obrázku 6a, kde horní signál je referenční ideální fEKG signál naměřený pomocí FSE a dolní signál je aEKG signál naměřený břišní elektrodou v břišní oblasti matky. Na tomto obrázku jsou písmenem *f* označeny fQRS komplexy a písmenem *m* jsou označeny mQRS komplexy. Překrytí QRS komplexů lze pozorovat také na obrázku 6b, který zobrazuje spektrum aEKG signálu z obrázku 6a. Lze vidět, že frekvenční oblast fQRS komplexů, které leží přibližně v oblasti 10 až 15 Hz (označeno modrou barvou), se překrývá s frekvenční oblastí mQRS komplexů, které leží přibližně v oblasti 0,5 až 35 Hz (označeno červenou barvou). Z toho plyne, že pro extrakci fEKG signálu nelze použít pouze obyčejnou filtraci určitého pásma. Hodnoty frekvenčních pásem fQRS komplexů a mQRS komplexů byly získány ze studie Sameni a kol. v roce 2010 [9]. Obrázek 6 byl vytvořen na reálném záznamu r01 z databáze abdominálního a přímého fEKG (ADFECGDB) [13, 46, 47, 48, 49], která obsahuje 5 pětikanálových záznamů (4 aEKG signály a 1 čistý fEKG signál naměřený pomocí FSE) od různých těhotných žen v 38. až 41. týdnu těhotenství, dlouhých 5 min, se vzorkovací frekvencí 1 kHz a s rozlišením 16 bitů.



(a) Naměřený fEKG signál pomocí FSE (horní signál) a naměřený aEKG signál břišní elektrodou (dolní signál).



(b) Spektrum naměřeného aEKG signálu s vyznačenými pásmy fQRS komplexů (modře) a mQRS komplexů (červeně).

Obrázek 6: Ukázka naměřených reálných signálů z databáze ADFECGDB.

Následující obrázek 7 [50, 51, 52] zobrazuje hlavní komerčně dostupná zařízení pro měření NI-fEKG od tří různých společností: zařízení Monica (nový wireless patch system), zařízení Mindchild (meridian M110 fetal monitoring system), a zařízení Nemo (nemo fetal monitoring system). Nedávný nárůst počtu nových sofistikovaných zařízení pro měření NI-fEKG potvrzuje, že postupně dochází k nahrazení konvenčně používaného KTG zařízeními pro měření NI-fEKG.



(a) Nový wireless patch system.



(b) Meridian M110 fetal monitoring system.



(c) Nemo fetal monitoring system.

Obrázek 7: Komerčně dostupná zařízení pro měření NI-fEKG.

Velkou perspektivu pro monitorování plodu má ST analýza získaného fEKG signálu. Tato analýza byla vytvořena za účelem poskytnutí objektivní informace o stavu plodu v návaznosti na monitorování fHR. Repolarizace buněk myokardu je velice citlivá na metabolickou disfunkci vyvolanou hypoxií, která se projeví v EKG změnou tvaru vln jako je nárůst ST segmentu a T vlny. Proto ST analýza sleduje schopnost myokardu reagovat na hypoxii, při které dochází k vzestupu ST segmentu a T vlny. Změna poměru ST analýzy je považována za změnu buněčných iontových proudů během anaerobního metabolismu srdce [9]. Vzestup vlny T je obecně známkou, že se myokard plodu snaží adaptovat na hypoxii. Pokud se nadále prohlubuje hypoxie, dojde k stále většímu vzestupu T vlny, až nakonec nastane velký pokles T vlny, čímž vzniká velké riziko akutního kardiovaskulárního selhání. Kombinovaným monitorováním fHR a ST analýzy dochází k snížení nesprávných případů předčasného ukončení těhotenství. Bylo dokázáno, že použitím ST analýzy dochází k včasné identifikaci případů, kdy během porodu dochází k acidóze, což je pokles koncentrace standardních hydrogenuhličitanů pod referenční hodnoty. Nevýhodou ST analýzy je její invazivnost a možnost použití pouze během porodu, protože v současnosti není možné provést přesnou ST analýzu na jiných signálech než na signálech pořízených pomocí FSE připojené k plodu během porodu po prasknutí membrány s plodovou vodou. Další nevýhodou je, že ST analýza umožňuje zobrazení pouze jednorozměrného záznamu, a proto je tato technika značně ovlivněna šumem a je zaměřena pouze na problémy, které ovlivňují srdce jako celek. Problémy, které ovlivňují jinou část srdce nebudou tudíž zjištěny. Rovnice (2) ukazuje výpočet tohoto důležitého parametru pro sledování stavu plodu, kde T je velikost amplitudy T vlny a QRS je velikost QRS komplexu [11]. Poměr vyšší než 0,1 značí projev adaptace myokardu na hypoxický stav. Poté záleží, zda se tento poměr upraví do 10 min, nebo se nadále zvyšuje a hypoxie přetrvává. Na obrázku 8 lze vidět klasické zařízení S31 pro ST analýzu [35, 53].


$$ST_{\text{analýza}} = \frac{T}{QRS}. \quad (2)$$



Obrázek 8: ST analyzátor S31.

2.6 Srovnání technik monitorování plodu

Všechny techniky měření mají své výhody i nevýhody, ale v současné době se vývoj hodně zaměřuje na monitorování plodu pomocí fEKG. Obrázek 9 zobrazuje jednotlivé popsané techniky monitorování plodu, jako je fECHO, fMKG, KTG, fFKG, NI-fEKG a invazivní fEKG (I-fEKG). Na obrázku lze vidět rozdíl mezi využitím elektrod při adaptivním a neadaptivním zpracování fEKG signálu. Pro adaptivní zpracování je potřeba použít elektrody z hrudní oblasti (na obrázku jsou tyto elektrody označeny jako TE_1 a TE_2) i z břišní oblasti (na obrázku jsou tyto elektrody označeny jako AE_1 , AE_2 , AE_3 a AE_4). U neadaptivního zpracování je poté nutné použít pouze elektrody z břišní oblasti. Je zřejmé, že mEKG signál prochází z hrudní oblasti až do břišní oblasti těhotné ženy, proto se signál naměřený v břišní oblasti skládá z mateřské a plodové komponenty. Naopak signál naměřený v hrudní oblasti těhotné ženy obsahuje pouze čistý mateřský signál bez plodové komponenty. Dále lze na obrázku vidět možnost měření fFKG pomocí mikrofونů umístěných v břišní oblasti těhotné ženy na mateřském břiše (na obrázku jsou mikrofony označeny jako P_1 a P_2).



Obrázek 9: Techniky monitorování plodu a zpracování signálu.

Tabulka 2 zobrazuje souhrn hlavních informací o každé technice zobrazené na obrázku 9, jako je technické řešení nebo omezení z hlediska využití v určitém týdnu těhotenství. Tabulka 2 dále srovnává nejvýznamnější výhody a nevýhody jednotlivých zmíněných monitorovacích technik [RJ3, 8, 16, 18, 30, 32, 54]. Toto shrnutí naznačuje, že NI-fEKG je velmi slibnou technikou, protože se jedná o velice bezpečný, levný a jednoduchý přístup. Některé studie [55, 56] uvádějí, že fEKG dosahuje lepších výsledků než konvenční KTG. Navíc se, zda být přesnější metodou pro pacienty s vyšším BMI.

Tabulka 2: Tabulka srovnání technik monitorování plodu.

Metoda	Gestační věk	Technické řešení	Výhody	Nevýhody
NI-fEKG [RJ1, RJ3, RJ5, RJ6] [8, 9, 10, 11]	≥ 20 Možné použití během porodu	Standardní EKG elektrody umístěné v břišní oblasti (počet elektrod se liší)	Levné Relativně přesné Snadné ovládání Pohodlné (možnost pohybu) Kontinuální monitorování Monitorování fHR	Nízké SNR Významné množství překrývajících se nežádoucích signálů Bez morfologické analýzy fEKG signálu * (ST analýza)
I-fEKG [12, 13, 14]	Pouze během porodu	Transvaginální fetální skalp elektroda	Přesné Morfologická analýza fEKG signálu Kontinuální monitorování Monitorování fHR	Drahé Invasivní (nebezpečí infekce) Nepohodlné (omezuje pohyb) Výžaduje dobře vyškolený personál
KTG [12, 25, 26, 27]	≥ 20 Možné použití během porodu	Jeden snímač pro měření fHR a jeden snímač pro měření děložních kontrakcí	Relativně levné Vyhlazenější křivky signálu Spíše robustní a spolehlivé Nejvíce používané v klinické praxi	Nemožné posoudit variabilitu mezi jednotlivými tepey Ultrazvukové záření Není pasivní
fECHO [19, 20, 21]	≥ 18	Snímač v sondě slouží jako vysílač a přijímač pro ultrazvukové signály	Poskytuje spolehlivé údaje o morfologii srdce, o odchylkách v morfologii a o odchylkách v rychlosti průtoku krve	Drahé Výžaduje dobře vyškolený personál Ultrazvukové záření Nevhodné pro kontinuální monitorování
fFKG [RJ7, RJ8, RJ9] [RJ10, RJ11, RJ12] [15, 16, 17, 18]	≥ 20 Možné použití během porodu	Mikrofonní senzory (nebo optické ** senzory) umístěné v břišní oblasti	Levné Nepřenáší žádnou energii Stanovení vícečetných těhotenství Možnost domácího monitorování (mobilní aplikace)	Nepoužívá se v klinické praxi Náchylné na polybové artefakty (pohyb snímače)
fMKG [22, 23, 24]	≥ 20	Snímání magnetické aktivity fetálního srdce pomocí SQUID	Lepší morfologická analýza díky vysoké hodnotě SNR	Drahé Složitě měření Výžaduje dobře vyškolený personál Neumožňuje dlouhodobé monitorování z důvodu velikosti zařízení a nákladů

* Lze předpokládat, že pokročilé metody zpracování NI-fEKG signálu brzy umožní morfologickou analýzu [RJ3, 9].

** V současné době se používají optické senzory pro měření fFKG [17].

3 Základní rozdělení metod zpracování fEKG signálu

Existuje mnoho metod zpracování fEKG signálu a jejich základní rozdělení je na adaptivní a neadaptivní metody. Oba typy metod mají své výhody a nevýhody a jejich funkčnost se stále vylepšuje, ale přesto nebyla dosud nalezena optimální metoda.

Adaptivní metody jsou filtry, které jsou založeny na systému učení. Systém učení je schopen přizpůsobit své vlastnosti měnícím se podmínkám, ve kterých pracuje. Tento systém také využívá předchozí zkušenosti ke zlepšení svých vlastností (učí se). Aby systém učení mohl tak učinit, musí zaznamenávat změny v podmínkách, ve kterých pracuje, a na základě těchto záznamů systém zvažuje další kroky své činnosti. Systém poté automaticky nastaví své vlastní koeficienty na základě vnějších vlivů a používá aEKG signál jako primární vstup a mEKG signál jako referenční vstup. Adaptivní metody se používají k potlačení šumu a ke zlepšení SNR. Základní rozdělení je na nelineární adaptivní metody a na lineární adaptivní metody [RJ5, 8].

Mezi nelineární adaptivní metody patří:

- Umělé neuronové sítě (ANN).
- Hybridní neuronové sítě (HNN).
- Adaptivní neuro-fuzzy inferenční systém (ANFIS).

Mezi nelineární adaptivní metody patří:

- Kalmanova filtrace (KF).
- Algoritmus založený na stochasticky gradientní adaptaci (LMS).
- Algoritmus založený na rekurzivní optimální adaptaci (RLS).
- Adaptivní lineární neuron (ADALINE).

Neadaptivní metody nevyužívají žádný adaptivní systém k odstranění mEKG signálu a šumu, mezi který řadíme biologické a technické artefakty. Metody využívají buď jednocanálového zdroje signálu, nebo vícekanálového zdroje signálů.

3.1 Jednocanálové neadaptivní metody

Existuje mnoho metod, které využívají pouze jednocanálový zdroj signálu pro extrakci fEKG signálu. Volba metody je silně závislá na typu signálu, který je potřeba zpracovat. Tabulka 3 v kapitole 3.1.9 zobrazuje srovnání popsaných jednocanálových neadaptivních metod na základě specifických kritérií.

Do skupiny neadaptivních metod využívajících jednocanálový zdroj signálu patří:

- Vlnková transformaci (WT).
- Korelační technika (CT).
- Odčítací technika (ST).

- Průměrovací technika (AT).
- Filtrační technika (FT) jako je frekvenčně selektivní filtr s konečnou impulzní odezvou (FIR) a frekvenčně selektivní filtr s nekonečnou impulzní odezvou (IIR).
- Metoda založená na Winerově filtraci.
- Fixované FT, mezi které patří filtr typu dolní propust (DP), filtr typu horní propust (HP), filtr typu pásmová propust (PP) a filtr typu pásmová zádrž (PZ).
- De-shape krátko časová Fourierova transformace (STFT).
- Šablonové odčítání (TS).
- Empirický režim rozkladu (EMD).

3.1.1 Vlnková transformace

Existuje několik typů WT jako je diskrétní WT (DWT), spojitá WT (CWT), WT založená na dvouprůchodovém stupni synchronizace (PSWT), a další. Jejich využití je velice závislé na aplikaci a typu signálu, který je zpracováván. Při provádění určité WT je potřeba zvolit stupeň rozkladu signálu a typ vlnky [57]. Vlnková transformace poskytuje velice cenné informace v časové a frekvenční oblasti, proto jsou metody založené na WT velice účinné na nestacionární signály a na signály, které obsahují více komponent. Tato metoda je v podstatě konvoluční funkce signálu a vlnkové funkce [58]. Velice často se WT využívá jako předzpracování nebo pozpracování pro hybridní metody zpracování fEKG signálu [15, 59].

Hassanpour a kol. v roce 2006 [57] použili DWT k odhadnutí fEKG signálu. Jejich metoda měla dva kroky. V prvním kroku použili dvoustupňovou WT pro extrakci fEKG a mEKG signálů a v druhém kroku použili na získaný fEKG signál Savitzky-Golayův vyhlazovací filtr (SGSF), aby snížili vliv šumu. Savitzky-Golayův vyhlazovací filtr je nízkopásmový filtr, dobře přizpůsobený pro vyhlazení zašuměných signálů. Použili vlnku Daubechies, která byla tvarově stejná jako je srdeční tep. Pro testování funkčnosti DWT metody využili 3 syntetická data, kde mEKG signál měl desetkrát větší amplitudu než fEKG signál a reálná data z databáze DAISY vyvinuté De Moorem [60], která obsahuje 5 aEKG signálů a 3 mEKG signály dlouhé 10 s se vzorkovací frekvencí 250 Hz. Na základě výsledků došli k závěru, že tato metoda je slibná pro extrakci fEKG signálu.

Bhoker a kol. v roce 2013 [58] vyzkoušeli využití DWT pro extrakci fEKG signálu a pro následnou detekci R kmitů. Nejdříve v prvním kroku použili DWT pro extrakci fEKG a mEKG signálů a následně v druhém kroku v odhadnutém fEKG signálu detekovali R kmity. Pro experiment použili reálná data z NI-fEKG databáze (NIFECGDB) [49, 61], která obsahuje 55 vícekanálových záznamů (2 mEKG signály a 3 až 4 aEKG signály) naměřených u žen v 21. až 40. týdnu těhotenství s různou délkou trvání, vzorkovací frekvencí 1 kHz a s rozlišením 16 bitů. Z této databáze použili 15 rozdílných záznamů. Pomocí DWT vznikl mEKG signál, který následně odečetli od originálního aEKG signálu k odhadnutí fEKG signálu. Tento krok provedli, protože energie mEKG signálu byla mnohem větší než energie fEKG signálu v použitých aEKG signálech. Došli

k výsledkům, že u takto získaných signálů byli schopni detekovat stejný počet R kmitů plodu jako bylo obsaženo v originálním aEKG signálu.

Karvounis a kol. v roce 2004 [62] použili CWT metodu pro automatické stanovení fHR. Tuto metodu popisovali jako velice úspěšnou při detekci měnících se vlastností nestacionárních signálů. Metoda CWT probíhala ve 4 krocích. V prvním kroku bylo provedeno předzpracování pomocí zprůměrování signálu. Ve druhém byla provedena identifikace mHR. Ve třetím byla provedena identifikace fHR včetně falešně pozitivních tepů. V posledním byl aplikován heuristický algoritmus k zjištění překrývajících se QRS komplexů plodu a matky a bylo provedeno odstranění špatně zjištěných QRS komplexů. Pro hodnocení použili fEKG databázi univerzity v Nottinghamu [63], která obsahuje 15 tříkanálových záznamů (3 aEKG signály) dlouhých 1 min, se vzorkovací frekvencí 300 Hz a rozlišením 12 bitů. Z celkového počtu 1975 tepů, obsažených v použitých záznamech, CWT metoda dokázala správně detekovat 1954 tepů, 12 tepů vynechala a 9 tepů identifikovala špatně. Většina špatně identifikovaných QRS komplexů bylo na začátku a konci jednotlivých záznamů. Metodu určili jako velice účinnou, protože zlepšuje analýzu signálu díky informacím z imaginární části vlnek, a protože je schopna extrahovat mHR pro paralelní sledování stavu matky a plodu.

Kumar a kol. v roce 2016 [64] představili PSWT metodu extrakce fEKG signálu. Tato metoda je založena na konceptu, který dokáže zachytit kolísání signálu mezi R-R intervaly. V první části se odhadne mEKG signál ze zašuměného aEKG signálu pomocí synchronního rozložení smyček a poté se odhadne požadovaný fEKG signál. V závěru práce označili metodu PSWT za velice přesnou a užitečnou, a to zvláště při nízké energii (amplitudě) fEKG signálu obsaženého v zašuměném aEKG signálu. Metoda dokáže zajistit minimální ztráty informace při extrakci fEKG signálu a mEKG signálu. Výsledky rovněž ukázaly, že PSWT metoda při extrakci fEKG signálu výrazně zlepšila SNR a bylo možné přesně stanovit fHR.

3.1.2 Korelační technika

Autokorelační a křížově korelační techniky hledají podobnosti mezi dvěma vzorky daného signálu jako funkci časového zpoždění. Díky tomu CT zvýrazňuje periodicky se vyskytující vlny v signálu pomocí zvýraznění neperiodicky nekorelovatelných událostí jako je šum. Korelační techniky se často využívají k fEKG extrakci, ale pouze někdy se této metodě podaří dobře detekovat fEKG signál kvůli nedostatku správné šablony [59]. Šablona závisí na mnoha faktorech jako je týden aktuálního těhotenství ženy, BMI, počet plodů v těle matky, věk matky, a podobně. Tato metoda je také velice nepřesná při detekci a monitorování mnohočetného těhotenství a je neúčinná na nestacionární signály. Korelační technika je založena na získání zprůměrovaného mEKG signálu při použití vhodné korelační funkce, který se odečte od vstupního aEKG signálu k získání fEKG signálu.

Van Bommel v roce 1968 [65] ukázal metodu, která obsahovala autokorelační a křížově korelační techniky k detekci slabého fEKG signálu z aEKG signálu. Pro testování použil syntetická

i reálná data a došel k výsledkům, že metoda sice extrahuje fEKG signál, ale není dostatečně efektivní.

3.1.3 Odčítací technika

Jedná se prakticky o nejstarší, nejjednodušší a nejpřímochařejší způsob zpracování fEKG signálu. V dnešní době je ovšem ST metoda považována za zastaralou díky tomu, že mEKG signál neodpovídá vstupnímu aEKG signálu. Při extrakci fEKG signálu je mEKG signál velmi dominantní, takže ST metoda selhává při odstranění mateřské komponenty ze vstupního aEKG signálu. Kvůli neshodě signálů je mEKG signál místo odstranění sdružen se vstupním aEKG signálem a je nemožné detekovat čistý fEKG signál. Metoda je založena na seřazení aEKG signálu a mEKG signálu tak, že mEKG signál může být odečten od vstupního aEKG signálu. Tím je obdržen výsledný fEKG signál se zbytkovým šumem, který se v dalším kroku odstraní.

Bergveld a Meijer v roce 1981 [66] použili ST metodu k potlačení mEKG signálu z aEKG signálu k získání požadovaného fEKG signálu. Použili syntetická a také reálná data a došli k závěru, že čistý fEKG signál je těžké získat, protože naměřený mEKG signál z hrudníku není většinou stejný jako mEKG signál obsažený v aEKG signálu.

Levkov a kol. v roce 2005 [67] se zabývali zlepšením ST metody. Použili hardwarové měření k monitorování interferenčních period softwarového měření ke kompenzaci odchylky frekvence. Filtrační modul byl zaveden do metody, aby zvýšil flexibilitu konstrukce. Použili také digitální filtraci na lineární segmenty signálu, aby odstranili rušivé komponenty. Pro hodnocení použili 2 signály, přičemž 1. byl z jejich vlastní databáze a 2. byl syntetický. Závěrem bylo, že účinnost metody nezávisí na amplitudě a frekvenci rušení. Hlavní výhodou ST metody je, že prakticky zcela eliminuje síťové rušení z fEKG signálu bez porušení spektra.

3.1.4 Průměrovací technika

Tato metoda je jednou z nejvíce využívaných metod minulého století k extrakci fEKG signálu, která používá pouze jeden vstupní aEKG signál. Při extrakci fEKG signálu mají mateřské R kmity větší amplitudu, takže je snadné provést detekci z aEKG signálu pomocí detektoru založeném na prahové hodnotě. Referenční signál je získán zprůměrováním R-R intervalů obsahujících mQRS komplexy se stejnou fází. Dalším krokem AT metody je potlačení fEKG signálu a šumu z reference. Následně odečtením vytvořeného mEKG signálu od zašuměného aEKG signálu se získá požadovaný fEKG signál zcela bez mateřské komponenty [8]. Metodu AT lze použít k extrakci fEKG signálu pouze pokud je synchronizována relativní časová poloha z jednoho úseku signálu na druhý. V opačném případě bude AT metoda velmi nepřesná [15].

Hon a Lee v roce 1964 [68] se zabývali AT metodou a zjistili, že omezením této metody je nutnost uměle převést neperiodický signál na periodický. Po provedení experimentu došli k závěru, že AT metoda zlepšuje SNR o 10 až 20 dB. Byly tedy schopni extrahovat fEKG signál, který zobrazuje P a T vlny stejně dobře jako změny izolinie během těhotenství a porodu.

3.1.5 Filtrační technika

Abdominální EKG naměřené v břišní oblasti gravidní ženy obsahuje kromě plodové komponenty také artefakty jako je mEKG signál a šum. Tyto artefakty lze filtrovat pomocí velkého množství rozdílných FT jako jsou FIR filtry, IIR filtry, Wienerovo filtrování (WF), projektivní filtrování (PF), lineární filtry časové domény, frekvenční filtry, fixované filtry, a další. Některé typy artefaktů lze filtrovat přímo v časové oblasti, protože spektrální charakteristiky nemusí být vyžadovány. Ve většině případů je filtrování v časové oblasti rychlejší než filtrování ve frekvenční oblasti [8]. V případě, kdy se spektrum signálu a šumu překrývá, jsou lineární filtry neúčinné. Dále existuje možnost použití synchronizovaného zprůměrování signálu, nebo klouzavého průměrování (MA). Spolehlivost extrakce parametrů nebo signálu založená na konvenčním filtrování závisí hlavně na informaci z frekvenční oblasti nebo ze spektrální výkonové hustoty.

Alcaraz a kol. v roce 2007 [69] použili HP s mezní frekvencí 0,5 Hz k odstranění kolísání izolinií, DP s mezní frekvencí 70 Hz k odstranění vysokých frekvencí a notch filtr pro odstranění síťového rušení. Použili tyto nastavené hodnoty na 20 reálných záznamů EKG, které byly 15 s dlouhé se vzorkovací frekvencí 1 kHz a dokázali, že následně použitá metoda po tomto předzpracování pracovala mnohem přesněji.

Chmelka a kol. v roce 2005 [70] implementovali WF na data z vícekanálové atlasové knihovny. Knihovna obsahovala signály se vzorkovací frekvencí 500 Hz s malými amplitudami Q kmitů, velkými amplitudami R kmitů a s pozoruhodnými změnami signálu v oblasti QRS komplexů. Závěrem práce bylo, že se snižující úroveň SNR přestává WF fungovat.

Sun a kol. v roce 2002 [71] naimplementovali morfologickou filtrační metodu, který používá modifikované morfologické operátory pro korekci izolinií a eliminaci šumu. Pro otestování použili databázi arytmií vytvořenou institucí technologií v Massachusetts a nemocnicí v Beth Israel (MIT-BIH) [72], která obsahuje 48 reálných záznamů s délkou 30 min, vzorkovací frekvencí 360 Hz a rozlišením 11 bitů. Došli k výsledkům, že výběr sekvencí strukturovaných prvků závisí na rychlosti a tvaru pulzu signálu. Jejich metodu označili za vhodnou k využití jako předzpracování fEKG signálu.

3.1.6 De-shape krátko časová Fourierova transformace

De-shape krátko časová Fourierova transformace byla vytvořena pro úpravu omezení, které má diskrétní Fourierova transformace. Tato metoda poskytuje spolehlivý kompromis mezi časovou a frekvenční reprezentací vstupního aEKG signálu. Nicméně STFT metoda není příliš přesná pro analýzu nestacionárních signálů a časově měnícího se šumu, který je obsažen v fEKG signálech [73].

3.1.7 Metoda šablonového odčítání

Tato metoda využívá toho, že se určitá část signálu pravidelně opakuje (mEKG signál), aby mohla získat fEKG signál. Metoda šablonového odčítání může být aplikována jako jednokanálová

metoda využívající jeden vstupní aEKG signál, nebo jako vícekanálová metoda využívající více než dva vstupní aEKG signály. Každý srdeční cyklus matky je rekonstruován pomocí společné tepové křivky (šablony). Šablona je stanovena přímo z aEKG signálu a obsahuje několik kroků zpracování signálu. Při zpracování fEKG signálu se v prvním kroku získají všechny R kmity matky a každý tep matky je rozsegmentován tak, aby obsahoval odpovídající PQRST komplexy. Poté se provede zprůměrování za účelem získání šablony. Tato šablona lze vypočítat z každého segmentovaného tepu pomocí partikulárních adaptivních filtrů. Nakonec je každý tep matky zrekonstruován a tyto tepy jsou zřetězeny pro odhad mEKG signálu. Ten se následně odečte od vstupního aEKG signálu a získá se fEKG signál [74].

Agostinelli a kol. v roce 2017 [75] představil metodu založenou na TS nazývanou segmentační modulace. Tato metoda pracuje na základě hypotézy znalosti R kmitů a je schopna odhadnout fEKG signál téměř stejné kvality jako signál fEKG naměřený pomocí FSE. Pro testování použili reálná data z databáze ADFECGDB [13, 46, 47, 48, 49]. Jako hodnotící parametr použili SNR pro kvantifikaci kvality použité metody založené na TS. Dospěli k závěru, že tato metoda založená na TS dokázala extrahovat fEKG signály korelovatelné s přímými signály fEKG. Navíc potvrdili, že metody založené na TS výrazně zlepšují přesnost odhadu fEKG signálu a mohou přispět k rozšíření neinvazivní techniky odhadu fEKG signálu do klinické praxe.

Matonia a kol. v roce 2006 [76] použili metodu založenou na TS sloužící k potlačení mateřského PQRST komplexu. Odečtení PQRST komplexu je provedeno během následujících po sobě jdoucích mateřských srdečních cyklů, což se provádí synchronizací šablony PQRST a následného komplexu v čase. Jejich metoda nejdříve určí referenční body a poté odhadne mateřský PQRST komplex pomocí zprůměrování adekvátních komplexů. V dalším kroku stanoví potřebné faktory, a nakonec odečte šablonu ze vstupních aEKG signálů v referenčních bodech. Tuto TS metodu použili k porovnání s metodou potlačení mEKG signálu pomocí jednoúčelových koeficientů. Pro porovnání použili 3 záznamy, které obsahovaly 4 aEKG signály. Došli k výsledkům, že TS metoda nevyžaduje mEKG signál a nevyžaduje přesně stanovenou polohu měřených elektrod v břišní oblasti gravidní ženy. V závěru konstatovali, že TS metoda je schopna úplného potlačení mEKG signálu bez vlivu na kvalitu fEKG signálu. Nicméně použitá metoda nedokáže potlačit všechny ostatní složky šumu obsažené ve vstupních aEKG signálech.

3.1.8 Empirický režim rozkladu

Jedná se o automatickou metodu, která rozkládá nestacionární a nelineární signál do oscilačních komponent s určitými základními vlastnostmi. Tato metoda rozkládá časové řady na součet funkcí omezujících pásmo pomocí empiricky identifikujících fyzikálních časových řad. Všechny tyto funkce nazývané funkcemi vnitřního režimu (IMF) a obsahují dvě podmínky. Počet extrémů a počet nulových průchodů se musí rovnat nebo maximálně lišit o jednu hodnotu v celém záznamu. V celém záznamu je průměrná hodnota obálky definována pomocí lokálního maxima, kdy obálka definována pomocí lokálního minima je rovna nule. Je třeba zdůraznit, že okamžité frekvence nebudou mít přebytečné fluktuace vyvolané asymetrickými průběhy. Jedna podmínka

je prakticky shodná s úzkopásmovým požadavkem pro stacionární Gaussovský proces a druhá podmínka je shodná s lokálním požadavkem vyvolaným globálním požadavkem. Empirický režim rozkladu závisí na počtu frekvenčních komponent a amplitudě každé komponenty zpracovávaného signálu. Metoda EMD spouští extrakci vysokofrekvenčních komponent a opakuje se až k nízkofrekvenčním komponentám. Základem EMD je 5 kroků. Prvním krokem je identifikování maxima a minima časových řad. Druhým krokem je generování horních a dolních obálek pomocí samostatného propojení maxim a minim s interpolací kubických křivek. Třetím krokem je stanovení lokálního průměru. Čtvrtým krokem je odečtení IMF z originálního signálu k vytvoření nulového lokálního průměru. Pátým krokem je kontrola, zda výstupní vytvořená funkce nulového lokálního průměru je IMF nebo nikoli vzhledem k popsaným podmínkám [15, 77].

3.1.9 Shrnutí jednokanálových neadaptivních metod

Tabulka 3 ukazuje shrnutí jednokanálových neadaptivních metod zpracování fEKG signálu. Objektivní srovnání metod používaných v dnešní době je velice obtížné, protože v jednotlivých studiích používají rozdílné databáze, hodnotící parametry, a podobně. Proto je použito subjektivní hodnocení jednotlivých popsaných metod z hlediska celkového výkonu, zlepšení SNR, výpočetní náročnosti, možnosti monitorování v reálném čase a složitosti implementace.

Tabulka 3: Tabulka srovnání neadaptivních metod využívajících jednokanálový zdroj signálu.

Metoda	Celkový výkon	Zlepšení SNR	Výpočetní náročnost	Monitorování v reálném čase	Složitost implementace
WT (kap. 3.1.1)	Průměrný	Průměrné	Nízká	Ano	Průměrná
CT (kap. 3.1.2)	Nízký	Nízké	Nízká	Ano	Jednoduchá
ST (kap. 3.1.3)	Nízký	Nízké	Nízká	Ano	Jednoduchá
AT (kap. 3.1.4)	Nízký	Nízké	Nízká	Ano	Jednoduchá
FT (kap. 3.1.5)	Nízký	Nízké	Nízká	Ano	Jednoduchá
STFT (kap. 3.1.6)	Nízký	Průměrné	Nízká	Ne	Průměrná
TS (kap. 3.1.7)	Průměrný	Nízké	Nízká	Ne	Průměrná
EMD (kap. 3.1.8)	Průměrný	Průměrné	Vysoká	Ne	Průměrná

Celkový výkon odráží robustnost jednotlivé metody a je rozdělen na:

- Nízký celkový výkon – ukazuje, že metody jsou vhodné primárně jako předzpracování signálu, protože nejsou schopny extrahovat fEKG signál. Metody s nízkým celkovým výkonem jsou schopny pouze odstranit určitý typ rušení, jako je kolísání izoliny, síťové rušení, a podobně. Zlepšují SNR o méně než 5 dB (stanoveno na základě extrakce fEKG signálu ze syntetických dat).
- Střední celkový výkon – ukazuje, že metody jsou použitelné pro pokročilé předzpracování signálu a jsou schopny odstranit většinu rušení jako jsou pohybové artefakty, dechové artefakty, a podobně. Takto označené metody dokáží při zpracování fEKG signálu částečně potlačit mateřskou komponentu, umožňují detekci fQRS komplexů a stanovení fHR. Zlepšují SNR až o 20 dB (stanoveno na základě extrakce fEKG signálu ze syntetických dat).

- Vysoký celkový výkon – naznačuje, že metody poskytují uspokojivé informace o fHR a morfologii fEKG signálu. Zlepšují SNR o více než 20 dB (stanoveno na základě extrakce fEKG signálu ze syntetických dat).

Je třeba poznamenat, že parametr SNR objektivně určuje účinnost metody vzhledem k referenci, ale pokud jde o klinické použití, tak může být parametr SNR velmi zavádějící. Při zpracování fEKG signálu mohou být metody velmi nepřesné při detekci fQRS komplexu, přičemž vykazují vynikající zlepšení SNR. Zlepšení SNR je opět rozděleno do tří skupin:

- Nízké zlepšení SNR.
- Průměrné zlepšení SNR.
- Vysoké zlepšení SNR.

Výpočetní náročnost vyhodnocuje požadavky metod z hlediska výpočetní složitosti a tento parametr je rozdělen do tří kategorií:

- Nízká výpočetní náročnost.
- Střední výpočetní náročnost.
- Vysoká výpočetní náročnost.

Monitorování v reálném čase definuje, zda lze metodu použít v online režimu (v reálném čase) z hlediska její proveditelnosti s použitím aktuálně dostupných hardwarových zařízení v klinické praxi.

Složitost implementace hodnotí celkovou složitost, pokud jde o nasazení v klinické praxi. Složitost hardwaru a softwaru musí být ekonomicky proveditelná (pokud jde o monitorování stavu plodu) a systém by měl být veřejně dostupný všem těhotným ženám. Složitost implementace je rozdělena do tří kategorií:

- Jednoduchá implementace.
- Průměrná složitost implementace.
- Složitá implementace.

3.2 Vícekanálové neadaptivní metody

Tyto metody využívají jako vstup minimálně 2 aEKG signály. Při zpracování fEKG signálu s sebou nese každá elektroda umístěná v břišní oblasti gravidní ženy svůj vlastní šum, proto při použití aEKG signálů do vícekanálových neadaptivních metod musí být zvolen optimální počet elektrod pro získání ideální formy fEKG signálu. Do skupiny metod využívajících vícekanálový zdroj signálů patří hlavně metody založené na slepé separaci zdrojů (BSS), což je velice slibný a rozvíjející se soubor metod zpracování fEKG signálu. Metody BSS stanoví fEKG signál pomocí odhadu nezávislých zdrojů pro srdeční bioelektrické aktivity plodu [8]. Tyto metody se používají k získání nepozorovaných zdrojů signálů a předpokladem je, že zdroje signálů jsou statisticky

nezávislé ze známé směsice signálů. Tabulka 4 v podkapitole 3.2.15 zobrazuje srovnání popsaných vícekanálových neadaptivních metod na základě specifických kritérií [59].

Mezi BSS metody založené na statistických informacích vyššího řádu patří:

- Analýza nezávislých komponent (ICA).

Mezi BSS metody založené na statistice druhého řádu patří:

- Rozklad singulárních hodnot (SVD).
- Analýza hlavních komponent (PCA).
- Analýza periodických komponent (π CA).

Kromě metod založených na BSS existuje mnoho jiných vícekanálových neadaptivních metod:

- Sekvenční analýza (SA).
- Barrosova metoda (BM).
- Zhangova metoda (ZM).
- Metoda šikmosti (SM).
- Optimalizovaná kvalita indexu (QIO).
- Polynomiální maticový rozklad vlastních hodnot (PEVD).
- Fuzzy C-means shlukování (FCM).
- Stlačené snímání (CS).
- π Tuckerova metoda.
- Multivariační empirický režim rozkladu (MEMD).
- TS.

3.2.1 Analýza nezávislých komponent

Jedná se o nejčastěji publikovanou a nejčastěji užívanou neadaptivní metodu zpracování signálu. Analýza nezávislých komponent předpokládá, že komponenty zpracovaných signálů jsou statisticky nezávislé. Při zpracování signálu vyžaduje minimálně tolik vstupních zašuměných signálů jako je počet nekorelovaných zdrojů signálu. Během zpracování fEKG signálu vyžaduje tudíž minimálně dva vstupní aEKG signály, protože obsahují fetální a mateřský zdroj signálu. Samozřejmě je třeba si uvědomit, že není vhodné používat příliš moc vstupních aEKG signálů, protože každý s sebou nese vlastní šum. Metoda ICA obsahuje své vlastní předzpracování ve formě centrování a bělení. Centrováním se vytvoří vektor s nulovou střední hodnotou. Bělením se vytvoří vektor, jehož komponenty jsou nekorelované s jednotkovým rozptylem [59, 78].

Ve studiích existuje velké množství metod založených na ICA metodě:

- Rychlá ICA metoda (FastICA).
- Jednokanálová ICA metoda (SCICA).
- Přibližné diagonalizované spojení vlastních matic (JADE).

- ICA metoda s pevnými body.
- Maximalizování informace ICA metody (InfoMax).
- Comonova ICA metoda.
- Minimální Renyiho vzájemná informace (MeRMaId).
- Multidimenzionální ICA metoda (MICA).
- Neparametrická ICA metoda (NpICA).
- Flexibilní ICA metoda (FlexiICA).
- Neurální ortogonální skupina ICA metody (OgICA).
- Rychlá a adaptivní ICA metoda založená na plně multiplikativní ortogonální skupině (FastAdaptOgICA).
- Pearsonova ICA metoda.

Ahuja a kol. v roce 2016 [79] ukázali funkčnost FastICA metody při extrakci fEKG signálu. Problémem FastICA metody je získání směšovací matice a matice aEKG signálů ve formě, aby sloupcové vektory matice aEKG signálů byly statistické nezávislé. Kurtóza je maximální pro sloupcové vektory a pro nezávislé signály ve srovnání se smíšenými signály. Nezávislé signály jsou tudíž negaussovské v porovnání se smíšenými signály. Metoda FastICA začíná konverzí smíšených signálů pomocí vypočtení kovarianční matice konvertovaných signálů. V dalším kroku jsou inicializovány hodnoty nové matice a obnoví se její prvky pomocí iteračního vzorce. Provádí se zvolený počet iterací všech prvků, dokud všechny prvky nejsou vzájemně ortogonální. Nakonec jsou násobením získány nezávislé signály. Pro otestování účinnosti FastICA metody použili osmikanálové signály. Došli k výsledkům, že FastICA metoda je klinicky důležitá k odhadnutí různých parametrů týkajících se plodu. Závěrem bylo, že FastICA metoda je velice efektivní a rychlá pro extrakci nezávislých komponent.

Pani a kol. v roce 2008 [80] porovnávali online verzi metody JADE s blokovou verzí metody JADE. K porovnání využili krátkých úseků signálu a ručně přeměrovali zdroje. Metoda JADE se skládá ze 2 stupňů. Stupně obsahující statistiku druhého řádu (provádí centrování a bělení) a stupně obsahujícího statistiku vyššího řádu. Bělení dekoreluje a ortogonalizuje originální smíšené signály. Tím se snižuje počet parametrů, které je třeba odhadnout. K odhadnutí nezávislých zdrojů je následně vyžadována pouze rotace, která je provedena pomocí statistiky vyššího řádu. Prakticky se jedná o dávkovou metodu, která se zaměřuje na části signálu obsahující dostatečné statistické informace o nezávislých komponentech. Nevýhodou metody JADE je její vysoká senzitivita na šum. Pro otestování funkčnosti metody JADE použili veřejně dostupnou databázi reálných dat BIOMED [81], která obsahuje osmikanálové záznamy (5 aEKG signálů a 3 mEKG signály), které jsou 10 s dlouhé, mají vzorkovací frekvenci 250 Hz a rozlišení 12 bitů. Dále použili reálná data z databáze profesora De Lathauwera [82], která obsahuje osmikanálové záznamy (5 aEKG signálů a 3 mEKG signály), které jsou 1 min dlouhé, mají vzorkovací frekvenci 500 Hz a rozlišení 12 bitů. Druhou databázi převzorkovali na 250 Hz, protože vysoká vzorkovací frekvence není dobrá pro přesnou separaci. Jako hodnotící parametr použili relativní střední kvadratickou chybu (RMSE) mezi homogenními odhadnutými fEKG zdroji v rámci segmentu

T vlny. Další hodnocení bylo založeno na úspěšnosti separace a robustnosti proti permutacím. Došli k výsledkům, že metoda JADE má špatnou robustnost vůči šumu a obsahuje permutace v zašuměných kanálech kvůli nedokonalému online vzorkovacímu úseku ve stupni statistiky druhého řádu. I přes tyto negativní výsledky se zdá, že užitečné signálové zdroje nejsou ovlivněny permutacemi. Navrhované řešení je velmi slibné a stále se zlepšuje.

Ananthanag a kol. v roce 2003 [83] představili a porovnali metody založené na ICA metodě. Použili metodu JADE, ICA metodu s pevnými body, metodu InfoMax a Comonovu ICA metodu. Metoda ICA s pevnými body využívá kurtózy a výpočtů, které mohou být provedeny buď v režimu šrafování nebo v poloadaptivním režimu. Tato metoda využívá deflační přístup pro obnovení separační matice a pro nalezení jedné nezávislé komponenty po druhé. Poté metoda ICA s pevnými body začne využívat hyperbolickou tečnu, exponenciální funkci nebo kubickou funkci jako svou kontrastní funkci. Další použitá metoda nazývaná InfoMax vyvinutá Bellem a Sejnowskim je založena na maximalizaci entropie v jednovrstvé dopředné neuronové síti. Tato metoda využívá myšlenky, že pomocí maximalizací spojení výstupů entropie neurálního procesu může být minimalizováno vzájemná informace mezi výstupními komponentami. Metoda vyvinutá Comonem je založena na kontrastní funkci využívající minimalizování vzájemné informace mezi komponentami na výstupu separátoru. Kontrastní funkce je přímo spojena s Kullback-Leiblerovou divergencí mezi výstupní vektorovou funkcí hustoty pravděpodobnosti (PDF) a mezi její PDF (pokud je vyrobena z nezávislých komponent). Hodnocení přesnosti testovaných metod provedli na syntetických datech, které vytvořili spojením fEKG signálu a mEKG signálu a přidáním náhodného bílého Gaussova šumu. Došli k výsledkům, že všechny testované metody jsou schopny extrahovat fEKG signál s dobrou přesností, což je užitečné hlavně v případech vícečetného těhotenství. Dosáhli mnohem větší přesnosti při použití více vstupních signálů během testování metod. Se zhoršujícím se SNR vstupních signálů se ztrácely P a T vlny v šumu, ale stále tyto metody založené na ICA metodě byly schopny přesně detekovat R kmity.

Marosero a kol. v roce 2003 [84] použili metodu MeRMaId a porovnali ji s metodou FastICA a metodou InfoMax. Použitá metoda obsahovala 4 kroky. Prvním byla inicializace daných úhlů buď na všechny nuly nebo náhodně. Dále byla vypočtena bělicí matice pomocí offline separace, nebo pomocí online adaptivní verze PCA metody. Pokud by byly použity offline separace, tak by se následně použil dávkový gradient. V případě, kdy by byla použita online adaptivní verze PCA metody, tak by se následně použil stochastický gradient využívající pouze určitý počet vzorků v určitém čase včetně nejnovějšího vzorku. Při použití stochastického gradientu se použítá metoda nazývá MeRMaId-SIG. V posledním kroku je obnoven daný úhel natočení, který používá nejstrmější sestup. Použité metody porovnali na základě složitosti implementace, robustnosti a účinnosti separace, která je hodnocena pomocí odstupu signálu od deformace (SDR). Pro testování použili uměle vytvořenou směs 2 EKG signálů s původní vzorkovací frekvencí 500 Hz. Dále použili 5 min dlouhé reálné záznamy, které obsahují osmikanálové směsice signálů se vzorkovací frekvencí 200 Hz. Pro předzpracování signálů použili HP šestého řádu a předbělení. Na základě složitosti implementace, robustnosti a SDR označili metodu MeRMaId za výkonnější, než je me-

toda FastICA a metoda InfoMax. Tato metoda je prokazatelně efektivnější jak v dávkových, tak online režimech provozu, proto může být metoda MeRMaId použita k monitorování životních funkcí plodu v reálném čase.

Camargo-Olivares a kol. v roce 2011 [85] přišli s dalším metodou založenou na metodě ICA, která je jejím rozšířením a nazývá se MICA. Tato metoda nepředpokládá, že jsou komponenty statisticky nezávislé. Dle této metody mohou být komponenty rozděleny do skupin, které jsou statisticky nezávislé. V této studii navrhli zvýšení vstupních signálů obsahujících mEKG, které jsou zaznamenány v břišní oblasti těhotné ženy. Z těchto signálů se tedy odstraní plodová komponenty, aby se zabránilo neúspěšné separaci metodou MICA. Takže metoda MICA není schopna vyprodukovat užitečné informace bez toho, aby se nejdříve provedlo odhadnutí mEKG signálu. Metoda je složena z předzpracování signálu, odhadnutí mEKG signálu (např. pomocí PCA metody), z části ICA metody a z pozpracování signálu. V předzpracování použili FIR filtr typu PP s mezními frekvencemi 1 a 90 Hz a notch filtr. Pro testování použili 1 reálný záznam z databáze NIFECGDB [49, 61] a 15 záznamů z databáze syntetických dat, které jsou 30 min dlouhé. V části ICA použili nejdříve metodu JADE a poté zkusili metodu FastICA. Došli k závěru, že metoda MICA je efektivnější, když se využije více vstupních signálů pouze s odhadnutým mEKG signálem spolu s aEKG signály obsahujícími mEKG i fEKG signály.

Sevim a kol. v roce 2011 [86] použili model založený na odhadu hustoty jádra pro přímý odhad PDF z dat. Tento model využili k vytvoření metody založené na metodě ICA nazvané NpICA. Tato metoda v jednom okamžiku odhadne PDF zdrojových signálů a lineární operátor, který umožňuje separaci smíšených signálů. Pro první experiment použili syntetické záznamy s délkou signálů v rozmezí 512 až 4608 vzorků. Jako hodnotící parametr použili SNR a metodu NpICA porovnali s metodou FastICA a metodou JADE. Druhý experiment byl proveden na reálných datech naměřených pomocí 9 elektrod umístěných v břišní oblasti gravidní ženy. Tento experiment byl proveden pouze pro metodu NpICA. Došli k výsledkům, že metoda NpICA dosáhla většího výkonu než metody FastICA a JADE. Metoda NpICA je velmi robustní a je velice efektivní na záznamech s větší délkou signálu, ale tento vynikající výkon byl dosažen na úkor zvýšené výpočetní složitosti.

Ye a kol. v roce 2008 [87] navrhli rychlou a adaptivní metodu založenou na ICA metodě nazvanou FastAdaptOgICA. Tato metoda je založena na plně multiplikativní ortogonální skupině, která může okamžitě oddělit směsi subgaussovských zdrojových signálů, supergaussovských zdrojových signálů a také může oddělit šikmé nebo prakticky Gaussovy signály. K porovnání metody FastAdaptOgICA použili metodu OgICA, metodu dávkového učení pro analýzu neurových komponent, metodu InfoMax a metodu FlexiICA. Metoda OgICA je plně multiplikativní. Metoda FlexiICA může oddělit směsi subgaussovských a supergaussovských zdrojových signálů se samoučící nelinearitou. K testování použili data z balíčku ICALAB [88] a reálná data z databáze DAISY vyvinuté De Moorem [60]. Došli k závěru, že metoda FastAdaptOgICA úspěšně extrahovala fEKG signály s lepším separačním výkonem a rychlejší rychlostí konvergence než ostatní použité metody založené na metodě ICA.

3.2.2 Rozklad singulárních hodnot

Jedná se o prostorovou filtrační techniku a metodu rozkladu. Metoda SVD je řízena daty vytvářejícími požadované základní funkce ze samotných dat pomocí maximalizace několika statistických veličin rozdělení signálu [8]. Tato metoda je založena na maticové transformaci jednoho vektorového prostoru do jiného a je velmi výpočetně náročná [89].

De Lathauwer a kol. v roce 2000 [90] porovnávali běžný typ SVD metody, kvantitativní typ SVD metody a multilineární typ SVD metody. Pro testování použili osmikanálové a 1 min dlouhé signály, které mají vzorkovací frekvenci 500 Hz. Hodnotili výpočetní náročnost, robustnost a požadované iterace s uživatelským množstvím poskytnutých informací. Došli k závěru, že směšovací matice u multilineárního typu SVD metody může být získána bez kontroly, ale tato metoda je výpočetně náročnější. Metodu SVD označili za nejběžnější a efektivní techniku extrakce fEKG signálu.

3.2.3 Analýza hlavních komponent

Tato metoda je založena na redukci (snížení) počtu dimenzí z numerického měření několika proměnných. Při hledání zjednodušeného statistického problému ztrácí PCA metoda minimum informací. Využití PCA metody může být při hledání lineární kombinace pro separaci signálů ze zdrojů, které jsou statisticky nezávislé. To je provedeno určením dat pomocí nového souřadného systému a tato operace je obousměrná, při které se neztrácí žádná informace [91].

Raj a kol. v roce 2015 [92] použili metodu PCA a porovnávali její účinnost extrakce fEKG signálu spolu s metodou FastICA v program LabVIEW. Jako hodnotící parametry zvolili korelační koeficient a stanovení bpm. Pro testování použili reálná data z databáze ADFECGDB [13, 46, 47, 48, 49] a reálná data z databáze EKG physionet challenge 2013 [49, 93], která obsahuje 447 čtyřkanálových aEKG záznamů dlouhých 1 min se vzorkovací frekvencí 1 kHz a s rozlišením 12 bitů. Výsledky ukázaly, že obě metody mají prakticky stejnou účinnost a přesnost.

Bacharakis a kol. v roce 1996 [94] porovnali metodu PCA využívající statistiku druhého řádu s metodou SVD a metodou rozkladu vlastních hodnot (EVD), které využívají statistiku vyššího řádu. Použili 8 reálných záznamů, které jsou 10 s dlouhé a mají vzorkovací frekvenci 500 Hz. Výsledky ukázaly, že PCA metoda dosahuje menšího výkonu než SVD metoda a EVD metoda.

3.2.4 Analýza periodických komponent

Analýza periodických komponent využívá destruktivní interference k odstranění šumu a konstruktivní interference ke zlepšení periodických složek frekvenčního spektra. Metoda odstraňuje neúčinnost autokorelace stupně periody. Metoda π CA nevyžaduje zpoždění signálu a koreluje signály v čase a v pořadí aktuálního stupně v porovnání s originální vzorkovací frekvencí. Tato technika se snaží nalézt lineární směsici s maximální periodickou strukturou, která minimalizuje míru periodicity [95].

Kharabian a kol. v roce 2009 [95] použili metodu π CA k odhadnutí fEKG signálu a Hilbertovu transformaci k zvýraznění R kmitů. Pro testování použili 8 syntetických záznamů se vzorkovací frekvencí 500 Hz a přidáním vygenerovaným šumem. Účinnost metody π CA ve výsledcích porovnávali s metodou JADE. Došli k závěru, že měření periodicity je příležitostí použít známé informace ke zlepšení extrakce fEKG signálu. Tuto metodu označili za velice užitečnou pro automatické odfiltrování mEKG signálu.

3.2.5 Sekvenční analýza

Metoda SA využívá předchozí informace o rušení využité k extrakci fEKG signálu. Při zpracování fEKG signálu obsahuje SA metoda filtr odstraňující kolísání izolinie, detektor QRS komplexu, odstranění mateřské komponenty a odhadnutí fetální komponenty [96].

Martens a kol. v roce 2007 [96] představili novou metodu SA sloužící k extrakci fEKG signálu. Ke srovnání účinnosti použili metodu JADE a pro testování použili 20 záznamů naměřených u žen v 18. až 38. týdnu těhotenství. Výsledky ukázaly, že metoda SA dosáhla 85 % přesnosti detekce a metoda JADE pouze 60 % přesnosti detekce. Metoda SA byla určena za více robustní a přesnou, a to zvláště u nahrávek s nízkým SNR.

3.2.6 Barrosova metoda

Barrosova metoda patří mezi metody slepé extrakce zdrojů (BSE), což jsou učící metody schopné extrahovat jeden zdroj signálu z lineární směsi zdrojových signálů. Naopak BSS metody extrahují všechny zdroje signálů. Jedná se o velice jednoduchou metodu dávkového učení poloslepé extrakce fEKG signálu. Tato metoda při extrakci plodové komponenty extrahuje pouze fEKG signál z lineárních směsí. Využívá koncepcí sekvenční slepé extrakce a ICA metody. Přesto BM nepředpokládá, že jsou zdroje statisticky nezávislé a neprovádí extrakci přímo slepě jako metody BSS, ale poloslepě. Využívá předchozí informace o autokorelační funkci primárních zdrojů k extrakci fEKG signálu. Při zpracování fEKG signálu závisí účinnost BM na přesném odhadu periody plodové komponenty [97].

Barros a Cichocki v roce 2001 [97] vyvinuli BM k extrakci fEKG signálu. K testování použili reálná data z databáze DAISY vyvinuté De Moorem [60]. Výsledky ukázaly, že BM pracuje efektivně při odhadnutí fEKG signálu. Nicméně dokáže extrahovat signály pouze po dobu, kdy jsou dekorelované a vykazují časovou strukturu. Předností BM je její rychlost konvergence, protože k dosažení konvergence vyžadovala BM pouze několik iterací.

Zhang a Ye v roce 2005 [98] vyvinuli rozšířenou verzi BM. Tato metoda dokáže extrahovat úplně neznámé zdroje, které mají autokorelační vlastnosti. Klasická BM je omezena vyžadováním předchozích znalostí o autokorelačních funkcích zdrojů a jejich použití na neznámých zdrojích pro extrakci fEKG signálu. Jejich rozšířená verze BM aplikuje BSS techniku na autokorelační funkce pozorovaných signálů a pro optimální časové zpoždění získává při předzpracování pravidelně se objevující kmitů v autokorelační funkci. K testování použili reálná data z databáze

DAISY vyvinuté De Moorem [60]. Dospěli k výsledkům, že tato rozšířená verze BM dokáže extrahovat fEKG signál po dobu, kdy mají autokorelační vlastnosti.

3.2.7 Zhangova metoda

Zhangova metoda extrahuje fEKG signál ze vstupních aEKG signálů pomocí předchozích znalostí o rozsahu, ve kterém leží jeho hodnota kurtózy. Tato metoda je založena na vyhodnocení rozsahu kurtózy fEKG signálu. Hlavním problémem je, že chyba odhadu kurtózy velmi ovlivňuje výkonnost této metody [99].

Zhang a Yi v roce 2006 [99] vyvinuli ZM. Použili 4 syntetické záznamy, které obsahují stokrát nezávisle smíšené zdrojové signály s nulovou střední hodnotou, jednotkovým rozptylem a s délkou 3000 vzorků. Dále použili reálná data z databáze DAISY vyvinuté De Moorem [60]. Došli k výsledkům, že ZM je užitečná pro extrakci fEKG signálu, jehož hodnota kurtózy leží v určitém rozsahu.

3.2.8 Metoda šikmosti

Tato metoda využívá předchozí informace o šikmosti, která leží ve specifickém rozsahu, k extrakci fEKG signálu. Pomocí šikmosti je definována nákladová funkce, která obnovuje vektor hmotnosti pro extrakci fEKG signálu. Při monitorování plodu je tato metoda používána v rozsahu hodnot šikmosti pro plod, který byl zjištěn komplexními experimenty na reálných a syntetických datech [100].

Jafari a kol. v roce 2010 [100] použili SM pro extrakci a vyhodnocení fEKG signálu na základě stanovení hodnoty SNR před a po provedení filtrace a na základě výpočetní náročnosti. Použili reálná data z databáze DAISY vyvinuté De Moorem [60] a došli k výsledkům, že SM metoda zlepšuje kvalitu extrahovaného signálu. Výpočetní náklady potřebné pro extrakci fEKG signálu pomocí SM jsou nízké.

3.2.9 Optimalizovaná kvalita indexu

Metoda QIO se používá při extrakci fEKG signálu a využívá charakteristiky pseudoperiodicity a tvaru QRS komplexu v čase. Metoda obsahuje index kvality, který syntetizuje charakteristiky pseudoperiodicity. K extrakci fQRS komplexu vytváří jeden index kvality pro fEKG signál a jeden index kvality pro mEKG signál. Skládá se ze tří částí. První částí je předzpracování. Další je zlepšená extrakce mEKG signálu, která je provedena lineární kombinací maximalizující index kvality pro mEKG signál, mQRS detektor a odhadnutí (odstranění) mEKG signálu pomocí vážené SVD metody. Třetí částí je zlepšená extrakce fEKG signálu, která je provedena lineární kombinací maximalizující index kvality pro fEKG signál a fQRS detektor [101, 102].

Varanini a kol. v roce 2017 [102] vyvinuli a porovnali metodu QIO s několika metodami, které jsou založeny na ICA metodě. K porovnání použili reálná data z databáze EKG physionet challenge 2013 [49, 93]. Došli k závěru, že metoda QIO překonává ostatní srovnávané metody

při fQRS detekci. Navržená metoda eliminovala problém ICA, která automaticky volí fEKG signál nebo mEKG signál mezi odhadnutými nezávislými zdroji. Metoda QIO může být použita i v případě slabého fEKG signálu ve vstupních aEKG signálech.

3.2.10 Polynomiální maticový rozklad vlastních hodnot

Pro odhad širokopásmového podprostorového šumu se používá metoda PEVD. Tato metoda využívá sekvenční algoritmus druhého řádu nejlepší rotace, což je iterativní algoritmus časové domény založený na statistice druhého řádu poskytující vylepšenou silnou dekorelaci a spektrální majorizaci. Na základě rozkladu umožňuje tato metoda odhad podprostoru fEKG signálu. Jedná se o slepou techniku, která nemá předchozí znalosti o zdrojích nebo směšovací matici, ale využívá pouze znalost prostorově časové kovarianční matice. Energie mEKG signálu je dostatečnou v porovnání s fEKG signálem v záznamech, aby se oddělil od aEKG signálu a zůstal pouze fEKG signál [103].

Redif v roce 2016 [103] představil PEVD metodu a otestoval ji na syntetických datech z MIT-BIH databáze arytmií [72] a na reálných datech z databáze EKG physionet challenge 2013 [49, 93]. Došel k závěru, že ve srovnání s SVD metodou a metodami založenými na ICA metodě disponuje PEVD metoda vyšší přesností a je robustnější. Metoda PEVD dokáže odhadnout fetální R kmity s dobrou přesností a nevyžaduje mEKG signál jako referenční signál pro vstup. Výhodou PEVD metody je, že je velmi málo senzitivní na umístění elektrod při zaznamenávání aEKG signálů.

3.2.11 Fuzzy C-means shlukování

Jedná se o jednoduchou a efektivní metodu jejíž největší výhodou je posouzení počtu plodů v těle těhotné ženy. Tato metoda využívá předešlých znalostí pro následnou metodu slepé extrakce fEKG signálu. Cílem této metody je zvolení počátečních hodnot jako počáteční centra shlukování a poté rozdělit data do shluků pomocí iterace. Následně jsou stejné shluky minimalizovány a rozdílné shluky maximalizovány [104].

Tan a kol. v roce 2015 [104] vyzkoušeli FCM metodu k extrakci fEKG signálu. Použili dva aEKG signály s délkou 7 vteřin a vzorkovací frekvencí 500 Hz. Označili metodu FCM za extrémně přesnou a jednoduchou pro posouzení případu mnohočetného těhotenství.

3.2.12 Stlačené snímání

Tato metoda je založena na řídkých komponentách, které jsou obdrženy metodou ICA použitou ve stlačovací části metody. Jedná se o snímací a vzorkovací techniku, která umožňuje obnovit řídké komponenty z menšího počtu vzorků (než jaký dovoluje Shannonův vzorkovací teorém). Předpokladem CS metody je, že malý počet lineárních projekcí obsahuje dostatek informací k zrekonstruování řídkých signálů. Metoda stlačeného snímání obsahuje akvizici část

a stlačovací část. Jedná se o velice zajímavou metodu pro systémy bezdrátového monitorování biologických signálů [105].

Da Poian a kol. v roce 2016 [105] vyvinuli metodu CS a porovnali ji s metodou FastICA. K testování použili reálná data z databáze ADFECGDB [13, 46, 47, 48, 49] a reálná data z databáze EKG physionet challenge 2013 [49, 93]. Dospěli k závěru, že CS metoda může být použita pro kompresi aEKG signálu, odhadnutí fEKG signálu a pro monitorování fHR v reálném čase.

3.2.13 π Tuckerova metoda

Tato metoda využívá ke zpracování signálu morfologii srdečního signálu, který je svou kvazi-periodickou povahou a penalizovanou objektivní funkcí vhodný pro π Tuckerův rozklad sloužící k extrakci fEKG signálu z aEKG signálů. Jedná se o iterativní metodu, která dokáže automaticky zvolit požadovanou komponentu ze zdrojového prostoru [106].

Akbari a kol. v roce 2015 [106] použili metodu π Tucker k extrakci fEKG signálu a k porovnání s metodami založenými na metodě ICA. Pro testování použili reálná data z databáze ADFECGDB [13, 46, 47, 48, 49]. Výsledky ukázaly, že tato metoda dosahuje uspokojivého výkonu. Navíc požaduje pouze 20 iterací k dosažení uspokojivé formy extrahovaného fEKG signálu.

3.2.14 Multivariační empirický režim rozkladu

Tato metoda je založena na EMD metodě, což je plně datově řízená metoda pro nelineární a nestacionární signály v reálném světě. Metoda MEMD rozděluje signál na konečnou sadu několika IMF. Prvním krokem je odstranění více zašuměných aEKG signálů na základě porovnávání podobně indexovaných IMF, které byly vytvořeny pomocí metody MEMD. Následně je provedeno odstranění šumu ve zbývajících aEKG signálech opět pomocí odstranění podobně indexovaných IMF. Nakonec je nežádoucí mEKG signál odstraněn ze vstupních aEKG signálů a je odhadnut fEKG signál [107].

Gupta a kol. v roce 2016 [107] použili MEMD metodu na reálná data z databáze ADFECGDB [13, 46, 47, 48, 49] a na jednu databázi (v současné době zrušena), které obsahovala pouze 1 záznam těhotné ženy ve 40. týdnu těhotenství se vzorkovací frekvence byla 1 kHz. Výsledky ukázaly, že MEMD metoda dosáhla vysoké korelace mezi detekovanými a referenčními fHR, takže tuto metodu lze v praxi použít k monitorování fHR.

3.2.15 Shrnutí vícekanálových neadaptivních metod

V tabulce 4 lze vidět srovnání jednotlivých vícekanálových neadaptivních metod zpracování fEKG signálu. Pro relevantní porovnání všech popsaných metod byla použity stejná hodnotící kritéria jako v tabulce 3. Lze konstatovat, že většina vícekanálových neadaptivních metod dosahuje lepších výsledků než jednokanálové neadaptivní metody.

Tabulka 4: Tabulka srovnání neadaptivních metod využívajících vícekanálový zdroj signálů.

Metoda	Celkový výkon	Zlepšení SNR	Výpočetní náročnost	Monitorování v reálném čase	Složitost implementace
ICA (kap. 3.2.1)	Průměrný	Průměrné	Průměrná	Ne	Průměrná
SVD (kap. 3.2.2)	Nízký	Nízké	Průměrná	Ano	Jednoduchá
PCA (kap. 3.2.3)	Nízký	Průměrné	Nízká	Ano	Jednoduchá
π CA (kap. 3.2.4)	Průměrný	Vysoké	Nízká	Ne	Jednoduchá
SA (kap. 3.2.5)	Průměrný	Průměrné	Průměrná	Ne	Průměrná
BM (kap. 3.2.6)	Průměrný	Průměrné	Nízká	Ne	Jednoduchá
ZM (kap. 3.2.7)	Průměrný	Průměrné	Nízká	Ne	Jednoduchá
SM (kap. 3.2.8)	Průměrný	Průměrné	Průměrná	Ne	Jednoduchá
QIO (kap. 3.2.9)	Průměrný	Průměrné	Průměrná	Ne	Průměrná
PEVD (kap. 3.2.10)	Průměrný	Průměrné	Průměrná	Ne	Průměrná
FCM (kap. 3.2.11)	Průměrný	Průměrné	Průměrná	Ano	Jednoduchá
CS (kap. 3.2.12)	Průměrný	Průměrné	Průměrná	Ano	Průměrná
π Tucker (kap. 3.2.13)	Průměrný	Průměrné	Nízká	Ne	Jednoduchá
MEMD (kap. 3.2.14)	Průměrný	Průměrné	Průměrná	Ne	Průměrná

3.3 Hybridní metody

Mnoho aktuálních studií se zabývá možnostmi kombinování jednotlivých neadaptivních metod mezi sebou, nebo také možnostmi kombinace neadaptivních metod s adaptivními metodami. Tím dochází k vytvoření hybridních metod. Neadaptivní metody zpracování fEKG signálu jsou ve velkém množství případů využity pro předzpracování vstupních aEKG signálů před aplikací adaptivní metody. Neadaptivní metody totiž dokáží částečně oddělit komponenty ze vstupních aEKG signálů, což velice usnadní a zlepší kvalitu extrakce fEKG signálu pomocí následně použité adaptivní metody. Tato podkapitola se zabývá vybranými hybridními metodami, které dosahují větší přesnosti extrakce fEKG signálu oproti použití pouze adaptivní, nebo neadaptivní metody. Tabulka 5 v podkapitole 3.3.13 zobrazuje srovnání vybraných a popsaných hybridních metod na základě specifických kritérií.

3.3.1 Analýza nezávislých komponent, soubor empirického režimu rozkladu a vlnkové zmenšení

Jedná se o adaptivně integrovanou hybridní metodu pro fEKG extrakci, která se skládá z ICA, souboru EMD (EEMD) a vlnkového zmenšení (WS) (hybridní metoda ICA-EEMD-WS). V první části je aplikována metoda FastICA k separování smíšeného aEKG signálu a k odhadnutí fEKG signálu obsahujícího šum. Poté je provedeno odstranění šumu z fEKG signálu částečnou rekonstrukcí z IMF. Metoda EEMD v podstatě rozloží fEKG signál pomocí tříkrokového integrovaného algoritmu. Následuje aplikování metody WS k odstranění vysokofrekvenčního šumu. Kolísání izoliny a další artefakty jsou odstraněny přímo. Nakonec je provedena rekonstrukce fEKG signálu pomocí IMF bez šumu v první skupině a rezervovanými IMF ve druhé skupině [108].

Liu a Luan v roce 2015 [108] vyvinuli hybridní metodu ICA-EEMD-WS, a porovnali ji s Butterworthovým (BW) filtrem, čistou metodou WS a s hybridní metodou EEMD-WS. K otestování použili syntetická data z NI-fEKG generátoru signálů využívajícího Gaussovský EKG model [109], která se skládala z 6 vícekanálových záznamů s délkou 1200 vzorků a vzorkovací

frekvencí 1 kHz a z 500 jednonálových záznamů s různými artefakty. Dále použili MIT-BIH databázi arytmií [72] a reálná data z databáze ADFECGDB [13, 46, 47, 48, 49]. Výsledky získané na základě stanovení hodnoty SNR, korelačního koeficientu a střední kvadratické odchylky (MSE) ukázaly, že hybridní metoda ICA-EEMD-WS dosahuje vyšší hodnoty SNR a korelačního koeficientu. Zároveň dosáhla menší hodnoty MSE v porovnání s ostatními testovanými metodami. Pokud by byla hybridní metoda EEMD rychlejší mohla by být použita k monitorování fHR a mHR v reálném čase.

3.3.2 Adaptivní filtry a analýza nezávislých komponent

Gupta a kol. v roce 2007 [110] představili hybridní metodu, která se skládá z adaptivní metody čtyřkanálového odstranění mEKG signálu (FAMC), z adaptivního zesilovače fEKG signálu (AFE) a ICA metody (hybridní metoda FAMC-AFE-ICA). Adaptivní filtry u této hybridní metody využívají tři ortogonální mEKG signály a jeden aEKG signál k odhadnutí (odstranění) mEKG signálu a k extrahování fEKG signálu. K otestování použili MIT-BIH databázi arytmií [72] a reálná data z databáze DAISY vyvinuté De Moorem [60]. Došli k závěru, že hybridní metoda FAMC-AFE-ICA překonává výkonově metodu ICA a další starší schémata a poskytuje vynikající výsledky.

3.3.3 Analýza nezávislých komponent a projektivní filtrování

Kotas v roce 2008 [111] použil kombinaci ICA metody a jednonálového PF časově seřazených tepů fEKG signálu (hybridní metoda ICA-PF). Projektivní filtrování lze použít ke zlepšení částečného oddělení mEKG signálu, a poté lze mEKG signál zrekonstruovat a odečíst od vstupního aEKG signálu k odhadnutí fEKG signálu. Následně pomocí ICA metody lze zvýraznit fEKG signál. Hybridní metoda se skládá z lineárních filtrů provádějících předpracování, z metody ICA pro odhad zdrojových signálů, z výběru mateřské komponenty, z rekonstrukce mEKG signálu obsaženého v příslušných kanálech a z druhé aplikace ICA metody k odhadnutí fEKG signálu. Jako ICA metodu použil metodu JADE. Pro hodnocení použil záznamy 4 těhotných žen, které byly získány pomocí 4 abdominálních elektrod [112]. Dospěl k závěru, že hybridní metoda ICA-PF umožňuje efektivní extrakci fEKG signálu i v případech, kdy ICA metoda selhává nebo poskytuje špatné výsledky. Tato hybridní metoda může být užitečným prostředkem pro prenatální diagnostiku.

3.3.4 Analýza periodických komponent a generalizovaná metoda rozkladu vlastních hodnot

Sameni a kol. v roce 2008 [113] představili hybridní metodu založenou na metodě π CA a na generalizované verzi EVD metody (hybridní metoda π CA-EVD). Hybridní metoda π CA-EVD se snaží nalézt jakoukoli periodickou strukturu, která je synchronní s referenčními R kmity získanými z ideálního fEKG signálu. Experiment byl proveden na reálných datech z databáze

DAISY vyvinuté De Moorem [60]. V diskuzi uvedli, že hybridní metoda π CA-EVD nahrazuje kritérium nezávislosti ICA metody kritériem časové struktury, což je pro kardiology přínosné, protože periodické struktury se opakují v každém fEKG rytmu. Hybridní metoda π CA-EVD nahrazuje iterativní součást ICA metody, takže tato nová metoda je rychlejší. Dobrým přínosem této metody je, že klasifikuje extrahované komponenty podle stupně jejich synchronizace a jejich periodicity s R kmity. Přestože je generalizovaná EVD metoda velice citlivá na šum, tak hybridní metoda π CA-EVD byla stále dost robustní co se týče odchylky srdečního tepu a šumu.

3.3.5 Analýza hlavních komponent a analýza nezávislých komponent

Martin-Clemente a kol. v roce 2011 [114] vyzkoušeli kombinaci, která se skládá z redukce dimenzí a výpočetně méně náročného pozpracování ke zlepšení odhadnutého fEKG signálu. Krok redukce dimenzí je založen na metodě PCA, která snižuje počet zvažovaných signálů, což má za následek zrychlení procesu odhadnutí a výrazné snížení mEKG signálu stanoveného jako šum. Výpočetně méně náročné pozpracování je provedeno pomocí metody ICA, která je založena na maximalizaci kurtózy. Poté je aplikována metoda PCA znovu za účelem snížení dimenzí na jedinou (hybridní metoda PCA-ICA). Tento přístup se neustále opakuje, dokud nejsou odhadnuty všechny požadované signály. Pro testování použili volně přístupný EKG nástroj pro generování syntetických směsí fEKG a mEKG signálů s realistickým EKG šumem. Dále použili reálná data z databáze profesora De Lathauwera [82], která obsahuje osmikanálové záznamy (5 aEKG signálů a 3 mEKG signály), které jsou 1 min dlouhé, mají vzorkovací frekvenci 500 Hz a rozlišení 12 bitů. Tuto hybridní metodu porovnali s metodou FastICA, metodou JADE, hybridní metodou π CA-EVD a Pearsonovou ICA metodou. Dospěli k závěru, že tato kombinace je jednoduchá, rychlá a může být použita pro návrh bateriových zařízení pro monitorování fHR v reálném čase.

Ke stejnému výsledku dospěli Zarzoso a Nandi v roce 2001 [115], kdy použili PCA metodu jako předbělení pro ICA metodu a porovnávali účinnost s metodou multireferenčního adaptivního odstranění šumu. K otestování použili reálná data z databáze profesora De Lathauwera [82]. Hybridní metodu PCA-ICA určili jako robustnější a účinnější, než je srovnávaná adaptivní metoda. Jedinou nevýhodou je její vyšší výpočetní náročnost.

3.3.6 Rozklad singulárních hodnot a analýza nezávislých komponent

Gao a kol. v roce 2003 [116] použili kombinaci SVD spektrogramu a metody FastICA na spektrální a časové reprezentace signálu k extrakci fEKG signálu z jednokanálového aEKG signálu (hybridní metoda SVD-ICA). Hlavní myšlenkou kombinace SVD-ICA je přenést aEKG signál do vyšší dimenze a použít předpoklad statistické nezávislosti k odhadu fEKG signálu. Nejdříve je použita SVD metoda, která pomáhá oddělit komponenty. Následně se použije metoda FastICA, která přispívá k nezávislosti 2 komponent. Tuto hybridní metodu porovnávali s metodou SVD na základě detekce srdečních tepů na syntetických záznamech, které jsou zkonstruovány ze 2 si-

mulovaných EKG signálů. Dále použili 1 reálný záznam, který je 10 min dlouhý a má vzorkovací frekvenci 300 Hz. Došli k závěru, že hybridní metoda SVD-ICA je přesnější než metoda SVD, ale že detekuje falešně pozitivní tep v případě, když se překrývá mQRS komplex a fQRS komplex.

3.3.7 Rozklad singulárních hodnot a polynomiální klasifikátory

Ayat a kol. v roce 2008 [117] použili kombinaci SVD metody a polynomiálních klasifikátorů (PC) k extrakci fEKG signálu (hybridní metoda SVD-PC). Pomocí SVD metody se nejdříve odhadne mEKG signál, který je použit spolu s aEKG signálem jako vstup do PC. Ty následně extrahují fEKG signál pomocí dynamiky a nelinearity odhadnutého mEKG signálu. Tento hybridní model využívá pouze jednobaný vstupní signál, proto vyžaduje jednodušší hardware a umožňuje dlouhodobé nahrávání fEKG signálu v reálném čase. Pro hodnocení použili 1 syntetický záznam, který byl vygenerován pomocí 2 kompletně rozdílných EKG signálů. Dále použili reálná data z databáze profesora De Lathauwera [82] a reálná data zaznamenaná v nemocnici AI-Wasl v Dubaji. Dospěli k výsledkům, že tato hybridní metoda je velmi účinná a schopná extrahovat fEKG signál z jednobanového zdroje signálu.

3.3.8 Savitzky-Golayův vyhlazovací filtr a polynomiální klasifikátory

Ayat a kol. v roce 2015 [118] vyvinuli dvoustupňovou techniku extrakce fEKG signálu z jednobanového záznamu, která využívá SGSF a PC (hybridní metoda SGSF-PC). V prvním kroku je použit SGSF k odhadnutí mEKG signálu potlačením fetální komponenty, která může být brána jako šum překrývající se ve frekvenční oblasti s požadovaným mEKG signálem. Ten je poté nelineárně vyrovnán se vstupním aEKG signálem pomocí polynomiálních sítí metodou PC k odhadnutí fEKG signálu. Ke srovnání účinnosti použili metodu SVD. Pro testování zvolili 1 syntetický záznam vytvořený smíšením 2 reálných EKG signálů. Dále použili reálná data z databáze EKG physionet challenge 2013 [49, 93] a reálná data zaznamenaná v nemocnici AI-Wasl v Dubaji. Výsledky ukázaly, že tato hybridní metoda poskytuje lepší výsledky než metoda SVD a odstraňuje požadavek polynomiálních sítí, které používají jeden aEKG signál a jeden mEKG signál.

3.3.9 Barrosova metoda a Zhangova metoda

Ma a kol. v roce 2009 [119] vytvořili novou BSE metodu, která kombinuje metodu BM využívající periodicity a metodu ZM využívající kurtózy (hybridní metoda BM-ZM). K porovnání použili originální metody BM a ZM a k testování využili reálná data z databáze DAISY vyvinuté De Moorem [60]. Dospěli k závěru, že hybridní metoda BM-ZM není tak senzitivní na chybu odhadu period fEKG signálu jako je metoda BM a není tak senzitivní na chybu odhadu rozsahu kurtózy fEKG signálu jako je metoda ZM. Všechny tři provedené experimenty dokázaly, že tato nová hybridní metoda dosahuje lepšího výkonu než předešlé BM a ZM metody.

3.3.10 De-shape krátko časová Fourierova transformace a mediánová metoda

Tato metoda využívá z STFT pro přesné získání fetálních a mateřských R kmitů a k určení fHR a mHR. Dále využívá nelokální mediánovou metodu (NM) pro odhad křivek fEKG signálu a mEKG signálu (hybridní metoda STFT-NM). Hybridní metoda STFT-NM je založen na kroku předzpracování, kroku STFT metody pro stanovení mHR, kroku obdržení R kmitů pomocí sledování tepu a dynamického programování, kroku odhadnutí morfologie mEKG signálu pomocí NM, kroku stanovení fHR a kroku obdržení čistého fEKG signálu [73].

Su a He v roce 2017 [73] vyvinuli hybridní metodu extrakce fEKG signálu, která se skládá z STFT a NM. Hodnocení provedli na syntetických datech i reálných datech. Využili syntetická data z databáze simulovaných fEKG signálů (FECGSYNDB) [120], což je veřejně dostupný simulátor generující současně mEKG a fEKG signály v 34 kanálech a záznamy jsou dlouhé 5 min se vzorkovací frekvencí 250 Hz. Dále použili reálná data z databáze ADFECGDB [13, 46, 47, 48, 49] a reálná data z databáze EKG physionet challenge 2013 [49, 93]. Na základě testování došli k závěru, že hybridní metoda STFT-NM extrahuje fEKG signál velice dobře a může využít skrytých informací uvnitř aEKG signálu jako je informace o frekvenci, o energii a o nelineárních vztazích 2 po sobě jdoucích srdečních rytmech.

3.3.11 Jednokanálová slepá separace zdrojů

Jednokanálová slepá separace zdrojů (SCBSS) je založena na zpracování jediného vstupního zašuměného aEKG signálu k extrakci fEKG signálu. Tato metoda rozděluje signál na několik IMF pomocí EMD metody, která provádí mapování jednoho kanálu do více kanálů. Metoda se skládá z Bootstrap algoritmu, Houghova algoritmu, algoritmu Akaikeho informačního kritéria a PCA metody pro odhad počtu nezávislých komponent ve vstupním zašuměném aEKG signálu. Po provedení jednotlivých algoritmů jsou obdrženy 4 komponenty, které se sloučí s využitím optimalizace částic [121].

He a kol. v roce 2016 [121] vyvinuli metodu SCBSS. Pro ohodnocení použili 1 aEKG signál smíšený pomocí 4 vytvořených signálů a 2 signály z MIT-BIH databáze arytmií [72]. Došli k závěru, že tato hybridní metoda je velice přesná a může být použita pro určení počtu plodů v těle matky během těhotenství.

3.3.12 Metoda sekvenčního totálního variačního odstranění šumu

Metoda sekvenčního totálního variačního odstranění šumu (STVD) vychází z metody totálního variačního odstranění šumu (TVD), což je široce používaná metoda k odstranění šumu při zpracování obrazu. Dále se tato hybridní metoda skládá z TS metody využívající PCA (TS_{PCA}), protože dosahovala největší účinnosti než ostatní TS metody. Nejdříve je použita metoda TVD k odstranění šumu. Poté se aplikuje TS_{PCA} pro extrakci čistého šumu. Nakonec je použita opět metoda TVD jako kaskádový proces na zbytkový signál pro extrakci fEKG signálu [122].

Lee a kol. v roce 2016 [122] vyvinuli STVD metodu. Pro otestování účinnosti použili syntetická data z databáze FECGSYNDB [120] a reálná data z databáze EKG physionet challenge 2013 [49, 93]. Pro předzpracování použili notch filtr a BW s mezními frekvencemi nastavenými na 3 Hz a 90 Hz. Metodu STVD porovnávali s rozšířenou KF, s obyčejným použitím TS_{PCA} a s kombinací TVD a TS_{PCA} bez opětovného použití TVD metody. Došli k závěru, že STVD metoda je schopná efektivně detekovat správné R kmity plodu a snižuje detekční chyby. Závěrem bylo, že lze STVD metodu použít k monitorování fHR, protože má velmi nízké výpočetní nároky.

3.3.13 Shrnutí hybridních metod

Tabulka 5 porovnává různé typy popsaných hybridních metod. Pro relevantní srovnání všech zkoumaných metod jsme v předchozích případech použili identické hodnocení (tabulka 3 a tabulka 4). Obecně platí, že hybridní metody zpracování fEKG signálu překonávají výkonnostně jednokanálové a vícekanálové neadaptivní metody zpracování signálu.

Tabulka 5: Tabulka srovnání hybridních metod.

Metoda	Celkový výkon	Zlepšení SNR	Výpočetní náročnost	Monitorování v reálném čase	Složitost implementace
ICA-EEMD-WS (kap. 3.3.1)	Vysoký	Vysoké	Vysoká	Ano	Složitá
FAMC-AFE-ICA (kap. 3.3.2)	Vysoký	Průměrné	Vysoká	Ne	Složitá
ICA-PF (kap. 3.3.3)	Vysoký	Průměrné	Vysoká	Ne	Složitá
π CA-EVD (kap. 3.3.4)	Průměrný	Průměrné	Průměrná	Ne	Průměrná
PCA-ICA (kap. 3.3.5)	Průměrný	Průměrné	Průměrná	Ano	Průměrná
SVD-ICA (kap. 3.3.6)	Průměrný	Průměrné	Průměrná	Ano	Průměrná
SVD-PC (kap. 3.3.7)	Průměrný	Průměrné	Nízká	Ano	Průměrná
SGSF-PC (kap. 3.3.8)	Průměrný	Průměrné	Průměrná	Ne	Průměrná
BM-ZM (kap. 3.3.9)	Vysoký	Průměrné	Nízká	Ne	Jednoduchá
STFT-NM (kap. 3.3.10)	Průměrný	Průměrné	Průměrná	Ne	Průměrná
SCBSS (kap. 3.3.11)	Průměrný	Průměrné	Průměrná	Ne	Složitá
STVD (kap. 3.3.12)	Průměrný	Průměrné	Nízká	Ne	Složitá

3.4 Shrnutí metod zpracování signálů

Správně vyfiltrovaný fEKG signál poskytuje velice cenné a kritické informace o kondici plodu. Současné techniky jsou schopny identifikovat jen zlomek možných informací. V současné době lze s určitou přesností stanovit pouze fHR [123, 124]. Nicméně nejnovější studie ukazují, že NI-fEKG obsahují zatím nevyužité klinicky významné informace, jako jsou údaje o morfologii či délce prvků signálu [125]. Tyto informace jsou v dnešní době možné získat pouze invazivním přístupem, což je možné pouze po prasknutí plodové vody [126, 127]. Invazivní přístup poskytuje možnost určení hypoxického stavu plodu na základě fHR v kombinaci s ST analýzou a analýzou délky QT intervalu. Bohužel invazivní přístup je velice nebezpečný a má mnoho omezení, proto je velmi žádané vytvořit neinvazivní metodu, která neohrozí matku nebo plod a mohla by být použita k prenatální diagnostice.

Srovnání popsaných neadaptivních a hybridních metod shrnutých v tabulkách 3, 4 a 5 nabízí přehled výhod a nevýhod popsaných metod z hlediska jejich celkového výkonu, zlepšení SNR,

výpočetní náročnosti, možnosti monitorování v reálném čase a složitosti implementace. Srovnání metod z klinického hlediska je provedeno v tabulce 6, která ilustruje použitelnost metody na základě přesnosti stanovení fHR, možnosti morfologické analýzy signálu, použitých databází a technických řešení použitých pro otestování.

Přesnost stanovení fHR klasifikuje účinnost zkoumaných metod při monitorování plodu na základě stanovení R-R intervalů. Pro hodnocení jsou vytvořeny 4 kategorie:

- Nepřesné stanovení fHR – metody nejsou schopny dostatečně odstranit artefakty, aby byla možná detekce R-R intervalů. Takto zpracované signály nejsou použitelné pro stanovení fHR.
- Málo přesné stanovení fHR – metody odstraní většinu běžně vyskytujících se rušení a je možné provést detekci R-R intervalů. Nicméně se zde vyskytuje velký počet falešně detekovaných a nedetekovaných významných komplexů, tj. celková pravděpodobnost správné detekce tepů (ACC) $\leq 80\%$, sensitivita (SE) $\leq 80\%$, pozitivní prediktivní hodnota (PPV) $\leq 80\%$ a harmonický průměr mezi SE a PPV (F1) $\leq 80\%$.
- Přesné stanovení fHR – metody umožňují přesnou detekci fHR, tj. $80\% \leq \text{ACC} \leq 95\%$, $80\% \leq \text{SE} \leq 95\%$, $80\% \leq \text{PPV} \leq 95\%$ a $80\% \leq \text{F1} \leq 95\%$.
- Velmi přesné stanovení fHR – metody umožňují velmi přesný odhad fHR a v tomto případě se jedná o plnohodnotnou náhradu klasického KTG [25, 56, 128], tj. $\text{ACC} \geq 95\%$, $\text{SE} \geq 95\%$, $\text{PPV} \geq 95\%$ a $\text{F1} \geq 95\%$.

Možnost morfologické analýzy signálu klasifikuje účinnost zkoumaných metod z pohledu morfologické analýzy fEKG. Pro hodnocení jsou vytvořeny tři kategorie:

- Nemožná morfologická analýza – znázorňuje, že pro tyto metody nepřichází morfologická analýza signálu vůbec v úvahu.
- Částečně možná morfologická analýza – metody umožňují částečnou morfologickou analýzu signálu, ale pro dlouhodobé monitorování plodu jsou nepoužitelné (ST segment analýzu, QT segment analýzu, a podobně). Použité metody fungují dostatečně přesně jen na malém vzorku reálných dat, což je zapříčiněno kvalitou snímání, gestačním stářím, polohou plodu, a podobně.
- Možná morfologická analýza – morfologická analýza signálu je prakticky možná jen u hybridních metod.

Sloupec databáze uvádí zdroje dat, které byly v daných studiích použity. Databáze, které by uchovávaly záznamy fEKG, jsou důležitou součástí výzkumu této problematiky. Velkým problémem je jejich nedostatečné množství, které by bylo dostupné vědecké veřejnosti. Bez databází, respektive reálných záznamů, mohou vědci jen velice těžko ověřovat funkčnost metod, a tím docílit zpřesnění diagnostické kvality. Některé databáze obsahují mimo jiné také záznamy, které jsou opatřeny poznámkami. Typické je u databází fEKG opatření označení každého QRS komplexu dvěma a více kardiology nezávisle na sobě. Vznikají tak referenční anotace, které slouží jako zlatý standard pro další analýzy.

Technická řešení shrnuje technické informace u jednotlivých použitých studií, jako je:

- Typ a počet použitých elektrod (kanálů).
- Typ záznamů (syntetické nebo reálné).
- Počet pacientů, kvalita dat (z hlediska zašumění).
- Délka záznamů (T).
- Vzorkovací frekvence (Fs).
- Amplitudové rozlišení (res).
- Gestační věk (GA).

Tabulka 6: Srovnání popsaných metod zpracování signálů z hlediska získání klinických informací.

Metoda	Stanovení fHR	Morfologická analýza	Databáze	Technická řešení
WT [57] [58, 62, 64] kap. 3.1.1	Málo přesné	Nemožná	DAISY [60]; NIFECGDB [49, 61]; univerzita v Nottinghamu [63]	3 syntetické záznamy [57]; T=10 s; Fs=250 Hz; 8 kanálů [60]; Fs=1 kHz; res=16 b; 5-6 kanálů; GA=21.-40. týden; 55 reálných záznamů [49, 61]; T=1 min; Fs=300 Hz; res=12 b; 3 kanály; 15 reálných záznamů [63]
CT [65] kap. 3.1.2	Nepřesné	Nemožná	—	Bez technických specifikací [65]
ST [66, 67] kap. 3.1.3	Nepřesné	Nemožná	—	1 reálný záznam; 1 syntetický záznam [67]
AT [68] kap. 3.1.4	Nepřesné	Nemožná	—	Bez technických specifikací [68]
FT [69, 70, 71] kap. 3.1.5	Nepřesné	Nemožná	MIT-BIH [72]	T=15 s; Fs=1 kHz; 20 reálných záznamů [69]; Fs=500 Hz [70]; T=30 min; Fs=360 Hz; res=11 b; 48 reálných záznamů [72]
STFT [73] kap. 3.1.6	Málo přesné	Nemožná	—	Bez technických specifikací [73]
TS [74, 75, 76] kap. 3.1.7	Málo přesné	Nemožná	ADFECGDB [13, 46, 47, 48, 49]	T=5 min; Fs=1 kHz; res=16 b; GA=38.-41. týden; 5 reálných záznamů; 5 kanálů [13, 46, 47, 48, 49]; 4 kanály; 3 reálné záznamy [76]
EMD [77] kap. 3.1.8	Přesné	Nemožná	—	Bez technických specifikací [77]
ICA [79, 80, 83] [84, 85] [86, 87] kap. 3.2.1	Přesné	Částečně možná	BIOMED [81]; de Lathauwer [82]; NIFECGDB [49, 61]; ICALAB [88]; DAISY [60]	8 kanálů [79]; T=10 s; Fs=250 Hz; res=12 b; 8 kanálů [81]; T=1 min; Fs=500 Hz; res=12 b; 8 kanálů [82]; T=5 min; Fs=500 Hz; 8 kanálů [84]; Fs=1 kHz; res=16 b; 5-6 kanálů; GA=21.-40. týden; 55 reálných záznamů [49, 61]; T=30 min; 15 syntetických záznamů [85]; syntetické záznamy s 512-4608 vzorky; 9 kanálů [86]; T=10 s; Fs=250 Hz; 8 kanálů [60]

Metoda	Stanovení fHR	Morfologická analýza	Databáze	Technická řešení
SVD [90] kap. 3.2.2	Nepřesné	Nemožná	—	T=1 min; Fs=500 Hz; 8 kanálů [90]
PCA [92, 94] kap. 3.2.3	Málo přesné	Nemožná	ADFECGDB [13, 46, 47, 48, 49]; EKG physionet challenge 2013 [49, 93]	T=5 min; Fs=1 kHz; res=16 b; GA=38.-41. týden; 5 reálných záznamů; 5 kanálů [13, 46, 47, 48, 49]; T=1 min; Fs=1 kHz; res=12 b; 4 kanály; 447 reálných záznamů [49, 93]; T=10 s; Fs=500 Hz; 8 reálných záznamů [94]
π CA [95] kap. 3.2.4	Velmi přesné	Částečně možná	—	Fs=500 Hz; 8 syntetických záznamů [95]
SA [96] kap. 3.2.5	Přesné	Částečně možná	—	GA=18.-38. týden; 20 reálných záznamů [96]
BM [97, 98] kap. 3.2.6	Málo přesné	Nemožná	DAISY [60]	T=10 s; Fs=250 Hz; 8 kanálů [60]
ZM [99] kap. 3.2.7	Málo přesné	Nemožná	DAISY [60]	4 syntetické záznamy [99]; T=10 s; Fs=250 Hz; 8 kanálů [60]
SM [100] kap. 3.2.8	Přesné	Částečně možná	DAISY [60]	T=10 s; Fs=250 Hz; 8 kanálů [60]
QIO [102] kap. 3.2.9	Přesné	Částečně možná	EKG physionet challenge 2013 [49, 93]	T=1 min; Fs=1 kHz; res=12 b; 4 kanály; 447 reálných záznamů [49, 93]
PEVD [103] kap. 3.2.10	Přesné	Částečně možná	MIT-BIH [72]; EKG physionet challenge 2013 [49, 93]	T=30 min; Fs=360 Hz; res=11 b; 48 reálných záznamů [72]; T=1 min; Fs=1 kHz; res=12 b; 4 kanály; 447 reálných záznamů [49, 93]
FCM [104] kap. 3.2.11	Přesné	Částečně možná	—	T=7 s; Fs=500 Hz; 2 reálné záznamy [104]
CS [105] kap. 3.2.12	Přesné	Částečně možná	ADFECGDB [13, 46, 47, 48, 49]; EKG physionet challenge 2013 [49, 93]	T=5 min; Fs=1 kHz; res=16 b; GA=38.-41. týden; 5 reálných záznamů; 5 kanálů [13, 46, 47, 48, 49]; T=1 min; Fs=1 kHz; res=12 b; 4 kanály; 447 reálných záznamů [49, 93]
π Tucker [106] kap. 3.2.13	Málo přesné	Nemožná	ADFECGDB [13, 46, 47, 48, 49]	T=5 min; Fs=1 kHz; res=16 b; GA=38.-41. týden; 5 reálných záznamů; 5 kanálů [13, 46, 47, 48, 49];
MEMD [107] kap. 3.2.14	Přesné	Částečně možná	ADFECGDB [13, 46, 47, 48, 49]	T=5 min; Fs=1 kHz; res=16 b; GA=38.-41. týden; 5 reálných záznamů; 5 kanálů [13, 46, 47, 48, 49]; Fs=1 kHz; GA=40. týden; 1 reálný záznam [107]
ICA-EEMD-WS [108] kap. 3.3.1	Velmi přesné	Možná	NI-fEKG gen. [109]; MIT-BIH [72]; ADFECGDB [13, 46, 47, 48, 49]	Fs=1 kHz; 1200 vzorků; 506 syntetických záznamů [109]; T=30 min; Fs=360 Hz; res=11 b; 48 reálných záznamů [72]; T=5 min; Fs=1 kHz; res=16 b; GA=38.-41. týden; 5 reálných záznamů; 5 kanálů [13, 46, 47, 48, 49]
FAMC-AFE-ICA [110] kap. 3.3.2	Velmi přesné	Možná	MIT-BIH [72]; DAISY [60]	T=30 min; Fs=360 Hz; res=11 b; 48 reálných záznamů [72]; T=10 s; Fs=250 Hz; 8 kanálů [60]
ICA-PF [111] kap. 3.3.3	Velmi přesné	Možná	—	4 reálné záznamy; 4 kanály [111]
π -ICA-EVD [113] kap. 3.3.4	Velmi přesné	Částečně možná	DAISY [60]	T=10 s; Fs=250 Hz; 8 kanálů [60]

Metoda	Stanovení fHR	Morfologická analýza	Databáze	Technická řešení
PCA-ICA [114, 115] kap. 3.3.5	Přesné	Částečně možná	de Lathauwer [82]	8 syntetických záznamů; 5000 vzorků [114]; T=1 min; Fs=500 Hz; res=12 b; 8 kanálů [82]
SVD-ICA [116] kap. 3.3.6	Přesné	Částečně možná	—	2 syntetické záznamy [116]; T=10 min; Fs=300 Hz [116] 1 reálný záznam
SVD-PC [117] kap. 3.3.7	Málo přesná	Nemožná	de Lathauwer [82]	1 syntetický záznam [117, 118]; T=1 min; Fs=500 Hz; res=12 b; 8 kanálů [82]
SGSF-PC [118] kap. 3.3.8	Přesné	Nemožná	EKG physionet challenge 2013 [49, 93]	1 syntetický záznam [117, 118]; T=1 min; Fs=1 kHz; res=12 b; 4 kanály; 447 reálných záznamů [49, 93]
BM-ZM [119] kap. 3.3.9	Velmi přesné	Možná	DAISY [119]	T=10 s; Fs=250 Hz [119]
STFT-NM [73] kap. 3.3.10	Přesná	Nemožná	FECGSYNDB [120]; ADFECGDB [13, 46, 47, 48, 49]; EKG physionet challenge 2013 [49, 93]	T=5 min; Fs=250 Hz; res=16 b; 34 kanálů; 1750 syntetických záznamů [120]; T=5 min; Fs=1 kHz; res=16 b; GA=38.-41. týden; 5 reálných záznamů; 5 kanálů [13, 46, 47, 48, 49]; T=1 min; Fs=1 kHz; res=12 b; 4 kanály; 447 reálných záznamů [49, 93]
SCBSS [121] 3.3.11	Přesná	Nemožná	MIT-BIH [72]	1 syntetický záznam [121]; T=30 min; Fs=360 Hz; res=11 b; 48 reálných záznamů [72]
STVD [122] 3.3.12	Přesná	Nemožná	FECGSYNDB [120]; EKG physionet challenge 2013 [49, 93]	T=5 min; Fs=250 Hz; res=16 b; 34 kanálů; 1750 syntetických záznamů [120]; T=1 min; Fs=1 kHz; res=12 b; 4 kanály; 447 reálných záznamů [49, 93]

4 Cíle doktorské disertační práce

Z dosud publikovaných a autorem prostudovaných výsledků vědy a výzkumu, zabývajících se zpracováním NI-fEKG signálu, vyplynulo několik směrů, které dle názoru autora nebyly dosud dostatečně řešeny. Jedná se zejména o nedostačující aplikační výzkum hybridních metod pro zpracování fEKG signálu.

Cíle doktorské disertační práce jsou podloženy třemi impaktovanými publikacemi [RJ1, RJ3, RJ5], ve kterých autor shrnuje realizovanou rešerši a výsledky úvodních experimentů. V závislosti na výše uvedených skutečnostech byly stanoveny cíle doktorské disertační práce:

1. Provedení hloubkové rešerše současného stavu problematiky extrakce fEKG signálu s využitím hybridních metod pro zpracování fEKG signálu.
2. Návrh a realizace nového typu hybridních metod pro zpracování fEKG signálů, které budou kombinovat výhody jednotlivých metod:
 - Hybridní metoda kombinující analýzu nezávislých komponent; adaptivní neuro-fuzzy inferenční systém; vlnkovou transformaci (ICA-ANFIS-WT).
 - Hybridní metoda kombinující analýzu nezávislých komponent; algoritmus založený na rekurzivní optimální adaptaci; vlnkovou transformaci (ICA-RLS-WT).
3. Návrh a realizace modulární softwarové aplikace pro testování zkoumaných hybridních metod:
 - Plně funkční nastavování jednotlivých metod (ICA, ANFIS, RLS a WT).
 - Vizualizace realizovaných experimentů.
 - Statistické zpracování realizovaných výsledků (Bland-Altmanův graf a vyhodnocení obdržených parametrů).
 - Rozšiřitelnost aplikace pro další metody.
4. Realizace série experimentů na reálných datech z klinické praxe (databáze ADFECGDB [13, 46, 47, 48, 49] a databáze EKG physionet challenge 2013 [49, 93]). Velká část současných publikací využívá totiž pro ověření teoretického výzkumu pouze simulace. Řada metod, které v simulacích vykazují velice dobré výsledky, není možno v reálných aplikacích použít:
 - Stanovení fHR a statistické srovnání s referencí (referenční anotace).
5. Provedení objektivního hodnocení úspěšnosti extrakce fEKG signálu pomocí hybridních metod podle autorem navržené metodiky:
 - Stanovení ACC, SE, PPV a F1.
 - Bland-Altmanův graf.

Primárním přínosem hybridních metod zpracování fEKG signálu je možnost aplikování hlubší morfologické analýzy (ST segment analýzy, QT segment analýzy, a podobně), která přispívá k zvýšení senzitivity a specificity stanovení hypoxie plodu. Navíc vede ke snížení počtu zbytečně provedených operativních ukončení těhotenství pro domnělou hypoxii určenou na základě stanovení fHR. Hybridní metody mohou jednoznačně přispět k zcela nové neinvazivní diagnostické metodě, která bude kombinovat stanovení fHR a provedení hlubší morfologické analýzy. Je tedy zřejmé, že téma je velmi aktuální a je řešeno mnoha výzkumnými týmy po celém světě. Momentálně se z neinvazivně extrahovaného fEKG signálu dá stanovit pouze fHR. Pokud se povede do praxe zavést autorem navržené hybridní metody, mohlo by dojít k nahrazení klasického ST segment analyzátoru (STAN S31) s přínosem zachování neinvazivity vyšetření. Se současným vývojem je možné na programovatelná hradlová pole implementovat navržené hybridní metody v reálném čase (nebylo dříve možné).

5 Metody

Na základě provedené hloubkové rešerše [RJ1] a provedení úvodních experimentů [RJ3, RJ5] byla zvolena metoda ICA do první části hybridních metod. Bylo zjištěno, že metoda ICA je schopna z aEKG signálů vyextrahovat komponentu obsahující pouze mEKG signál. Dále je schopna vyextrahovat signál aEKG*obsahující mEKG signál a fEKG signál, který je zvýrazněný a v mnoha případech na stejné amplitudové úrovni jako mEKG signál. Spolu s FIR filtrem, který je použit na vstupní aEKG signály k odstranění neúčinné části signálů, tvoří metoda ICA předzpracování signálů pro adaptivní metody. Odhadnuté signály mEKG a aEKG* po provedení předzpracování jsou použity jako vstupy do dvou různých adaptivních metod. Jedná se o adaptivní metody ANFIS a RLS. Výstupní fEKG signál z obou adaptivních metod je potřeba vyhladit pomocí WT (pozpracování fEKG signálu). Spojením těchto metod vznikly 2 hybridní metody, ICA-ANFIS-WT a ICA-RLS-WT. Tato kapitola se bude v první části zabývat zmíněnými 5 použitými metodami (FIR filtr, ICA, RLS, ANFIS a WT) a jejich matematickým popisem. V další části této kapitoly budou popsány použité databáze v této práci a zvolené hodnotící parametry.

5.1 Frekvenčně selektivní filtr s konečnou impulzní odezvou

Filtrace signálu ve frekvenční oblasti slouží při zpracování fEKG signálu k odstranění určitých nežádoucích nebo nedůležitých složek signálu. Jedná se například o nedůležitou frekvenční oblast, kde se nachází část mQRS komplexu, nebo frekvenční oblast, kde se nachází šum způsobený kolísáním izolinií, myopotenciály, dechovou aktivitou, a podobně. Při zpracování fEKG signálu se ponechá pouze frekvenční oblast, ve které se s určitostí nachází fEKG signál, aby nedošlo k odstranění užitečného signálu pro stanovení fHR.

Základní rozdělení jednotlivých filtrů je na základě propusti signálu. Jedná se o filtry typu HP, DP, PP a PZ. Dalším dělením filtrů je podle délky impulzní odezvy na FIR filtry a IIR filtry. Mezi základní rozdíly mezi FIR a IIR filtry patří [129]:

- Filtry typu FIR jsou vždy stabilní na rozdíl od IIR filtrů, které mají problém se stabilitou.
- Filtry typu IIR vždy vyžadují aspoň jednu zpětnovazební smyčku na rozdíl od FIR filtrů, které nemají zpětné vazby.
- Filtry typu IIR mají malý řád přenosové funkce na rozdíl od FIR filtrů, které mají vysoký řád přenosové funkce.
- Filtry typu IIR mají celkem malé zpoždění a malé nároky na výpočetní paměť.
- Filtry typu FIR mají lineární fázovou charakteristiku v porovnání s IIR filtry, které mají nelineární fázovou charakteristiku.
- Nevýhodou FIR filtrů je menší strmota přechodového pásma.

Výslednou odezvu FIR filtru lze vypočítat pomocí diferenciální rovnice (3), kde N_{FIR} je řád filtru, h představuje impulzní odezvu a x představuje vstupní signál. Řád filtru bývá většinou v řádu desítek, proto dochází k velkému zpoždění výstupního signálu na rozdíl od vstupního

signálu. K popisu přenosové funkce FIR filtru slouží rovnice (4). Tato rovnice udává stabilitu FIR filtru. Základem FIR filtru je předpoklad, že frekvenční charakteristika filtru je periodická a impulsní charakteristiku lze vypočítat Fourierovou řadou. Výpočet Fourierovy řady je zde omezen na konečný počet koeficientů a vynásoben zvoleným oknem (Bartlettovým, Hanningovým, Hammingovým, Blackmanovým, a podobně). Násobení oknem má za úkol odstranit zákmity ve frekvenční charakteristice. Frekvenční charakteristiku lze vypočítat podle rovnice (5) [129].

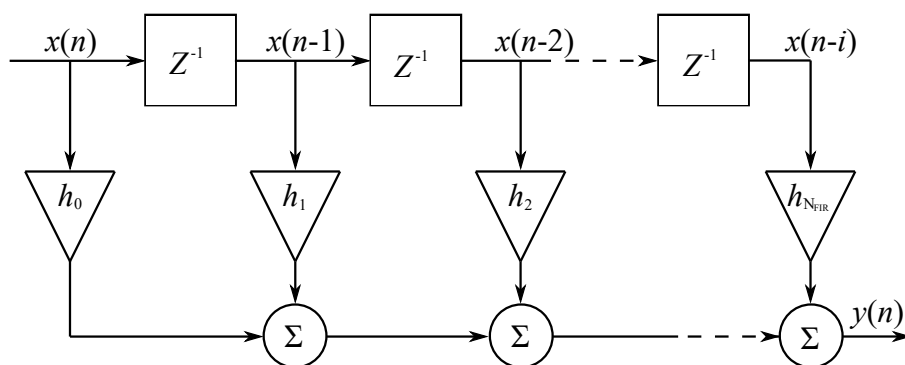
$$y_n = \sum_{i=0}^{N_{\text{FIR}}-1} h_i x_{n-i}. \quad (3)$$

$$H(z) = \frac{Y(z)}{X(z)} = \sum_{n=0}^{N_{\text{FIR}}-1} h_n z^{-n}. \quad (4)$$

$$G(\omega) = H(e^{j\omega T}) = \sum_{n=0}^{N_{\text{FIR}}-1} h_n e^{-j\omega n T}. \quad (5)$$

Implementace FIR filtru je jednoduchá a zpoždění je dáno několikanásobným pólem v počátku, který splňuje podmínku o stabilitě systému. Tento typ filtru je často označován jako nerekurzivní filtr, protože neobsahuje zpětnou vazbu. Během návrhu FIR filtru je vyžadováno, aby měl lineární frekvenční charakteristiku. Vlivem lineární fázové charakteristiky vzniká skupinové zpoždění, které se projevuje na každé harmonické složce. Splněním podmínky impulsní charakteristiky, viz rovnice (6), je dosaženo lineariry. Při filtraci signálu je potřeba zvolit mimo řád filtru N_{FIR} , také dolní mezní frekvenci f_{FIR_L} a horní mezní frekvenci f_{FIR_U} . Na obrázku 10 lze vidět blokové schéma FIR filtru [129].

$$h_n = \pm h_{(N_{\text{FIR}}-1-n)}. \quad (6)$$



Obrázek 10: Blokové schéma FIR filtru.

5.2 Analýza nezávislých komponent

Jedná se o metodu, která se pokouší najít lineární zobrazení negaussovských dat, které obsahují statisticky nezávislé komponenty (nebo komponenty blížící se nezávislosti). Při zpracování fEKG signálu lze princip ICA metody jednoduše vysvětlit. Jsou k dispozici 2 elektrody umístěné v břišní oblasti těhotné ženy poskytující 2 časové signály $x_1(t)$ a $x_2(t)$. Tyto signály poté obsahují součet signálů vyvolaných srdeční aktivitou matky a plodu označených jako $s_1(t)$ a $s_2(t)$ (reálně navíc signály vyvolané šumem). Tomuto problému, kdy jednotlivé získané signály obsahují více komponent (složek), se obecně říká Cocktail-party problém. Tuto situaci lze popsat pomocí rovnice (7) a (8), kde a značí parametry závislé na vzdálenosti jednotlivých srdečních aktivit od elektrod. Problémem je, že neznáme parametry a . Jedinou možností je předpokládat, že signály $s_1(t)$ a $s_2(t)$ jsou statisticky nezávislé, což je při zpracování fEKG signálu potvrzeno. Obecně lze složení časových signálů $x_1(t)$ až $x_m(t)$ popsat pomocí rovnice (9), kde n značí počet zdrojových signálů a m značí počet abdominálních signálů naměřených pomocí elektrod [RJ3, RJ5, 130, 131, 132].

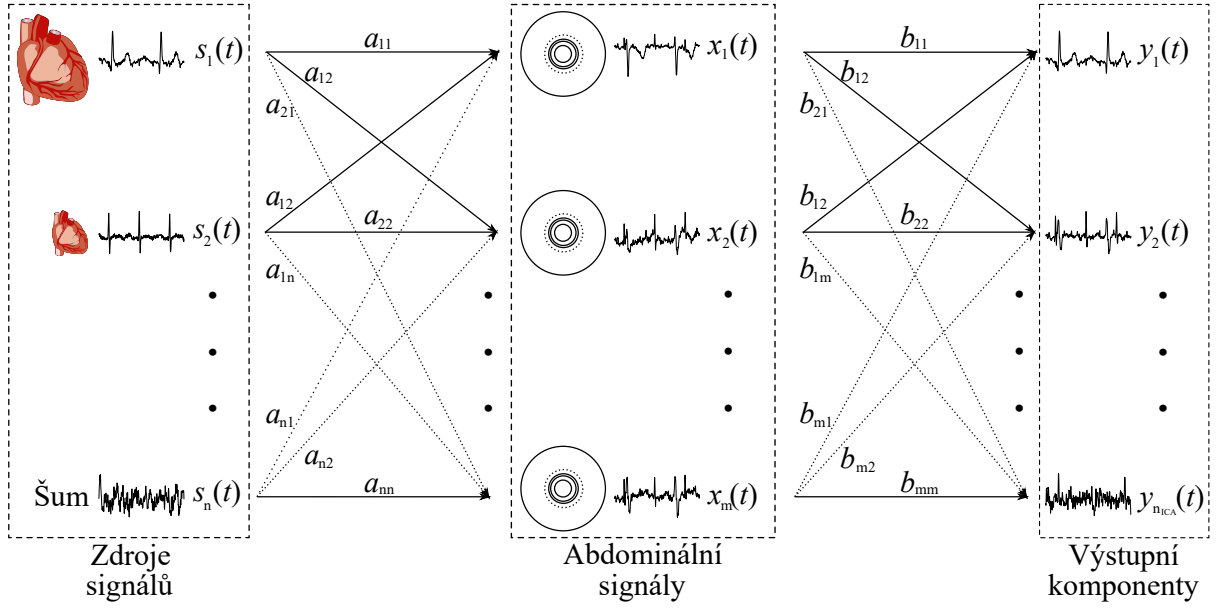
$$x_1(t) = a_{11}s_1 + a_{12}s_2. \quad (7)$$

$$x_2(t) = a_{21}s_1 + a_{22}s_2. \quad (8)$$

$$x_j = a_{j1}s_1 + a_{j2}s_2 + \dots + a_{jn}s_n. \quad (9)$$

Grafické znázornění popsaného problému při zpracování fEKG signálu lze vidět na obrázku 11, kde n značí počet zdrojových signálů, m značí počet abdominálních signálů naměřených pomocí elektrod a n_{ICA} značí počet statisticky nezávislých komponent. Je potřeba si uvědomit, že volba počtu výstupních komponent nemusí být stejná jako počet zdrojových signálů. Při zpracování fEKG signálu se zpravidla volí větší počet výstupních komponent, než je počet zdrojových signálů. To znamená volba aspoň 3 výstupních komponent. Ukázky signálů byly zpracovány na reálném záznamu r01 z databáze ADFECGDB [13, 46, 47, 48, 49].

Popsanými rovnicemi byl obdržen index času t , takže jednotlivé smíšené signály x_j a jednotlivé nezávislé komponenty (nezávislé zdroje signálů) s_k jsou náhodné proměnné. Následně je možné předpokládat, že jednotlivé smíšené signály a jednotlivé nezávislé komponenty mají nulovou střední hodnotu. Jestliže nemají nulovou střední hodnotu, tak se provede předzpracování ICA metody pomocí centrování (následně také pomocí bělení). Po provedení předzpracování ICA metody se pracuje se směšovací maticí \mathbf{A}_{mix} , viz rovnice (10), která obsahuje prvky a_{ij} a její řádky obsahují transponované vektory \vec{x}^T . Dalším předpokladem, který lze využít při implementaci ICA metody je, že směšovací matice \mathbf{A}_{mix} je čtvercová. Následně tedy lze provést inverzní matici \mathbf{W} z matice \mathbf{A}_{mix} a odhadnout nezávislé komponenty, viz rovnice (11) [RJ5, 132].



Obrázek 11: Grafické znázornění BSS problému při zpracování fEKG signálu.

$$\vec{x} = \mathbf{A}_{\text{mix}} \vec{s} = \sum_{i=1}^n a_i s_i. \quad (10)$$

$$\vec{s} = \mathbf{W} \vec{x}. \quad (11)$$

5.2.1 Předzpracování analýzy nezávislých komponent

Centrování se provádí odečtením středního vektoru $\vec{m} = E\{\vec{x}\}$ od \vec{x} a tím se obdrží vycentrovaný vektor \vec{x} s nulovou střední hodnotou. Tato operace způsobí, že vektor \vec{s} bude také s nulovou střední hodnotou. Z obdržené směšovací matice \mathbf{A}_{mix} pomocí dat po vycentrování, lze vypočítat zpětnou střední hodnotu vektoru \vec{s} pomocí $\mathbf{A}_{\text{mix}}^{-1} \vec{m}$ [RJ5, 132].

Kromě centrování se v předzpracování ICA metody provádí operace bělení. Při bělení se lineárně transformuje vektor \vec{x} k získání vektoru $\vec{\tilde{x}}$, jehož komponenty jsou následně nekorelované s jednotkovým rozptylem. Při bělení se kovarianční matice rovná identifikační matici, viz rovnice (12). Bělení lze provést využitím EVD kovarianční matice, viz rovnice (13), kde \mathbf{E} je ortogonální matice vlastních vektorů a \mathbf{D} je diagonální matice vlastních hodnot. Následně je bělení směšovací matice uskutečněno pomocí rovnice (14). Účelem bělení a hlavní výhodou je, že není potřeba určit n^2 parametrů matice \mathbf{A}_{mix} , ale stačí určit $n(n-1)/2$ parametrů vybělené ortogonální matice $\tilde{\mathbf{A}}_{\text{mix}}$. Bělení prakticky zjednodušuje práci ICA metody [RJ5, 132].

$$E\{\vec{\tilde{x}} \vec{\tilde{x}}^T\} = \mathbf{I}. \quad (12)$$

$$E\{\vec{x}\vec{x}^T\} = \mathbf{E}\mathbf{D}\mathbf{E}^T. \quad (13)$$

$$\vec{x} = \mathbf{E}\mathbf{D}^{-\frac{1}{2}}\mathbf{E}^T \vec{x} = \mathbf{E}\mathbf{D}^{-\frac{1}{2}}\mathbf{E}^T \mathbf{A}_{\text{mix}} \vec{s} = \tilde{\mathbf{A}} \vec{s}. \quad (14)$$

5.2.2 Nejasnosti u výstupních komponent

Jednou ze dvou základních nejasností u ICA metody je, že ICA metoda nezná energii jednotlivých nezávislých komponent (velikost a orientaci). To je způsobeno tím, že matice \mathbf{A}_{mix} a vektor \vec{s} jsou neznámé a libovolné skalární násobení v určitém zdroji s_i bude vyrušeno separací sloupce a_i v matici \mathbf{A}_{mix} . To způsobuje, že je snadné určit jednotlivé veličiny nezávislých komponent a lze předpokládat, že mají jednotkový rozptyl. Úpravou matice \mathbf{A}_{mix} není sice problém s nejasností znaménka odstraněn, ale u většiny případů se jedná o nedůležitý problém [RJ5, 132].

Další nejasností je, že nelze určit pořadí výstupních komponent z ICA metody, takže lze volat libovolnou komponentu jako první. Pomocí permutační matice \mathbf{P} a její inverzní matice lze následně vypočítat rovnici (15). Prvky $\mathbf{P}\vec{s}$ jsou v upravené originální nezávislé proměnné s_j (provedená změna pořadí) a matice $\mathbf{A}_{\text{mix}}\mathbf{P}^{-1}$ je nová neznámá směšovací matice [RJ5, 132].

$$\vec{x} = \mathbf{A}_{\text{mix}}\mathbf{P}^{-1}\mathbf{P}\vec{s}. \quad (15)$$

5.2.3 Definování nezávislosti veličin

Nezávislost mezi dvěma veličinami lze definovat tak, že informace obsažené v jedné veličině nejsou obsaženy v druhé veličině. Pomocí rovnice (16) a (17) může být popsána nezávislost mezi veličinami y_1 a y_2 , kde $p_1(y_1)$ značí funkci hustoty pravděpodobnosti veličiny y_1 , $p_2(y_2)$ značí funkci hustoty pravděpodobnosti veličiny y_2 a $p(y_1, y_2)$ značí funkci vzájemné hustoty pravděpodobnosti veličin y_1 a y_2 . Obě veličiny mohou být označeny za nezávislé jedině, když lze jejich vzájemnou hustotu pravděpodobnosti zapsat dle rovnice (18). Vzájemná hustota pravděpodobnosti musí splňovat n podmínek a týká se počtu n náhodných veličin. Pro funkce h_1 a h_2 lze sestrojit rovnici (19) [RJ5, 132].

$$p_1(y_1) = \int p(y_1, y_2) dy_2. \quad (16)$$

$$p_2(y_2) = \int p(y_1, y_2) dy_1. \quad (17)$$

$$p(y_1, y_2) = p_1(y_1)p_2(y_2). \quad (18)$$

$$E\{h_1(y_1)h_2(y_2)\} = E\{h_1(y_1)\}E\{h_2(y_2)\}. \quad (19)$$

Dále lze nezávislost popsat pomocí nekorelovatelnosti, kdy dvě veličiny jsou nekorelované, když výsledek jejich kovariance se rovná nule dle rovnice (20). Když jsou dvě veličiny mezi sebou nezávislé, a tudíž nemají vzájemnou korelaci, tak neplatí, že nekorelovatelnost je nezávislost [RJ5, 132].

$$E\{y_1, y_2\} - E\{y_1\}E\{y_2\} = 0. \quad (20)$$

Existuje ještě jedna možnost popisu nezávislosti, která je zároveň základem ICA metody. Jedná se o předpoklad, že nezávislé komponenty mají negaussovské rozdělení (nepochází z normálního rozdělení dat), viz rovnice (21). Důvodem je, že pokud by signály s_i pocházely z normálního rozdělení dat (Gaussova rozdělení), tak by hustota pravděpodobnosti byla symetrická a neposkytovala by žádné informace o směru sloupců matice \mathbf{A}_{mix} . To znamená, že by bylo zcela nemožné odhadnout nezávislé komponenty [RJ5, 132].

$$p(x_1, x_2) = \frac{1}{2\pi} \exp\left(-\frac{x_1^2 + x_2^2}{2}\right). \quad (21)$$

5.2.4 Možnosti odhadu nezávislých komponent

Běžně využívaným způsobem odhadnutí nezávislých komponent je využití vypočtení špičatosti, viz rovnice (22). Pokud výsledek špičatosti je kladný, tak je označována špičatost jako supergaussovská a její náhodné veličiny mají špičatější vzájemnou hustotu pravděpodobnosti. Naopak pokud výsledek špičatosti je záporný, tak je označována špičatost jako subgaussovská a její náhodné veličiny mají typicky plochou vzájemnou hustotu pravděpodobnosti [RJ5, 132].

$$kurt(y) = E\{y^4\} - 3(E\{y^2\})^2. \quad (22)$$

Druhou velice často používanou možností odhadu nezávislých komponent je využití negativní entropie (negentropie). Entropie sleduje míru náhodnosti proměnné, čím je náhodnost větší, tím je větší hodnota entropie. Výpočet entropie lze provést pomocí rovnice (23), kde \vec{y} je náhodný vektor s hustotou pravděpodobnosti $f(\vec{y})$. Proměnné pocházející z normálního rozdělení dat mají největší hodnotu entropie mezi náhodnými veličinami stejného rozptylu. Negentropie se následně využívá pro opačný případ, aby měla největší hodnotu u proměnných nepocházejících z normálního rozdělení dat (negaussovského rozdělení), viz rovnice (24), kde \vec{y}_{gauss} je náhodný vektor pocházející z normálního rozdělení stejné kovarianční matice jako vektor \vec{y} [RJ5, 132].

$$H(\vec{y}) = - \int f(\vec{y}) \log f(\vec{y}) dy. \quad (23)$$

$$J(\vec{y}) = H(\vec{y}_{\text{gauss}}) - H(\vec{y}). \quad (24)$$

Pokud by při výpočtu negentropie data pocházela z normálního rozdělení dat, tak by hodnota negentropie byla nulová. Pro ulehčení složitosti výpočtu negentropie se používá výpočet aproximace negentropie. Tato aproximace je založena na výpočtu maximální negentropie, viz rovnice (25), kde k_i je pozitivní konstanta, v je proměnná pocházející z normálního rozdělení dat s nulovou střední hodnotou a jednotkovým rozptylem jako má proměnná y a G_i je kvadratická funkce (tuto funkci je potřeba vhodně zvolit) [RJ5, 132].

$$J(\vec{y}) \approx \sum_{i=1}^P k_i [E\{G_i(y)\} - E\{G_i(v)\}]^2. \quad (25)$$

5.2.5 Metoda rychlé analýzy nezávislých komponent

Metoda FastICA je v dnešní době prakticky nejpoužívanějším typem ICA metody. Jejím základem je pevné iterační schéma hledající maxima dat nepocházejících z normálního rozdělení dat $\vec{w}^T \vec{x}$. Toho lze docílit také použitím aproximace Newtonovy iterace. K sestrojení metody FastICA je potřeba váhového vektoru \vec{w} a derivace g nekvadratické funkce G , viz rovnice (25). Tím se obdrží deriváty, viz rovnice (26) a (27), kde a_i je vhodná konstanta z intervalu $1 \leq a_i \leq 2$ [RJ5, 132].

$$g_1(u) = \tanh(a_1 u). \quad (26)$$

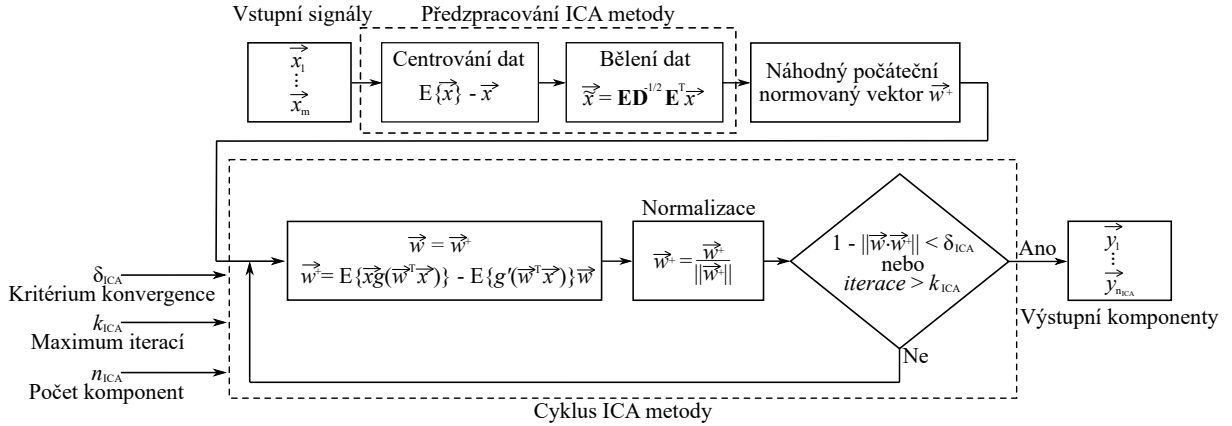
$$g_2(u) = u \exp\left(-\frac{u^2}{2}\right). \quad (27)$$

Základem FastICA metody jsou 4 kroky. Před provedením následujících kroků musí být aplikováno předzpracování formou centrování a bělení, musí se zvolit kritérium konvergence δ_{ICA} (často se používá $\delta_{\text{ICA}} = 0,00001$), maximální počet iterací cyklu k_{ICA} (často se používá $k_{\text{ICA}} = 100$) a počet výstupních komponent n_{ICA} (nejmenší doporučený počet výstupních komponent při zpracování fEKG signálu je $n_{\text{ICA}} = 3$). Snahou konvergence je dosáhnout prakticky nulového skalárního součinu mezi starými a novými hodnotami vektoru. Nejdříve se provede vytvoření náhodných normovaných počátečních vah vektoru \vec{w}^+ . Poté se uloží aktuální vektor \vec{w}^+ do vektoru \vec{w} a pomocí rovnice (28) se vypočte špičatost, nebo se může v tomto kroku vypočítat negentropie. Následně se provede normování pomocí rovnice (29). Poslední krok kontroluje, zda skalární součin nového vektoru \vec{w}^+ a vektoru \vec{w} je menší než zvolené kritérium konvergence δ_{ICA} , a zda neproběhl cyklus vícekrát, než je zvolený maximální počet iterací k_{ICA} , viz rovnice (30). Pokud není splněna podmínka, tak se opakuje druhý a třetí krok FastICA metody. Obrázek 12 [133] zobrazuje blokové schéma popsané funkce metody FastICA [RJ5, 132].

$$\vec{w}^+ = E\{\vec{x}g(\vec{w}^T\vec{x})\} - E\{g'(\vec{w}^T\vec{x})\}\vec{w}. \quad (28)$$

$$\vec{w}^+ = \frac{\vec{w}^+}{\|\vec{w}^+\|}. \quad (29)$$

$$1 - \|\vec{w} \cdot \vec{w}^+\| < \delta_{ICA}, \text{ nebo } \textit{iterace} > k_{ICA}. \quad (30)$$



Obrázek 12: Blokové schéma funkce metody FastICA.

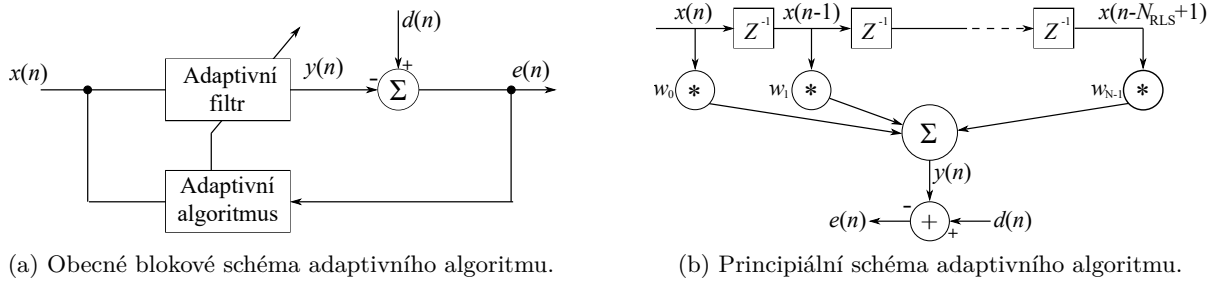
5.3 Metoda založená na rekurzivní optimální adaptaci

Pro popis adaptivního algoritmu RLS je potřeba si nejdříve objasnit základní principy adaptivního filtrování. Obrázek 13a zobrazuje obecné blokové schéma adaptivního algoritmu a obrázek 13b poté znázorňuje principiální schéma adaptivního algoritmu, kde $x(n)$ je vstupní signál, $y(n)$ je výstupní signál, $d(n)$ je požadovaný výstup, $e(n)$ je stanovená chyba mezi požadovaným a reálným výstupem adaptivního algoritmu, w_i značí koeficienty vah, z^{-1} je zpoždění a N_{RLS} je řád filtru [134]. Chyba $e(n)$ mezi požadovaným výstupem $d(n)$ a reálným výstupem $y(n)$ adaptivního algoritmu se vypočítá pomocí rovnice (31). Adaptivní algoritmus se snaží upravit koeficienty filtru za účelem dosažení co nejvíce korelujícího výstupu jako je požadovaný výstup. Optimalizování chybové funkce se provádí pomocí statistického nebo deterministického přístupu. Statistický způsob využívá hlavně LMS algoritmus, který potřebuje větší množství měření pro vypočítání statistiky. Deterministický způsob využívá právě RLS algoritmus, který vypočítává charakteristiky pomocí velkého množství vzorků [135, 136].

$$e(n) = d(n) - y(n). \quad (31)$$

Algoritmus RLS je založen na rekurzivním stanovení váhových koeficientů, teorii KF, časovém průměrování a také na LMS algoritmu. Výhodou tohoto algoritmu je, že využívá hodnoty

předchozích odhadů chyb a má velmi vysoký výkon v časově proměnných prostředích. Nevýhodou poté je, že má vyšší výpočetní náročnost a má problémy se stabilitou. Jeho snahou je minimalizovat výsledek účelové funkce ξ , viz rovnice (32), kde n představuje vnější časový index (značící počet posledních hodnot) a k značí vnitřní časový index. Požadovaný výstup p lze vyjádřit pomocí rovnice (33), kde λ_{RLS} značí faktor zapomínání pohybující se v intervalu $\langle 0,1 \rangle$. Nejčastěji se pohybuje hodnota faktoru zapomínání v rozmezí 0,95 až 1. Faktor zapomínání λ_{RLS} slouží k zapomínání předešlých hodnot. Je žádoucí udělat kompromis mezi snahou dosáhnout konvergence parametrů pomocí $\lambda_{\text{RLS}} = 1$ a mezi možností sledovat citlivost algoritmu na měnící se parametry pomocí $\lambda_{\text{RLS}} < 1$. Ideálním řešením problému je využití proměnlivého faktoru zapomínání [135, 136, 137].



Obrázek 13: Schémata adaptivního algoritmu.

$$\xi(n) = \sum_{k=1}^n p_n(k) e_n^2(k). \quad (32)$$

$$p_n(k) = \lambda_{\text{RLS}}^{n-k}. \quad (33)$$

Z rovnice (32) je zřejmé, že v určitém čase n je nutné mít k dispozici všechny hodnoty získané od zahájení RLS algoritmu. To znamená, že s přibývajícím časem se zvyšuje počet zpracovávaných hodnot, a tudíž je RLS algoritmus velice náročný na paměť. Ke snížení výpočetní náročnosti se využívá řád filtru N_{RLS} , který značí konečný počet zpracovávaných předchozích hodnot [135, 138].

Odvozením rovnice (31) pro výpočet chyby mezi požadovaným a reálným výstupem adaptivního algoritmu lze získat rovnici (34), která vznikla aplikací proměnlivosti v čase adaptivních filtrů RLS algoritmu. Reálný výstup RLS algoritmu $y_n(k)$ značí výstup FIR filtru v n daným současným vektorem vah $\vec{w}(n)$ a vstupujícím vektorem předešlého času k . Vektor $\vec{x}(k)$ značí vstupní signál. Vektor $\vec{w}(n)$ je jediná část rovnice, kterou lze měnit za účelem minimalizování chyby $e(k)$ [135, 138].

$$e(k) = d(k) - y_n(k) = d(k) - \vec{w}^T(n) \vec{x}(k). \quad (34)$$

Pokud by se použila matice $\mathbf{X}(n)$, která by byla tvořena předešlým vstupním vektorem v čase od n až do aktuálního stavu, mohl by být zápis reálného výstupu RLS algoritmu $y(k)$ zapsán pomocí rovnice (35) [135].

$$y(n) = \mathbf{X}^T(n) \vec{w}(n). \quad (35)$$

Následně lze využít rovnice (36) k popisu účelové funkce $\xi(n)$ s využitím diagonální matice $\tilde{\lambda}(n)$, která obsahuje na své diagonále váhové koeficientu. Diagonální matice $\tilde{\lambda}(n)$ je vyjádřena v rovnici (37) [135].

$$\xi(n) = \sum_{k=1}^n \lambda_{\text{RLS}}^{n-k}(k) e_n^2(k) = \vec{e}^T(n) \tilde{\lambda}(n) \vec{e}(n). \quad (36)$$

$$\tilde{\lambda}(n) = \begin{bmatrix} \lambda_{\text{RLS}}^{n-1} & 0 & 0 & \cdots & 0 \\ 0 & \lambda_{\text{RLS}}^{n-2} & 0 & \cdots & 0 \\ 0 & 0 & \lambda_{\text{RLS}}^{n-3} & \cdots & 0 \\ \cdots & \cdots & \cdots & \cdots & \cdots \\ 0 & 0 & 0 & \cdots & 1 \end{bmatrix}. \quad (37)$$

Nyní je možné provést hlubší úpravy účelové funkce, viz rovnice (38), (39) a (40) [135].

$$\xi(n) = \vec{d}^T \tilde{\lambda} \vec{d} - \vec{d}^T \tilde{\lambda} \vec{y} - \vec{y}^T \tilde{\lambda} \vec{d} + \vec{y}^T \tilde{\lambda} \vec{y} = \vec{d}^T \tilde{\lambda} \vec{d} - 2\vec{\theta}_{\lambda_{\text{RLS}}}^T \vec{w} + \vec{w}^T \tilde{\Psi}_{\lambda_{\text{RLS}}} \vec{w}. \quad (38)$$

$$\tilde{\Psi}_{\lambda_{\text{RLS}}}(n) = \mathbf{X}(n) \tilde{\lambda}(n) \mathbf{X}^T(n). \quad (39)$$

$$\tilde{\theta}_{\lambda_{\text{RLS}}}(n) = \mathbf{X}(n) \tilde{\lambda}(n) \vec{d}(n). \quad (40)$$

Gradient zápisu účelové funkce je možné odvodit k dosažení rovnice (41) a (42). Pokud by byl výsledek roven nule, šlo by stanovit koeficienty filtru $\vec{w}(n)$ k dosažení minima účelové funkce [135].

$$\tilde{\Psi}_{\lambda_{\text{RLS}}}(n) \vec{w}(n) = \tilde{\theta}_{\lambda_{\text{RLS}}}(n). \quad (41)$$

$$\vec{w}(n) = \tilde{\Psi}_{\lambda_{\text{RLS}}}^{-1}(n) \tilde{\theta}_{\lambda_{\text{RLS}}}(n). \quad (42)$$

Rekurzivní tvar matice $\tilde{\Psi}_{\lambda_{\text{RLS}}}^{-1}(n)$ je dán pomocí rovnice (43), kde vektor $\vec{k}(n)$ značí zisk a slouží k jednoduššímu stanovení rovnice, viz rovnice (44) [135].

$$\begin{aligned}\tilde{\Psi}_{\lambda_{\text{RLS}}}^{-1}(n) &= \lambda_{\text{RLS}} \tilde{\Psi}_{\lambda_{\text{RLS}}}^{-1}(n-1) + \vec{x}(n) \vec{x}^{\text{T}}(n) = \\ &= \lambda_{\text{RLS}}^{-1} (\tilde{\Psi}_{\lambda_{\text{RLS}}}^{-1}(n-1) - \vec{k}(n) \vec{x}^{\text{T}}(n) \tilde{\Psi}_{\lambda_{\text{RLS}}}^{-1}(n-1)).\end{aligned}\quad (43)$$

$$\vec{k}(n) = \frac{\lambda_{\text{RLS}}^{-1} \tilde{\Psi}_{\lambda_{\text{RLS}}}^{-1}(n-1) \vec{x}(n)}{1 + \lambda_{\text{RLS}}^{-1} \vec{x}^{\text{T}}(n) \tilde{\Psi}_{\lambda_{\text{RLS}}}^{-1}(n-1) \vec{x}(n)} = \tilde{\Psi}_{\lambda_{\text{RLS}}}^{-1}(n) \vec{x}(n).\quad (44)$$

Rekurzivní forma $\tilde{\theta}_{\lambda_{\text{RLS}}}(n)$ je nápomocná k dosažení výsledných rovnic (45), (46) a (47) pro stanovení aktuálního váhového vektoru popsaného adaptivního RLS algoritmu [135].

$$\tilde{\theta}_{\lambda_{\text{RLS}}}(n) = \lambda_{\text{RLS}} \tilde{\theta}_{\lambda_{\text{RLS}}}(n-1) + \vec{x}(n) \vec{d}(n).\quad (45)$$

$$\vec{w}(n) = \tilde{\Psi}_{\lambda_{\text{RLS}}}^{-1}(n) \tilde{\theta}_{\lambda_{\text{RLS}}}(n) = \vec{w}(n-1) + \vec{k}(n) \vec{e}_{n-1}(n).\quad (46)$$

$$\vec{e}_{n-1}(n) = d(n) - \vec{w}^{\text{T}}(n-1) \vec{x}(n).\quad (47)$$

Tímto bylo provedeno základní matematické odvození RLS algoritmu. Tento algoritmus provádí v každé iteraci cyklu aktualizaci aktuálních proměnných na základě stavu v minulé iteraci. Při implementaci RLS algoritmu je možné snížit výpočetní náročnost (mimo snížení řádu filtru) vynecháním kroku inverzní matice, jejíž výpočet není v praxi nezbytný. Další možností je zavedení rychlého transversálního filtru, který je schopen razantně snížit výpočetní náročnost, a zároveň ponechat stejnou rychlost konvergence. Následně je možné popsat přímou implementaci RLS algoritmu krok po kroku vzhledem k matematickému odvození. V prvním kroku je proveden výpočet výstupu filtru pomocí vstupního vektoru současné iterace a pomocí vah filtru získaných během předešlé iteraci, viz rovnice (48) [135, 136].

$$\vec{y}_{n-1}(n) = \vec{w}^{\text{T}}(n-1) \vec{x}(n).\quad (48)$$

Ve druhém kroku se provede výpočet středního vektoru zisků pomocí rovnice (49) a (50) [135, 136].

$$\vec{u}(n) = \tilde{\Psi}_{\lambda_{\text{RLS}}}^{-1}(n-1) \vec{x}(n).\quad (49)$$

$$\vec{k}(n) = \frac{1}{\lambda_{\text{RLS}} + \vec{x}^{\text{T}}(n) \vec{u}(n)} \vec{u}(n).\quad (50)$$

Třetím krokem je vypočtena rovnice (51), která stanoví hodnotu chyby odhadu [135, 136].

$$\vec{e}_{n-1}(n) = d(n) - \vec{y}_{n-1}(n).\quad (51)$$

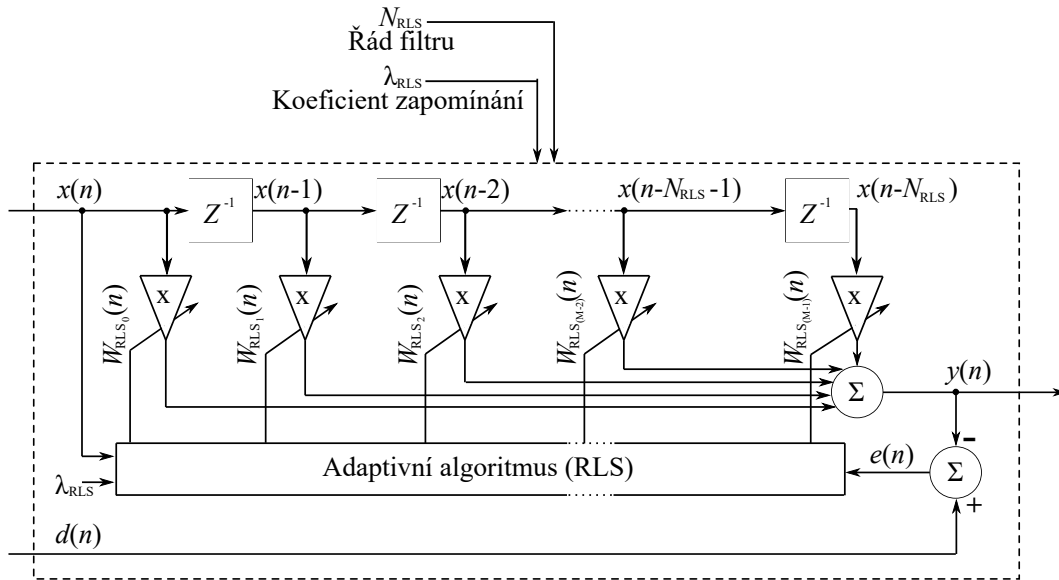
V následujících kroku je provedena aktualizace vektoru vah $\vec{w}(n)$ pomocí hodnoty chyby odhadu a pomocí vektorů zisků, viz rovnice (52) [135, 136].

$$\vec{w}(n) = \vec{w}^T(n-1) + \vec{k}(n)\vec{e}_{n-1}(n). \quad (52)$$

V posledním kroku se provede výpočet inverzní matice, viz rovnice (53), a je ukončen výběr vzoru z trénovací množiny [135, 136].

$$\tilde{\Psi}_{\lambda_{\text{RLS}}}^{-1}(n) = \lambda_{\text{RLS}}^{-1}\tilde{\Psi}_{\lambda_{\text{RLS}}}^{-1}(n-1) - \vec{k}(n)[\vec{x}^T(n)\tilde{\Psi}_{\lambda_{\text{RLS}}}^{-1}(n-1)]. \quad (53)$$

Obrázek 14 znázorňuje blokové schéma funkce adaptivního RLS algoritmu včetně parametrů, které je možné nastavovat [137]. Parametr λ_{RLS} znázorňuje faktor zapomínání a N_{RLS} značí řád filtru.



Obrázek 14: Principiální schéma funkce algoritmu RLS.

5.4 Adaptivní neuro-fuzzy inferenční systém

Jedná se o prakticky nejčastěji používanou adaptivní metodu k extrakci fEKG signálu, kterou vyvinul ve své práci Jang v roce 1993 [139]. Tato adaptivní metoda patří mezi softcomputingové metody, což jsou metody založené na analytických metodách, booleovské logice, ostré klasifikaci a deterministickém prohledávání. U metody ANFIS je možné často se setkat s označením jako hybridní adaptivní metoda, protože kombinuje fuzzy inferenční systém typu Takagi-Sugeno (fuzzy logiku) a učící metodu dopředné neuronové sítě. Jedná se tudíž o velice výkonnou metodu využívající výhod fuzzy expertních systémů (možnost práce s nepřesnými daty) a neuronových sítí (učení z okolí). Metoda ANFIS může navíc pracovat s učícím algoritmem tvořeným pouze metodou zpětného šíření (backpropagation) nebo tvořenou kombinací metody zpětného šíření

a LMS algoritmem. Pro správné pochopení metody ANFIS je potřeba popsat základní informace o fuzzy expertních systémech a neuronových sítích [135, 140, 141, 142].

5.4.1 Fuzzy expertní systémy

Pojem fuzzy se v češtině dá přeložit jako neostrý, nejasný, nepřesný nebo také neurčitý (vágní). Zadeh v roce 1965 [143] poprvé představil ve své studii fuzzy logiku, která je základním stavebním kamenem všech fuzzy expertních systémů a využívá aproximace výsledku s využitím neurčitosti. Tyto systémy odráží způsob řešení určité úlohy, kterou by řešil expert na danou problematiku. Rozdíl mezi tradiční logikou a fuzzy logikou je, že tradiční logika pracuje s jednoznačnými výrazy booleovské logiky (pravda pomocí logické 1 a nepravda pomocí logické 0) a fuzzy logika využívá velkého množství neurčitostí výroku, jako je zcela nepravda, asi nepravda, asi pravda, zcela pravda, a podobně. Při práci s fuzzy logikou se využívá teorie fuzzy množiny, kdy určitý popisovaný prvek či jev x může do fuzzy množiny patřit s určitou mírou příslušnosti $\mu_{\text{ANF}_A}(x)$ v uzavřeném intervalu $\langle 0,1 \rangle$. Pokud prvek x do fuzzy množiny A zcela patří je míra příslušnosti $\mu_{\text{ANF}_A}(x) = 1$, a když prvek x do fuzzy množiny A zcela nepatří je míra příslušnosti $\mu_{\text{ANF}_A}(x) = 0$. Jeden prvek může patřit částečně do jedné fuzzy množiny s určitou mírou příslušnosti (má hodnotu v rozmezí 0 až 1), a zároveň do jiné fuzzy množiny s určitou mírou příslušnosti [135, 144, 145].

Funkce příslušnosti μ_{ANF_A} mohou mít tvary sigmoidní funkce, zvonové funkce, Gaussovy funkce, a podobně. V praxi se velice často využívá aproximovaných tvarů lomenými přímkami pro jednodušší matematický popis. Například se jedná o funkce příslušnosti tvaru lichoběžníkové funkce Π , trojúhelníkové funkce \wedge , funkce L a funkce Γ [135, 144, 145].

Další důležitou součástí fuzzy logiky je fuzzifikace a defuzzifikace. Při fuzzifikaci se jedná o zápis ostré hodnoty pomocí fuzzy vyjádření začleněním všech mír příslušnosti do fuzzy množin. K tomu slouží jazyková proměnná $T(X)$, kde X může být například celkový výkon a jazyková proměnná může obsahovat například jazykové hodnoty $T(X) = \{\text{malý střední, vysoký}\}$ vyjádřené určitými funkcemi příslušnosti. Jazykovou hodnotu je možné vyjádřit pomocí $LP = (X, T(X), U)$, kde U je univerzum (množina hodnot, kterých nabývají prvky určité jazykové hodnoty). Určitá ostrá hodnota celkového výkonu poté může například patřit do fuzzy množiny popisující jazykovou hodnotu střední s mírou příslušnosti 0,4 a do fuzzy množiny popisující jazykovou hodnotu vysoký s mírou příslušnosti 0,6 [135, 144, 145].

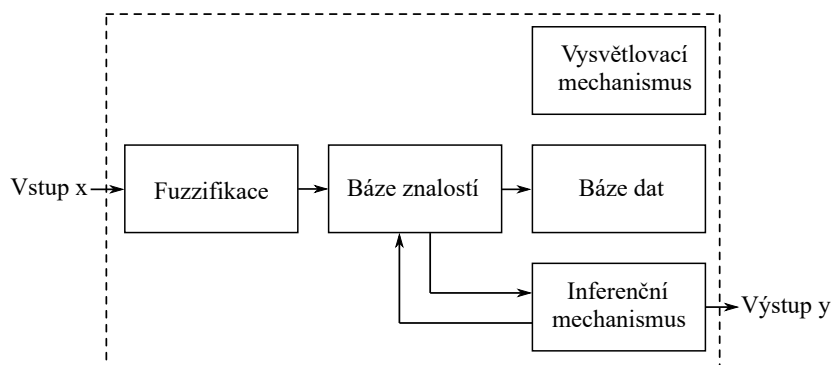
Fuzzy expertní systém využívá několik jazykových proměnných a po fuzzifikaci jednotlivých zadaných ostrých hodnot provede fuzzy expertní systém pomocí fuzzy pravidel defuzzifikaci. Defuzzifikace provádí převod fuzzy odpovědi na číselnou hodnotu. Při použití 3 vstupních jazykových proměnných, kdy každá obsahuje 3 jazykové hodnoty, obsahuje fuzzy expertní systém 27 pravidel pro pokrytí všech možných kombinací jazykových hodnot. Fuzzy pravidla jsou zapísána obvykle formou JESTLIŽE (IF, předpoklad, antecedent) - PAK (THEN, důsledek, konsekvence) pravidel. Všechna použitá JESTLIŽE-PAK pravidla se nazývají jako celek báze pravidel. Na určitou podmínku (vstupní ostré hodnoty) fuzzy expertní systém vyvodí určitou odpověď

(výstup). Najednou může být aktivních více pravidel, protože každá ostrá hodnota patří s určitými mírami příslušnosti do daných fuzzy množin. Čím více je aktivních fuzzy pravidel, tím lépe pro fuzzy expertní systém [135, 144, 145].

Existují 2 základní typy fuzzy inferenčních systému pracujících pomocí znalostních pravidel. Jedná se o fuzzy inferenční systémy typu Mamdani a Takagi-Sugeno. Již bylo zmíněno, že metoda ANFIS využívá fuzzy inferenční systém typu Takagi-Sugeno, proto bude popsán pouze tento typ fuzzy inferenčního systému. Zápis znalostních pravidel pro Sugenuv model lze vidět v rovnici (54), kde je zřejmé, že hodnota konsekventu y je dána ostrou hodnotou stanovenou pomocí lineární funkce (pomocí polynomů) proměnných z antecedentu. Lze vidět, že aproximace prochází R lineárními plochami a R pravidly. Na základě stupně polynomu je následně Sugenuv model označován jako Sugenuv model nultého řádu, prvního řádu, a podobně [135, 144, 145].

$$\begin{aligned}
 R_R : \text{JESTLIŽE } (x_1 \text{ je } A_{R1}) \text{ a } (x_2 \text{ je } A_{R2}) \text{ a } \dots \text{ a } (x_n \text{ je } A_{Rn}) \\
 \text{PAK } y_R = k_{0R} + k_{R1}x_1 + k_{R2}x_2 + \dots + k_{Rn}x_n.
 \end{aligned}
 \tag{54}$$

Na obrázku 15 lze vidět schéma popsaného Sugenuva modelu. První blok za vstupem je fuzzifikace, kde tedy dojde k zařazení prvku na základě míry příslušnosti $\mu_{ANF_A}(x)$ do fuzzy množin. Následuje báze znalostí obsahující JESTLIŽE-PAK podmínky Sugenuva modelu, viz rovnice (54). Dalším blokem je báze dat, která obsahuje jazykové hodnoty jednotlivých vstupních a výstupních jazykových proměnných. Inferenční mechanismus pomocí báze znalostí vypočítává výstup a vysvětlovací mechanismus slouží k zobrazení aktivních pravidel [135, 144, 145].



Obrázek 15: Blokové schéma fuzzy inferenčního systému typu Takagi-Sugeno.


5.4.2 Neuronové sítě

Neuronové sítě vycházejí z funkce neuronové soustavy živých organismů, jejichž základem je síť neuronů sestávající z velkého množství mezi sebou propojených neuronů. Jednotlivé neurony reagují na podněty (vstupy) určitou reakcí, která je přivedena na vstupy dalších neuronů. Takto si mezi sebou jednotlivé neurony předávají a uchovávají informace. Základem umělé neuronové sítě jsou jednoduché procesy mající schopnost upravovat své váhy, čímž předpovídají další procesy ze známých dat. To znamená, že mají schopnost se učit, adaptovat se a předvídat další

kroky. Neuron živého organismu se skládá z těla (soma), krátkých vstupních výběžků (dendrity) a jednoho dlouhého výstupního výběžku (axon). Spojení jednotlivých neuronů se nazývá synapse. Velkou výhodou neuronových sítí je, že velká část neuronů pracuje současně (paralelně), což snižuje dobu výpočtu ideálního nastavení synaptických vah [135, 146, 147].

Na obrázku 16 lze vidět schématický model nejjednoduššího zapojení neuronové sítě pomocí jednoho formálního neuronu (perceptron) [134]. Perceptron patří mezi dopřednou neuronovou síť schopnou najít výsledek pro lineárně oddělitelné situace. Rovnice (55) poté matematicky popisuje aktivační funkci perceptronu, kde w_i jsou synaptické váhy upravující výstupní signál neuronů, x_i jsou výstupní signály neuronů vstupující do popisovaného neuronu a θ je prahová hodnota neuronu. Na výstup neuronu y má zásadní vliv zvolená přenosová funkce f a nastavení vah vektoru \vec{w} obsahující jednotlivé synaptické váhy $w(n)$. Adaptace vektoru synaptických vah \vec{w} značí učení neuronu [135, 146, 147].

$$y = \text{Sgn} \left(\sum_{i=1}^n w_i x_i - \theta \right). \quad (55)$$




Obrázek 16: Schématický model funkčního neuronu (perceptron).

Spojením několika perceptronů dochází ke vzniku vícevrstvé neuronové sítě schopné oddělit od sebe lineárně neoddělitelné situace. Vlastností vícevrstevných neuronových sítí je, že se skládají z jedné vstupní vrstvy, jedné nebo více skrytých vrstev a jedné výstupní vrstvy. Obrázek 17 zobrazuje vícevrstvou neuronovou síť, kde k značí počet neuronů vstupní vrstvy, m značí počet neuronů skryté vrstvy a n značí počet neuronů výstupní vrstvy [134]. Neurony nižší vrstvy jsou u vícevrstvé neuronové sítě propojeny se všemi neurony vyšší vrstvy. Při zpracování řešení využívají nejčastěji vícevrstvé neuronové sítě při adaptaci synaptických vah metody zpětného šíření, což je metoda využívána právě u metody ANFIS [135, 146, 147].

Nastavováním synaptických vah (adaptací) na vstupu neuronu se provádí učení neuronové sítě. Učení může probíhat buď s učitelem nebo bez učitele. Učení s učitelem probíhá pomocí pravidelného předložení testovacích dat, kdy je výstup neuronové sítě s testovacími daty srovnáván. Pokud dojde k odchylce mezi neuronovou sítí a testovacími daty, tak vznikne zpětná vazba a dochází k vhodné adaptaci jednotlivých synaptických vah. Adaptace synaptických vah

probíhá v jednotlivých iteracích, dokud se nesníží hodnota chyby mezi výstupem neuronové sítě a testovacími daty pod stanovený limit. Učení bez učitele nevyužívá testovacích dat, ale testuje výstup neuronové sítě přímo na zpracovávaných datech, kdy hledá statisticky relevantní rysy. Pomocí zjištěných statisticky relevantních rysů se provádí samoorganizace sítě [135, 146, 147].



Obrázek 17: Vícevrstvá neuronová síť.

Již bylo zmíněno, že pro adaptaci synaptických vah se u vícevrstevných neuronových sítí nejčastěji využívá metody zpětného šíření. Tato metoda pracuje pomocí učení s učitelem, kdy postupně dochází k úpravám synaptických vah od výstupní vrstvy zpětně ke vstupní vrstvě. Metoda je založena na několika krocích. V prvním kroku jsou excitovány neurony vstupní vrstvy na požadovanou úroveň v intervalu $\langle 0,1 \rangle$ pomocí vektoru excitací vstupní vrstvy \vec{i} trénovací množiny. Poté se provede dopředné šíření, kdy jsou jednotlivé excitace neuronů přivedeny k neuronům vyšší vrstvy a tyto excitace jsou upraveny (zesíleny či zeslabeny) koeficienty synaptických vah. Jednotlivé neurony aktuálních vrstev provedou sumaci upravených přivedených excitací za účelem provedení své excitace na úroveň danou aktivační funkcí neuronu. Takhle to probíhá od nižších vrstev až k nejvyšší vrstvě, kde jsou obdrženy výstupní excitační stavy. Následně je provedeno srovnání výstupu neuronové sítě s vektorem excitací výstupní vrstvy \vec{o} trénovací množiny a vypočte se jejich rozdíl definovaný jako chyba neuronové sítě. Chyba neuronové sítě se poté vrací v určitém poměru formou úpravy synaptických vah mezi jednotlivými vrstvami od nejvyšší vrstvy neuronové sítě k nejnižší vrstvě neuronové sítě. Vždy je snahou dosáhnout v příštím kroku nižší chyby odezvy neuronové sítě. Tímto způsobem to proběhne pro všechny vektory trénovací množiny, a nakonec se vypočte celková chyba. Pokud je chyba vyšší než požadovaná, je celý popsáný proces opakován. Metoda zpětného šíření je ukončena buď při dosažení nižší chyby odezvy neuronové sítě, než je stanovený limit, nebo při překročení stanoveného maximálního počtu iterací. Při použití této metody musí být aktivační funkce spojitá a neklesající. Spojitý perceptron lze vyjádřit pomocí rovnice (56) a (57), kde z značí vnitřní potenciál neuronu a λ značí strmost sigmoidu [135, 146, 147].

$$y = \frac{1}{1 + e^{-\lambda z}}. \quad (56)$$

$$z = \sum_{i=0}^n w_i x_i. \quad (57)$$

Hledání chyby metodou zpětného šíření lze zapsat pomocí rovnice (58), kde y_j značí skutečnou odezvu neuronu j výstupní vrstvy neuronové sítě, o_j značí požadovanou odezvu neuronu j výstupní vrstvy neuronové sítě dle trénovací množiny, p je celkový počet vzorů trénovací množiny a m udává počet neuronů výstupní vrstvy neuronové sítě. Úpravu synaptických vah mezi jednotlivými neurony lze následně definovat rovnicí (59), kde η je koeficient učení, μ_{NS} je koeficient vlivu změny vah po předešlém stavu a Δw_i značí změnu synaptické váhy po předešlém stavu. Pravá část rovnice (59) udává vedlejší informace o možnostech urychlení konvergence sítě a levá část této rovnice značí podstatu neuronové sítě. Když koeficient vlivu změny vah μ_{NS} je roven 0, tak to značí, že není důležitý předchozí stav a synaptické váhy jsou vypočteny aktuálním krokem. V opačném případě, kdy koeficient vlivu změny vah μ_{NS} je roven 1, tak to znamená, že neuronová síť příliš bere zřetel na předchozí stav a dochází k pomalé adaptaci synaptických vah. Jestliže je výsledek derivace velká kladná hodnota, tak to značí potřebu snížit hodnoty synaptických vah, jinak by i malé zvýšení hodnoty mělo za vliv velkou chybu odezvy neuronové sítě. V opačném případě, kdy by výsledek derivace byla malá záporná hodnota, tak by to znamenalo potřebu zvýšit hodnoty synaptických vah. Velice důležitým parametrem je koeficient učení η , který čím větší bude mít hodnotu, tím větší bude změna odezvy neuronové sítě. Je potřeba opatrně volit jeho velikost, aby nedošlo k přeučení neuronové sítě [135, 146, 147, 148].

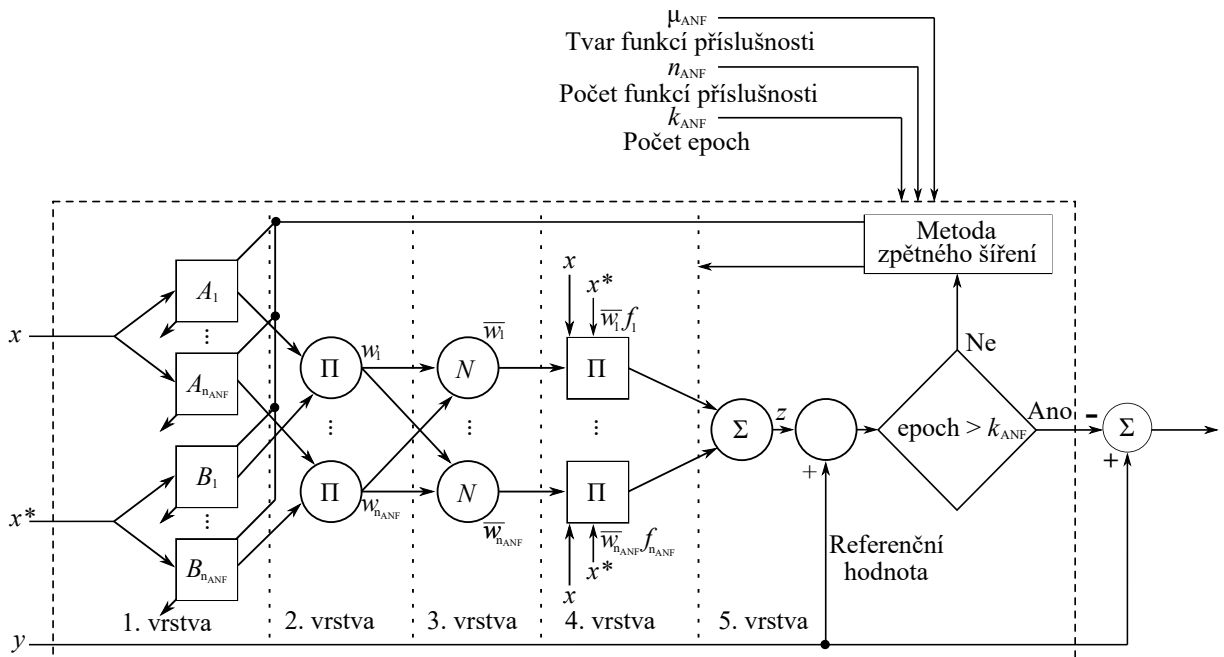
$$E = \frac{1}{2} \sum_{i=1}^p \sum_{j=1}^m (y_j - o_j)_i^2. \quad (58)$$

$$\Delta w_i = -\eta \frac{\partial E}{\partial w_i} + \mu_{NS} \Delta w_i. \quad (59)$$

5.4.3 Architektura adaptivního neuro-fuzzy inferenčního systému

Nyní je možné přejít k popisu metody ANFIS. Jak již bylo zmíněno, metoda ANFIS se projevuje jako fuzzy expertní systém realizovaný vícevrstvou dopřednou neuronovou sítí. Důležité je, aby metoda ANFIS obsahovala Sugenuv model nultého nebo prvního řádu. Dále je potřeba, aby systém měl pouze jeden výstup, neměl sdílená pravidla, výstupní funkce příslušnosti byly stejného typu (lineární nebo konstantní), a aby počet pravidel koreloval s počtem funkcí příslušnosti. Na obrázku 18 lze vidět ukázkou základní architektury metody ANFIS se vstupy x , x^* , a y a jedním výstupem z . Schéma na obrázku je modifikováno na základě využití metody ANFIS při zpracování fEKG signálu. Z tohoto důvodu obrázek obsahuje vstup x , který při zpracování fEKG signálu představuje mEKG signál, a vstup x^* , který při zpracování fEKG signálu představuje

o jeden vzorek zpožděný mEKG signál. Vstup y při zpracování fEKG signálu představuje aEKG signál sloužící nejdříve jako referenční hodnota a následně k odečtení odhadnutého signálu. Použití vstupů x a x^* napomáhá k lepšímu odhadnutí mateřské komponenty obsažené v aEKG signálu, což je potřeba k odečtení a následnému obdržení fEKG signálu. U metody ANFIS lze nastavit tvar funkcí příslušnosti μ_{ANF} , počet funkcí příslušnosti n_{ANF} a počet epoch k_{ANF} [141, 142]. Pro popis uvažujme místo vstupů x a x^* dva obecné vstupy x a y a jeden výstup z . Z obrázku je patrné, že architektura metody ANFIS se skládá z 5 dopředných vrstev. Bázi pravidel architektury metody ANFIS zobrazené na obrázku 18 lze popsat pomocí dvou JESTLIŽE-PAK pravidel, viz rovnice (60) a (61), odvozených od rovnice (54) [135, 140, 141, 142, 149].



Obrázek 18: Architektura metody ANFIS se dvěma vstupy a jedním výstupem.

$$R_1 : \text{JESTLIŽE } x \text{ je } A_1 \text{ a } y \text{ je } B_1, \text{ PAK } z_1 = p_1X + q_1Y + r_1. \quad (60)$$

$$R_2 : \text{JESTLIŽE } x \text{ je } A_2 \text{ a } y \text{ je } B_2, \text{ PAK } z_2 = p_2X + q_2Y + r_2. \quad (61)$$

V 1. vrstvě, která je adaptivní a označována jako vstupní vrstva, se provádí fuzzifikace vstupních jazykových proměnných, které představují jednotlivé uzly. Funkce pro jednotlivé uzly lze zapsat pomocí rovnice (62) a rovnice (63), kde x a y jsou vstupní jazykové proměnné a $\mu_{\text{ANF}_{A_i}}$ a $\mu_{\text{ANF}_{B_i}}$ představují míry příslušnosti jazykových hodnot A_i a B_i . Neuronová síť svým učení v první vrstvě adaptuje parametry funkcí příslušnosti představujících antecedent [135, 140, 141, 142].

$$o_{1,i} = \mu_{\text{ANF}_{A_i}}(x). \quad (62)$$

$$o_{1,i} = \mu_{\text{ANF}_{B_i}}(y). \quad (63)$$

Ve 2. vrstvě, která se nazývá pravidlová vrstva, se provádí násobení výstupních signálů z 1. vrstvy za účelem stanovení vah w pravidel. Antecedent pravidel je složen z jazykových hodnot jazykových proměnných. Tato vrstva se tedy skládá pouze z neadaptivních uzlů představujících jednotlivá Takagi-Sugeno fuzzy pravidla. Váha jednotlivých pravidel je na výstupu 2. vrstvy a lze ji vypočítat pomocí rovnice (64), kde w_i značí sílu (váhu) pravidla, a i nabývá v tomto příkladě hodnot 1 a 2 [135, 140, 141, 142].

$$o_{2,i} = w_i = \mu_{\text{ANF}_{A_i}}(x) \cdot \mu_{\text{ANF}_{B_i}}(y). \quad (64)$$

Další vrstva představuje normalizační vrstvu složenou opět pouze z neadaptivních uzlů. Výstupem 3. vrstvy je poměr vah jednotlivých pravidel vůči součtu všech pravidel. Normalizovaná síla jednotlivých pravidel se vypočítá pomocí rovnice (65) [135, 140, 141, 142].

$$o_{3,i} = \bar{w}_i = \frac{w_i}{w_1 + w_2}. \quad (65)$$

Defuzzifikační vrstva (4. vrstva) využívá adaptivní uzly, které mají lineární nebo konstantní přenosovou funkci stanovenou konsekventem. Na 4. vrstvu jsou napojeny normalizační uzly, a zároveň jazykové proměnné x a y . Výpočet adaptivních uzlů 4. vrstvy se provede pomocí rovnice (66), kde p , q a r představují parametry konsekventu [135, 140, 141, 142].

$$o_{4,i} = \bar{w}_i f_i = \bar{w}_i \cdot z_i = \bar{w}_i(p_i x + q_i y + r_i). \quad (66)$$

Poslední 5. vrstvu představuje jeden neadaptivní uzel nazývaný jako sumační, který provádí výpočet rovnice (67) sloužící ke stanovení výstupu metody ANFIS [135, 140, 141, 142].

$$o_{5,i} = \sum_i \bar{w}_i f_i = \frac{\sum_i w_i f_i}{\sum_i w_i}. \quad (67)$$

Správná funkčnost metody ANFIS je velmi často provedena kombinací vhodně nastavených nelineárních parametrů 1. vrstvy metodou zpětného šíření a vhodně nastavených lineárních parametrů 4. vrstvy pomocí LMS algoritmu. Na výstupu metody ANFIS je vypočtena celková chyba mezi výstupem metody ANFIS a požadovaným výstupem. Program končí ve chvíli, kdy je dosaženo optimálně malé celkové chyby. Tato kombinace metody ANFIS pomocí metody zpětného šíření a LMS algoritmu obsahuje dopředný a zpětný chod [135, 140, 141].

Na začátku dopředného chodu jsou metodě ANFIS předány tréninkové vzory. Provede se výpočet výstupů prvních 3 vrstev a poté je proveden výpočet parametrů konsekventu 4. vrstvy algoritmem LMS. Výstup konsekventu Sugenoova modelu lze zapsat pomocí lineární funkce, viz rovnice (68) [135, 141].

$$\vec{z}_i = p_i x + q_i y + r_i. \quad (68)$$

Pomocí rovnice (69) lze zapsat množinu tréninkových vzorů obsahující vstupní a výstupní vektory, kde m je počet lineárních rovnic s parametry konsekventu p , q a r [135, 141].

$$\left\{ \begin{array}{l} \vec{z}(1) = \bar{w}_1(1)f_1(1) + \cdots + \bar{w}_n(1)f_n(1) \\ \vec{z}(2) = \bar{w}_1(2)f_1(2) + \cdots + \bar{w}_n(2)f_n(2) \\ \vdots \\ \vec{z}(m) = \bar{w}_1(m)f_1(m) + \cdots + \bar{w}_n(m)f_n(m) \end{array} \right\}. \quad (69)$$

Zjednodušený zápis množiny tréninkových vzorů lze vidět v rovnici (70), kde matici \mathbf{Z} lze zapsat pomocí rovnice (71), matici \mathbf{A} pomocí rovnice (72) a vektor \vec{k} neznámých parametrů konsekventu pomocí rovnice (73) [135, 141].

$$\mathbf{Z} = \mathbf{A} \cdot \vec{k}. \quad (70)$$

$$\mathbf{Z} = \begin{bmatrix} \vec{z}(1) \\ \vec{z}(2) \\ \vdots \\ \vec{z}(m) \end{bmatrix}. \quad (71)$$

$$\mathbf{A} = \begin{bmatrix} \bar{w}(1) & \bar{w}(1)x(1) & \bar{w}(1)y(1) & \cdots & \bar{w}_n(1) & \bar{w}_n(1)x(1) & \bar{w}_n(1)y(1) \\ \bar{w}(2) & \bar{w}(2)x(2) & \bar{w}(2)y(2) & \cdots & \bar{w}_n(2) & \bar{w}_n(2)x(2) & \bar{w}_n(2)y(2) \\ \vdots & \vdots & \vdots & \cdots & \vdots & \vdots & \vdots \\ \bar{w}(m) & \bar{w}(m)x(m) & \bar{w}(m)y(m) & \cdots & \bar{w}_n(m) & \bar{w}_n(m)x(m) & \bar{w}_n(m)y(m) \end{bmatrix}. \quad (72)$$

$$\vec{k} = [p_1 \quad q_1 \quad r_1 \quad p_2 \quad q_2 \quad r_2 \quad \cdots \quad p_n \quad q_n \quad r_n]^T. \quad (73)$$

Přeučení sítě nastává v případě, kdy je počet učících vzorů p trénovací množiny větší, než je počet neznámých konsekventů n . Jediným řešením této situace je využití algoritmu LMS, což vede ke snížení chyby pomocí pseudo-inverzní metody, viz rovnice (74) [135, 141].

$$\mathbf{k}^* = (\mathbf{A}^T \mathbf{A})^{-1} \mathbf{A}^T \mathbf{Z}. \quad (74)$$

Celková chyba mezi výstupem sítě a požadovaným výstupem je dána rovnicí (75) [135, 141].

$$\mathbf{e} = \mathbf{Z} - \mathbf{Z}_{\text{aktuální}}. \quad (75)$$

Zpětný chod metody ANFIS využívá metody zpětného šíření, která pomocí derivace složené funkce upravuje (adaptuje) parametry antecedentu. Při použití zvonové funkce příslušnosti ve výstupním uzlu sítě bude rovnice pro adaptaci parametrů dána rovnicí (76), kde η značí koeficient učení [135, 141]

$$\Delta a = -\eta \frac{\partial E}{\partial a} = -\eta \frac{\partial E}{\partial e} \cdot \frac{\partial e}{\partial \mathbf{Z}_{\text{aktuální}}} \cdot \frac{\partial \mathbf{Z}_{\text{aktuální}}}{\partial (\bar{w}_i f_i)} \cdot \frac{\partial (\bar{w}_i f_i)}{\partial \bar{w}_i} \cdot \frac{\partial \bar{w}_i}{\partial w_i} \cdot \frac{\partial w_i}{\partial w_{Ai}} \cdot \frac{\partial w_{Ai}}{\partial a}. \quad (76)$$

Hledání chyby metodou zpětného šíření lze odvodit pro tento příklad pomocí rovnice (77) [135, 141].

$$E = \frac{1}{2} e^2 = \frac{1}{2} (\mathbf{Z} - \mathbf{Z}_{\text{aktuální}})^2. \quad (77)$$

Po dosazení do rovnice (76) lze využít rovnice (78) a poté rovnice (79) [135, 141].

$$\Delta a = -\eta (\mathbf{Z} - \mathbf{Z}_{\text{aktuální}}) (-1) f_1 \cdot \frac{\bar{w}_i (1 - w_i)}{w_i} \cdot \frac{w_i}{w_{Ai}} \cdot \frac{\partial w_{Ai}}{w_a}. \quad (78)$$

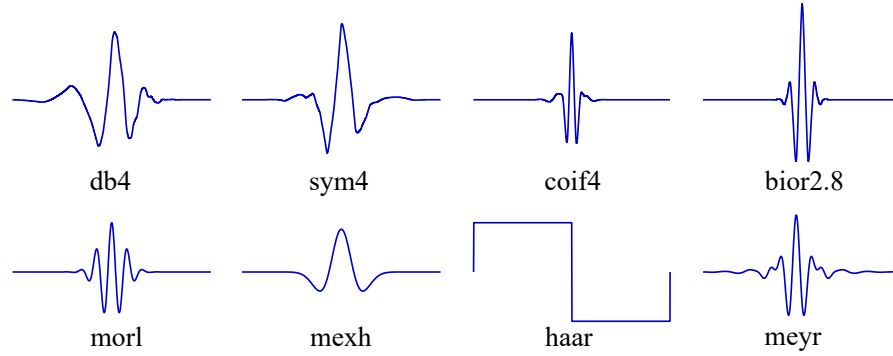
$$\Delta a = -\eta (\mathbf{Z} - \mathbf{Z}_{\text{aktuální}}) f_1 \bar{w}_i (1 - \bar{w}_i) \cdot \frac{1}{w_{Ai}} \cdot \frac{\partial w_{Ai}}{\partial a}. \quad (79)$$

Při použití zvonové funkce je obdržena výsledná rovnice (80) [135, 141].

$$\frac{\partial w_{Ai}}{\partial a} = \frac{1}{\left[1 + \left(\frac{x-a}{c}\right)^{2b}\right]^2} \cdot \frac{1}{e^{2b}} \cdot 2b \cdot (x-a)^{2b-1} \cdot (-1) = w_{Ai}^2 \cdot \frac{2b}{c} \cdot \left(\frac{x-a}{c}\right)^{2b-1}. \quad (80)$$

5.5 Vlnková transformace

Jedná se o velice podobný algoritmus jako je Fourierova transformace, ale její velkou výhodou je, že je velice efektivní při zpracování nestacionárních signálů a signálů obsahujících více komponent (jako je zpracování fEKG signálu). Základem WT je zvolení vhodného tvaru a následně šířky vlnky. Mezi základní typy vlnek patří například: Haar, Daubechies, Biorthogonal, Coiflet, Symlets, Morlet, Mexican Hat a Meyer, viz obrázek 19. Při zpracování fEKG signálu se velice často využívá vlnky typu Daubechies, Symlets a Coiflet [57, 58]. Jako nejvhodnější se jeví typ vlnky Daubechies, proto v této práci je zvolena tato vlnka při vyhlazování výsledného fEKG signálu. Vlnková transformace v podstatě provádí rozklad signálu (dekompozici) pomocí zvoleného typu a šířky mateřské vlnky Ψ_{WT} . Pro pomalu se měnící vlastnosti signálu, a tudíž pro nižší frekvence, je vhodné zvolit širší mateřskou vlnku. Naopak pro rychle se měnící vlastností, a tudíž pro vyšší frekvence, je vhodné zvolit užší mateřskou vlnku. Vlnková transformace se primárně dělí na CWT a DWT [57, 58, 150, 151, 152].



Obrázek 19: Ukázka vybraných vlněk vygenerovaných v programu MATLAB.

5.5.1 Spojitá vlnková transformace

K popisu přímé CWT lze použít rovnici (81) a k popisu zpětné CWT lze použít rovnici (82), kde $f(t)$ je vstupní signál, $\Psi_{\text{WT}}^*\left(\frac{t-\tau}{s}\right)$ je komplexně sdružená funkce k $\Psi_{\text{WT}}\left(\frac{t-\tau}{s}\right)$, s je dilatační škálovací parametr udávající šířku vlnky, τ je translační škálovací parametr udávající polohu vlnky na časové ose a zlomek $\frac{1}{\sqrt{s}}$ provádí normalizaci energie mateřské vlnky v případě změny měřítko. Mateřskou vlnku lze popsat rovnici (83) a musí splňovat podmínky, že má finitní energii, nulovou střední hodnotu a $\int_{-\infty}^{\infty} \Psi_{\text{WT}}(t) dt = 0$. Vlastnostmi CWT jsou linearita, invariance vzhledem k posunutí a dilataci WT a derivování originálu WT [150, 151].

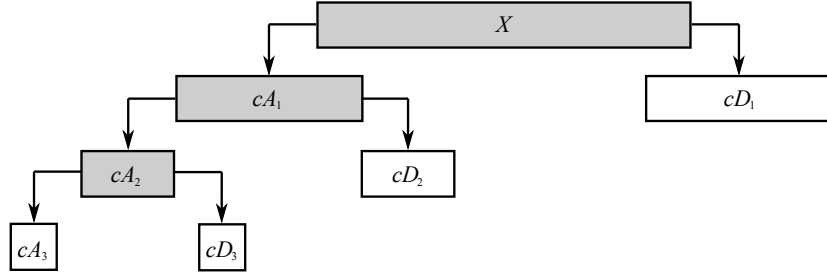
$$CWT(f) = F(s, \tau) = \hat{f}(s, \tau) = \frac{1}{\sqrt{s}} \int_{-\infty}^{\infty} f(t) \cdot \Psi_{\text{WT}}^*\left(\frac{t-\tau}{s}\right) dt. \quad (81)$$

$$CWT^{-1}(F) = f(t) = \frac{1}{\sqrt{s}} \int_{-\infty}^{\infty} \left(\int_{-\infty}^{\infty} F(s, \tau) \cdot \Psi_{\text{WT}}\left(\frac{t-\tau}{s}\right) ds \right) d\tau. \quad (82)$$

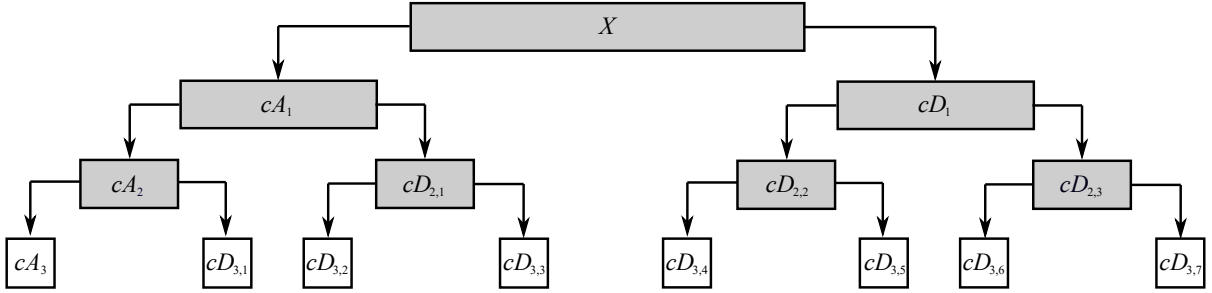
$$\Psi_{\text{WT}, \tau, s}(t) = \frac{1}{\sqrt{s}} \Psi_{\text{WT}}\left(\frac{t-\tau}{s}\right). \quad (83)$$

5.5.2 Diskrétní vlnková transformace

Při aplikování DWT je potřeba zvolit typ mateřské vlnky Ψ_{WT} a úroveň multirozkladu n_{WT} (víceúrovňové analýzy). V prvním stupni rozkladu se signál rozloží pomocí DP filtru na jednu aproximační složku cA (obsahující dolní polovinu frekvencí a poskytující celkový trend signálu) a pomocí HP filtru na jednu detailní složku cD (obsahující horní polovinu frekvencí a poskytující doplňující informace o jemnosti). Při druhém stupni rozkladu se rozloží aproximační složka signálu na další jednu aproximační složku a jednu detailní složku. Takhle to probíhá až do konečného zvoleného stupně rozkladu n_{WT} . Obrázek 20 zobrazuje popsaný rozklad signálu pomocí WT se stupněm rozkladu $n_{\text{WT}} = 3$. Kromě multirozkladu existuje také paketový rozklad (obrázek 21), který stejně jako multirozklad rozkládá aproximační složky, ale navíc stejně jako aproximační složky rozkládá i detailní složky [150, 151, 152].



Obrázek 20: Multirozklad signálu pomocí DWT se stupněm rozkladu 3.



Obrázek 21: Paketový rozklad signálu pomocí DWT se stupněm rozkladu 3.

Rovnice (84) slouží k popisu DWT, kde $\Psi_{\text{WT}_{j,k}}^*$ je komplexně sdružená funkce k dceřiné vlnce $\Psi_{\text{WT}_{j,k}}$. Dceřinou vlnku, která je dilatovaná a posunutá, lze popsat pomocí rovnice (85), kde j udává počet vlněk potřebných pro pokrytí mateřské vlnky a k udává pozici vlnky v čase [150, 151, 152].

$$DWT(f) = F(j, k) = \hat{f}(j, k) = \int_{-\infty}^{\infty} f(t) \cdot \Psi_{\text{WT}_{j,k}}^*(t) dt. \quad (84)$$

$$\Psi_{\text{WT}_{j,k}}(t) = 2^{\frac{j}{2}} \Psi_{\text{WT}}(2^j t - k). \quad (85)$$

Analýza signálu pomocí DWT, kdy se signál rozděluje na aproximační složky cA a detailní složky cD pomocí DP filtru a HP filtru, může být popsána pomocí rovnice (86) a (87), kde g a h jsou impulzní odezvy DP filtru a HP filtru [150, 151].

$$y_{\text{DP}}(k) = \sum_n f(n) \cdot g(2k - n). \quad (86)$$

$$y_{\text{HP}}(k) = \sum_n f(n) \cdot h(2k - n). \quad (87)$$

Aproximační složky cA mohou být definovány pomocí rovnice (88) a použitá vlnková funkce $\Psi_{\text{WT}_{j,k}}$ pomocí rovnice (89) [150, 151].

$$cA_{j,k} = \int f(t) \cdot \Psi_{\text{WT}_{j,k}}^*(t) dt. \quad (88)$$

$$\Psi_{\text{WT}_{j,k}} = \frac{1}{\sqrt{2^j}} \Psi_{\text{WT}} \left(\frac{t - k2^j}{\sqrt{2^j}} \right). \quad (89)$$

Obdobně lze popsat detailní složky cD pomocí rovnice (90) a použitou škálovací funkci $\Phi_{\text{WT}_{j,k}}$ pomocí rovnice (91) [150, 151].

$$cD_{j,k} = \int f(t) \cdot \Phi_{\text{WT}_{j,k}}^*(t) dt. \quad (90)$$

$$\Phi_{\text{WT}_{j,k}} = \frac{1}{\sqrt{2^j}} \Phi_{\text{WT}} \left(\frac{t - k2^j}{\sqrt{2^j}} \right). \quad (91)$$

Zpětná DWT obsahuje na svém vstupu signál c složený z poslední aproximační složky a ze všech detailních složek od nejvyššího stupně rozkladu po nejnižší, viz rovnice (92), kde n_{WT} značí zvolený stupeň rozkladu. Tento složený signál se pomocí prahování upraví před dokončením zpětné DTW. Jednotlivé posloupnosti jsou prodlouženy přidáním nul na pozice prvků s lichými indexy a následně se k provedení zpětné DWT aplikuje konvoluce s rekonstrukčními filtry. K výpočtu inverzní DWT slouží rovnice (93) [150, 151, 152].

$$c = cA_{n_{\text{WT}}} + cD_{n_{\text{WT}}} + cA_{n_{\text{WT}}-1} + \dots + cA_1. \quad (92)$$

$$DWT^{-1}(F) = f(t) = \sum_{j,k} c_{j,k} \cdot \Psi_{\text{WT}_{j,k}}(t). \quad (93)$$

5.5.3 Prahování

Před provedením zpětné DWT je potřeba provést prahování, aby měla provedená WT správnou účinnost. Prahováním se odstraňuje část šumu nulováním koeficientů. Koeficienty představující užitečnou část signálu se ponechávají nepoškozeny. K rozhodnutí, které koeficienty je potřeba nulovat, je potřeba stanovit hodnotu prahu na základě výpočtu směrodatné odchylky šumu σ_n pomocí mediánu Me (medián není ovlivněn vysokými hodnotami koeficientů fQRS komplexů), viz rovnice (94) [150, 151, 152, 153].

$$\sigma_{j,k} = \frac{Me|y_{j,k}|}{0,6745}. \quad (94)$$

Nejdříve lze prahování rozdělit na adaptivní a pevné prahování. Adaptivní prahování využívá výpočtu směrodatné odchylky šumu v plovoucím okně se zvolenou délkou l_{WT} . Pevné prahování vypočítává směrodatnou odchylku šumu celého záznamu se stanovením univerzálního, nebo empirického prahu λ_{WT} . Univerzální práh se vypočítá pomocí rovnice (95), kde n značí délku signálu, a většinou jsou jeho výsledky mnohem horší než při použití empirického prahu. Empirický práh, který se využívá pro pevné prahování i pro adaptivní prahování, se vypočítá pomocí rovnice (96), kde K_{WT} značí empirickou konstantu [150, 151, 152, 153].

$$\lambda_{WT_{j,k}} = \sigma_{j,k} \cdot \sqrt{2 \cdot \ln(n)}. \quad (95)$$

$$\lambda_{WT_{j,k}} = \sigma_{j,k} \cdot K_{WT}. \quad (96)$$


Dále je potřeba zvolit možnost tvrdého nebo měkkého prahování ρ . Při použití tvrdého prahování se koeficienty, které mají nižší hodnotu, než je hodnota prahu, vynulují. Koeficienty, které mají vyšší hodnotu, než je hodnota prahu, se ponechají nezměněny. Tento způsob prahování přináší riziko ponechání určitých koeficientů představujících šum. Měkké prahování přináší výhodu toho, že jsou koeficienty představující šum v signálu po zpětné rekonstrukci utlumeny. Nejprve se tedy provede, stejně jako u tvrdého prahování, vynulování koeficientů majících menší hodnotu, než je hodnota prahu. Poté se navíc zbylé koeficienty mající větší hodnotu, než je hodnota prahu, posunou o velikost prahu k nule. Nicméně je nevýhodou, že koeficienty představující užitečný signál mohou být utlumeny spolu s koeficienty šumu. Zápis pro tvrdé a měkké prahování lze vidět v rovnici (97) a (98) [150, 151, 152, 153].

$$\rho_{j,k}^{tvrdé}(c) = \begin{cases} c & |c| \geq \lambda_{WT}, \\ 0 & |c| < \lambda_{WT} \end{cases}. \quad (97)$$

$$\rho_{j,k}^{měkké}(c) = \begin{cases} c - \lambda_{WT} & |c| \geq \lambda_{WT}, \\ 0 & |c| < \lambda_{WT}, \\ c + \lambda_{WT} & |c| \leq -\lambda_{WT} \end{cases}. \quad (98)$$

Měkké prahování je následně provedeno pomocí rovnice (99), kde U značí zpracovávaná data a D provedení prahování před inverzní DWT, kde jsou koeficienty U upraveny dle zmíněného předpisu pro měkké prahování [154]. Jako ideální se jeví použití adaptivního prahování se zvolenou délkou okna l_{WT} a empirickou konstantou K_{WT} k výpočtu empirického prahu spolu s použitím měkkého prahování. Obrázek 22 zobrazuje blokové schéma implementace popsané DWT při použití zmíněného optimálního nastavení [150, 151, 152, 153].

$$D(U, \lambda_{WT}) = \text{sgn}(U) \max(0, |U| - \lambda_{WT}). \quad (99)$$



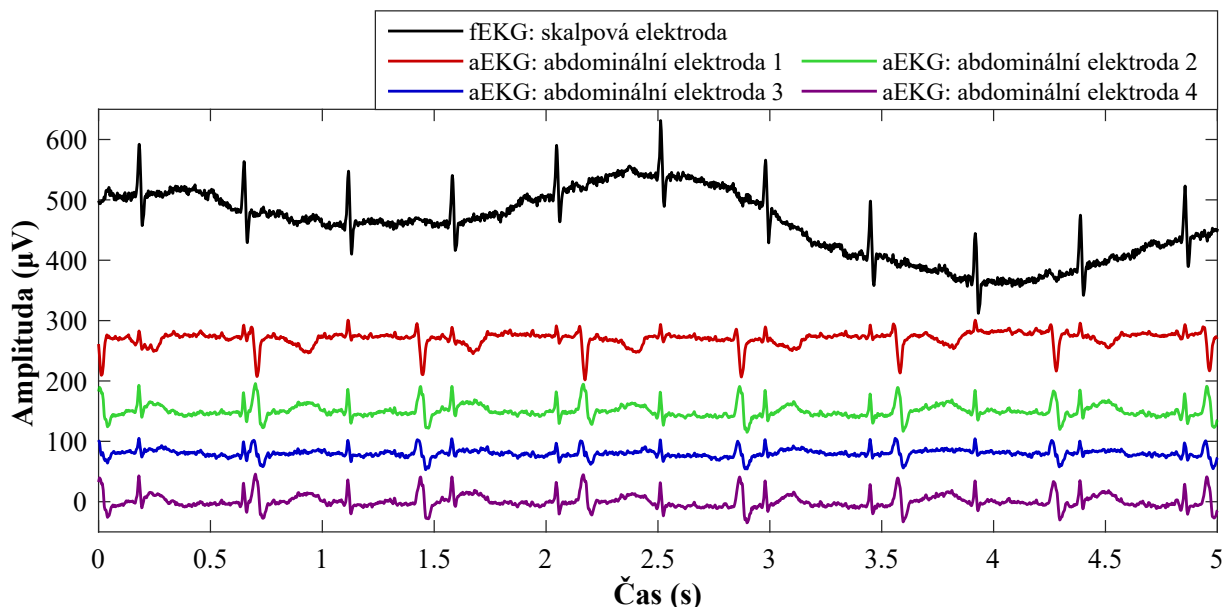
Obrázek 22: Blokové schéma principu DWT při použití adaptivního a měkkého prahování.

5.6 Databáze

Kvalitních databází, na kterých by se dalo provést testování extrakce fEKG signálu, je velmi málo. Pro testování hybridních metod byla zvolena databáze ADFECGDB a databáze EKG physionet challenge 2013. Hlavním důvodem zvolení těchto dvou databází bylo, že obsahují reálná data, a hlavně anotační značky pozic fQRS komplexů. Dalším důvodem bylo, že jsou velice často využívanými databázemi v prostudovaných studiích. Krom zvolených databází fEKG záznamů se používají ještě databáze DAISY, databáze FECGSYNDB, databáze NIFECGDB a databáze MIT-BIH, která ovšem obsahuje EKG záznamy dospělého člověka s arytmiemi.

5.6.1 Databáze abdominálního a přímého plodového elektrokardiogramu

Databáze ADFECGDB [13, 46, 47, 48, 49] je volně dostupná databáze ze stránek physionetu. Tato databáze obsahuje 5 pětikanálových záznamů získaných od 5 různých těhotných žen v 38. až 41. týdnu těhotenství, a které byly pořízeny při porodu. Všechny 5 záznamů bylo pořízeno na plicním oddělení lékařské univerzity ve městě Zabrze v Polsku. Jednotlivé signály jsou nahrány se šířkou pásma 1 až 150 Hz (s odstraněným síťovým rušením na frekvenci 50 Hz), vzorkovací frekvencí 1 kHz, rozlišením 16 bitů a délkou 5 min. Jednotlivé záznamy obsahují 4 aEKG signály naměřené v břišní oblasti těhotné ženy a jeden fEKG signál naměřený pomocí FSE. K naměření aEKG signálů použili 4 stříbrochloridové elektrody umístěné okolo pupíku (plocha elektrod byla vybroušena ke snížení impedance kůže), referenční elektrodu umístěnou nad sponou stydkou a aktivní elektrodu umístěnou na levé dolní končetině. Naměření přímého fEKG signálu bylo provedeno transvaginálně pomocí typické spirálové elektrody. Na obrázku 23 lze vidět vstupní signály ze záznamu r01.

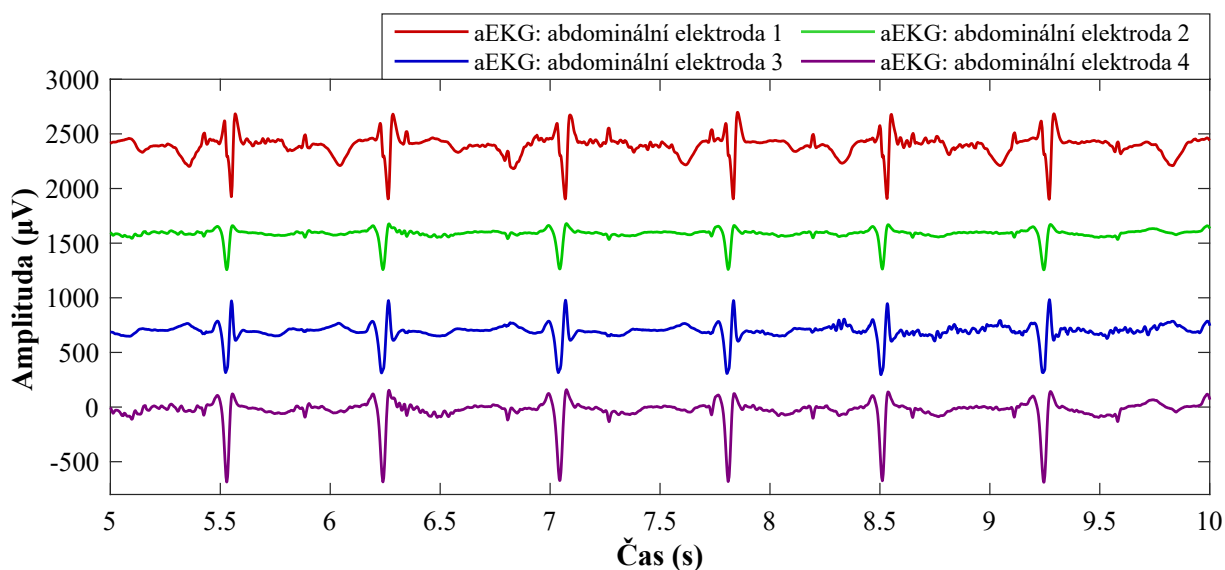


Obrázek 23: Ukázka vstupních signálů ze databáze ADFECGDB (záznam r01).

Z naměřeného přímého fEKG signálu byly pozice R kmitů automaticky zaznačeny použitým systémem snímání a následně byly ověřeny skupinou kardiologů za účelem sestavení přesných referenčních markerů (anotací). Kromě 5 záznamů uvedených na stránkách physionetu (záznamy r01, r04, r07, r08 a r10) bylo naměřeno dalších 7 záznamů (r02, r03, r05, r06, r09, r11 a r12), které nám byly poskytnuty. Tyto záznamy jsou odlišné pouze ve vzorkovací frekvenci, která je 500 Hz.

5.6.2 Databáze EKG physionet challenge 2013

Databáze EKG physionet challenge 2013 vznikla za účelem zlepšení vývoje přesných metod odhadu fHR, RR intervalů, či QT intervalů. Tato databáze obsahuje celkem 447 záznamů. Záznamy v databázi byly rozděleny do několika kategorií. Set A obsahuje 25 záznamů (a01 až a25), set A modifikovaný obsahuje 50 záznamů, set B obsahuje 100 záznamů a skrytý set C obsahuje 272 záznamů. Pro set A byly vytvořeny referenční anotace označující pozice jednotlivých R kmitů, proto v této práci je také jako v jiných studiích použit pouze tento soubor záznamů k otestování funkčnosti metod. Jednotlivé záznamy setu A obsahují 4 aEKG signály. Délka jednotlivých signálů je 1 min, a přestože byly zaznamenány s použitím různých přístrojů s rozdílnou frekvenční odezvou a konfigurací, tak všechny signály byly naměřeny se vzorkovací frekvencí 1 kHz a rozlišením 12 bitů. Na obrázku 24 lze vidět vstupní signály ze záznamu a01 [49, 93].



Obrázek 24: Ukázka vstupních signálů ze databáze EKG physionet challenge 2013 (záznam a01).


5.7 Hodnotící parametry

Pro kontrolu správnosti extrakce fEKG signálu je kvalitní hodnocení velice důležité. Pro tuto práci bylo zvoleno určení přesnosti detekce R kmitů vzhledem k referenci. Dále bylo zvoleno

využití Bland-Altmanova grafu, který je velice často používán v klinické praxi k porovnání dvou metod lékařského měření.

5.7.1 Určení přesnosti detekce R kmitů

Pro určení přesnosti extrakce fEKG signálu vzhledem k referenčnímu fEKG signálu (referenčním anotacím) bylo zvoleno využití stanovení parametrů určujících skutečně pozitivní hodnoty (TP), falešně pozitivní hodnoty (FP) a falešně negativní hodnoty (FN). Počet TP značí kolikrát byl v extrahovaném signálu určen pomocí detektoru R kmit v určitých místech signálu, kde mají být určeny R kmit dle reference. To znamená, že se jedná o správně detekované fQRS komplexy. Interval pro stanovení TP byl zvolen na 50 ms vlevo a 50 ms vpravo od referenčních anotací. Tento interval byl stanoven na základě studie od Billeci a Varanini z roku 2017 [101]. Tento interval poté slouží zároveň k určení počtu FN. Pokud dle referenční anotace měl být v daném místě signálu určen R kmit, ale v extrahovaném fEKG signálu nebyl určen, tak to znamená vynechání R kmitu, a zároveň zvýšení počtu FN. Počet FP značí určení R kmitů mimo intervaly, ve kterých se nachází R kmit dle reference. To znamená, že se jedná o falešně zjištěné neexistující fQRS komplexy. Ukázkou stanovení TP, FP a FN lze vidět na obrázku 25, který byl vytvořen při extrakci fEKG signálu na záznamu r06 z databáze ADFECGFB pomocí hybridní metody ICA-RLS-WT. Amplituda signálů je znormalizována, proto lze na ose Y vidět místo amplitudy normalizovanou jednotku, která je poté bezrozměrná (-).



Obrázek 25: Ukázka automatického stanovení TP, FP a FN na základě referenčních anotací pro extrahovaný signál pomocí hybridní metody ICA-RLS-WT na záznamu r06.

Pomocí získaných hodnot TP, FP a FN lze vypočítat pomocí rovnice (100) ACC, pomocí rovnice (101) lze vypočítat SE, pomocí rovnice (102) lze vypočítat PPV a pomocí rovnice (103) lze vypočítat F1. Hranice pro přijetí, že metoda funguje dobře dle parametrů ACC, SE, PPV a F1 je ve studiích 95 % [RJ3, 101].

$$ACC = \frac{TP}{TP + FP + FN} \cdot 100 (\%). \quad (100)$$

$$SE = \frac{TP}{TP + FN} \cdot 100 (\%). \quad (101)$$

$$PPV = \frac{TP}{TP + FP} \cdot 100 (\%). \quad (102)$$

$$F1 = 2 \cdot \frac{SE \cdot PPV}{SE + PPV} = \frac{2 \cdot TP}{2 \cdot TP + FP + FN} \cdot 100 (\%). \quad (103)$$

5.7.2 Bland-Altmanův graf

Pokud ve statistice je cílem ohodnotit dvojice náhodných veličin (X_1, Y_1) , (X_2, Y_2) až (X_n, Y_n) , které tvoří páry závislých pozorování, tak je nutné při ověřování polohy využít párové testy. Mezi takové testy patří párový t-test, Wilcoxonův test, ale také Bland-Altmanův graf. V prvním kroku párového testu se provede výpočet diferencí a průměrů mezi dvojicemi náhodných veličin, viz rovnice (104) a (105), kde \vec{D} je vektor diferencí, \vec{M} je vektor průměrů, \vec{X} je vektor náhodných veličin získaných z referenční křivky fHR, \vec{Y} je vektor náhodných veličin získaných z odhadnuté křivky fHR pomocí testované metody, n je počet prvků jednotlivých vektorů a i je i -tý prvek jednotlivých vektorů. Tímto lze poté předpokládat, že veličiny (D_1, D_2, \dots, D_n) jsou statisticky nezávislé a mají stejné rozdělení se střední hodnotou $\mu = \mu_1 - \mu_2$. Následně lze test o shodě dvou středních hodnot, který se provádí pomocí dvouvýběrového testu, převést na jednovýběrový test o střední hodnotě provedený na náhodných veličinách diferencí \vec{D} [155, 156, 157, 158].


$$\vec{D} = (D_1, D_2, \dots, D_n), \text{ kde } D_i = X_i - Y_i. \quad (104)$$

$$\vec{M} = (M_1, M_2, \dots, M_n), \text{ kde } M_i = \frac{X_i + Y_i}{2}. \quad (105)$$

Obrázek 26 zobrazuje hustotu rozdělení dat se střední hodnotou μ a směrodatnou odchylkou σ . Na tomto obrázku je reprezentována pravděpodobnost, že se bude náhodná veličina vyskytovat v intervalu $\mu \pm \sigma$ (68,2 %), v intervalu $\mu \pm 2\sigma$ (95,4 %) a v intervalu $\mu \pm 3\sigma$ (99,8 %). Normované normální rozdělení je založeno na bodu $\mu + 1,96\sigma$, což značí 97,5 % kvantil normálního rozdělení. Z rovnice (106) a úprav této rovnice, viz rovnice (107), (108) a (109), kde P značí pravděpodobnost a z značí kvantilový bod normálního rozdělení, poté vyplývá, že 95 % plochy normálního rozdělení leží v intervalu $\mu \pm 1,96\sigma$. Vypočtení střední hodnoty μ a $1,96\sigma$ z vektoru diferencí \vec{D} se provede na základě rovnic (110) a (111), kde n je celkový počet prvků vektoru diferencí \vec{D} a i je i -tý prvek vektoru \vec{D} [155, 156, 158].

$$P(z_{0,025} < \frac{\vec{D} - \mu}{\sigma} < z_{0,975}) = 0,95. \quad (106)$$

$$P(-z_{0,975} < \frac{\vec{D} - \mu}{\sigma} < z_{0,975}) = 0,95. \quad (107)$$



Obrázek 26: Hustota normálního rozdělení dat (Gaussovo rozdělení).

$$P(-1,96 < \frac{\vec{D} - \mu}{\sigma} < 1,96) = 0,95. \quad (108)$$

$$P(\mu - 1,96\sigma < \vec{D} < \mu + 1,96\sigma) = 0,95. \quad (109)$$

$$\mu = \frac{\sum_{i=1}^n D_i}{n}. \quad (110)$$

$$1,96\sigma = 1,96 \cdot \sqrt{\frac{\sum_{i=1}^n (D_i - \mu)^2}{n - 1}}. \quad (111)$$

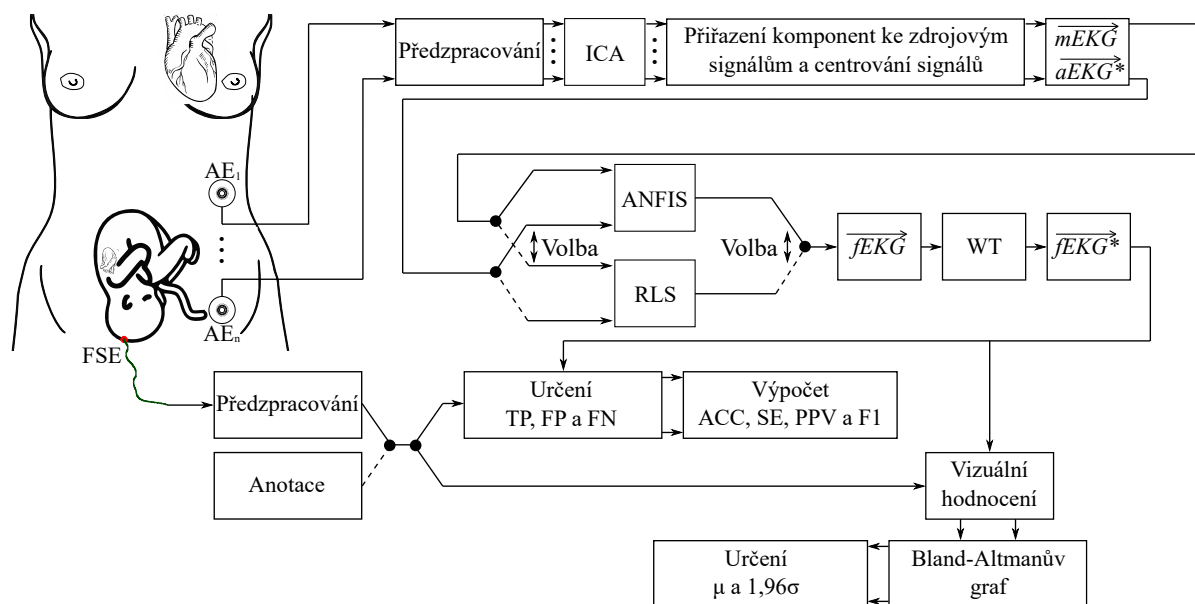
Při sestavení Bland-Altmanova grafu se nejdříve vynesou hodnoty vektorů \vec{D} a \vec{M} do grafu. Následně se vynesou prostřední čára značící střední hodnotu μ a dvě vnější čáry značící horní a dolní limity shody. Limity shody znázorňují v grafu právě hodnoty $\mu \pm 1,96\sigma$ [155, 156, 157].

6 Hybridní systém

V této části je detailně popsána koncepce nového hybridního systému pro NI-fEKG monitorování fHR, která představuje disertabilní jádro této doktorské disertační práce. Následně je zde popsána úprava detekovaných křivek fHR na základě rozhodování a použitého MA u všech použitých záznamů. Nakonec následuje statistické srovnání odhadnutých křivek fHR pomocí dvou nových hybridních metod ICA-ANFIS-WT a ICA-RLS-WT vůči referenční křivce fHR.

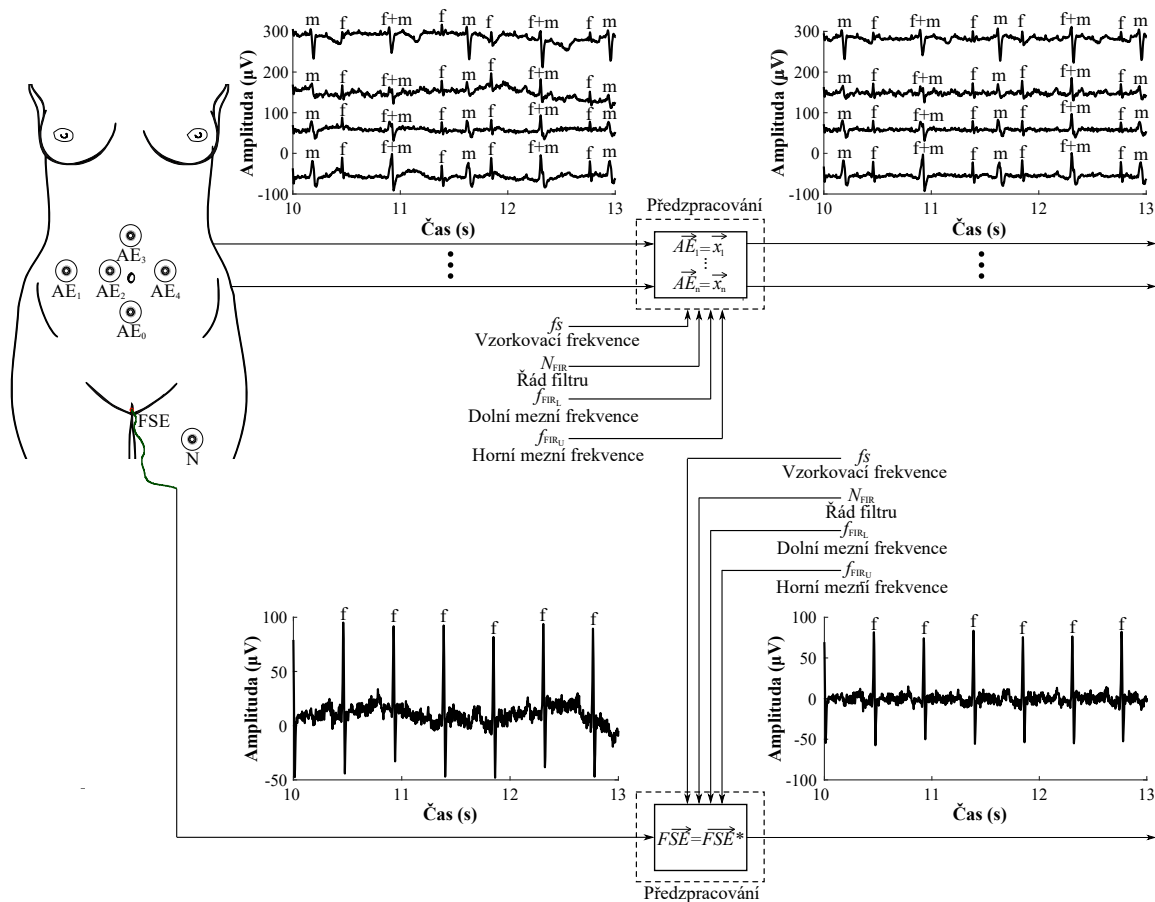
6.1 Popis hybridního systému

Na obrázku 27 lze vidět zjednodušené blokové schéma realizovaného hybridního systému. Extrakce fEKG signálu pomocí zvolené hybridní metody je provedena v několika blocích. V následující části této podkapitoly jsou rozebrány jednotlivé bloky hybridního systému pro lepší pochopení funkčnosti a pro představu, jak se signál mění během průchodu jednotlivými bloky.



Obrázek 27: Zjednodušené blokové schéma hybridního systému.

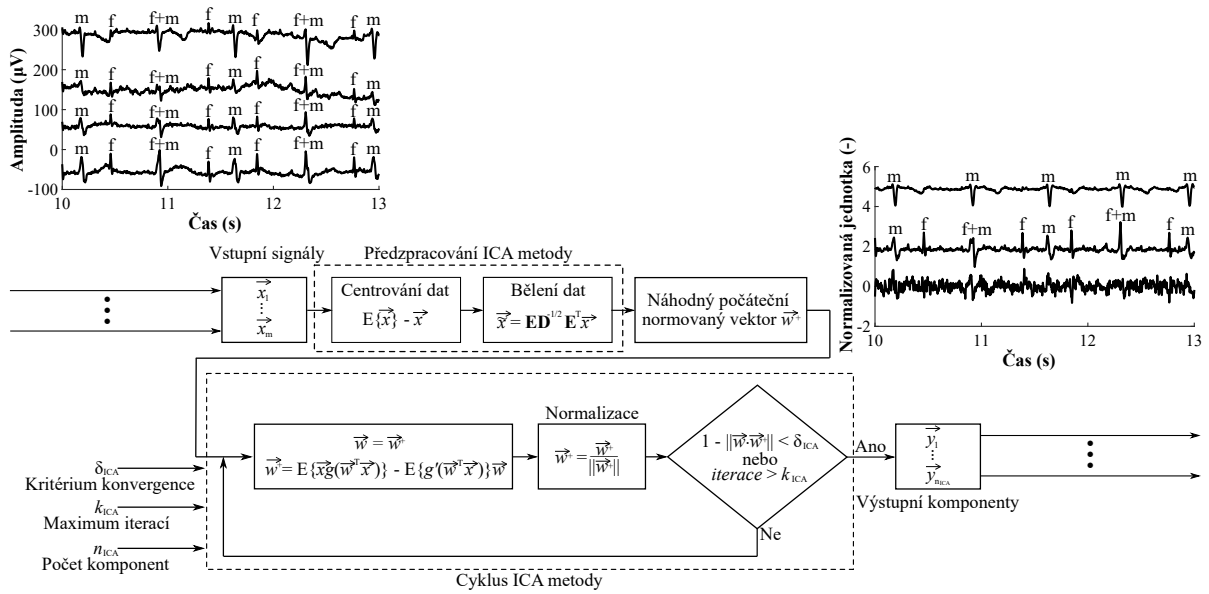
Do bloku předzpracování vstupují minimálně 2 reálné aEKG signály, které jsou následně filtrovány, viz obrázek 28. Rozmístění elektrod na tomto obrázku je provedeno podle databáze ADFECGDB [13, 46, 47, 48, 49]. Aktivní abdominální elektrody jsou označeny jako AE_1 až AE_4 , referenční elektroda je označen jako AE_0 a aktivní zem je označena jako N. Pro filtraci zvoleného pásma byl použit FIR filtr, ale lze v tomto bloku použít i jiný typ filtru. V bloku předzpracování je potřeba nastavit dolní mezní frekvenci f_{FIR_L} , horní mezní frekvenci f_{FIR_U} , řád filtru N_{FIR} a vzorkovací frekvenci f_s vstupních aEKG signálů, která se u databází liší na základě naměření záznamů.



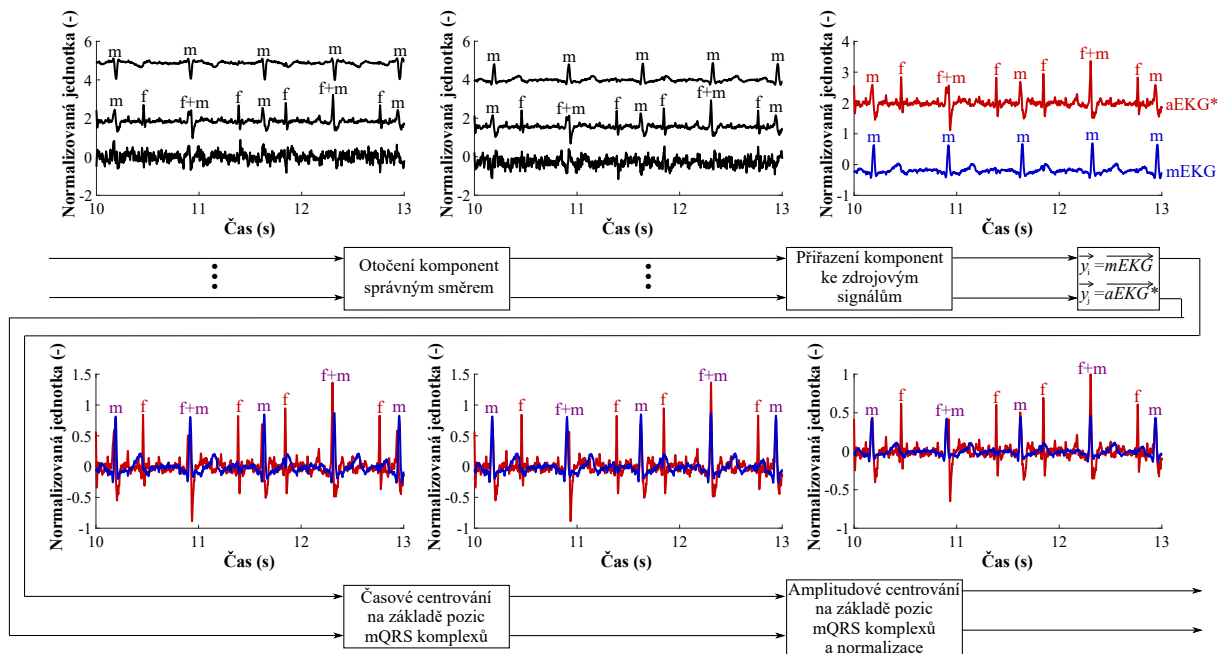
Obrázek 28: Předzpracování vstupních signálů.

V této práci byla zvoleno toto nastavení parametrů bloku předzpracování: $f_{FIR_L} = 3$ Hz, $f_{FIR_U} = 150$ Hz, $N_{FIR} = 500$ a $fs = 500; 1000$ Hz (všechny záznamy z databáze EKG physionet challenge 2013 měly vzorkovací frekvenci 1000 Hz, 5 záznamů z databáze ADFECGDB mělo vzorkovací frekvenci 1000 Hz a 7 záznamů z databáze ADFECGDB mělo vzorkovací frekvenci 500 Hz). Dle studie Sameni a kol. v roce 2010 [9] (dle této studie se fQRS komplexy nachází ve frekvenčním pásmu 10 až 15 Hz) je zřejmé, že použitá pásmová propust nemá negativní vliv na kvalitu extrahovaného fEKG signálu. Účelem využití FIR filtru se zvolenými mezními frekvencemi je, aby byl zredukován šum způsobený kolísáním izolinií, myopotenciály, dechovou aktivitou, a podobně.

Vyfiltrované signály následně vstupují do bloku ICA metody, viz obrázek 29. Zde je potřeba zvolit počet výstupních komponent z ICA metody n_{ICA} , kritérium konvergence δ_{ICA} a maximální počet iterací cyklu k_{ICA} . Pro experimenty bylo nastaveno $n_{ICA} = 3$, $\delta_{ICA} = 0.00001$ a $k_{ICA} = 100$. Zvolení 3 výstupních komponent slouží k odhadnutí signálu šumu a dvou signálů potřebných jako vstup do adaptivních metod. Jeden signál poté odpovídá mEKG signálu bez nutnosti jeho naměření pomocí hrudní elektrody. Druhý signál je v této práci označen jako aEKG* a jedná se o signál podobný vstupním aEKG signálům ovšem se zvýrazněnou plodovou složkou.



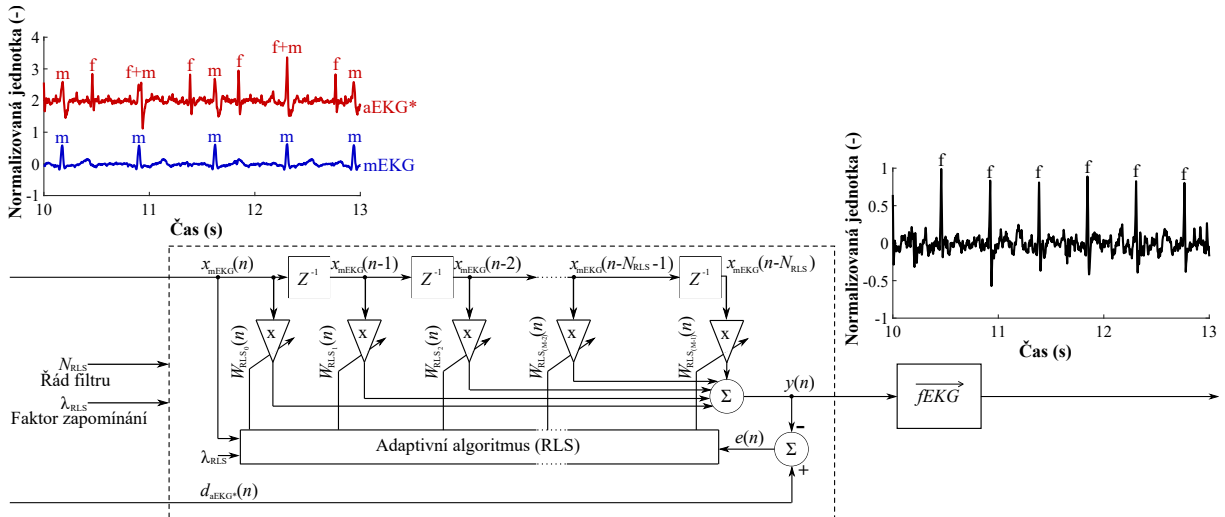
Obrázek 29: Aplikování ICA metody k obdržení komponent pro adaptivní metody.



Obrázek 30: Postup algoritmu automatického volení a centrování výstupních komponent z ICA metody.

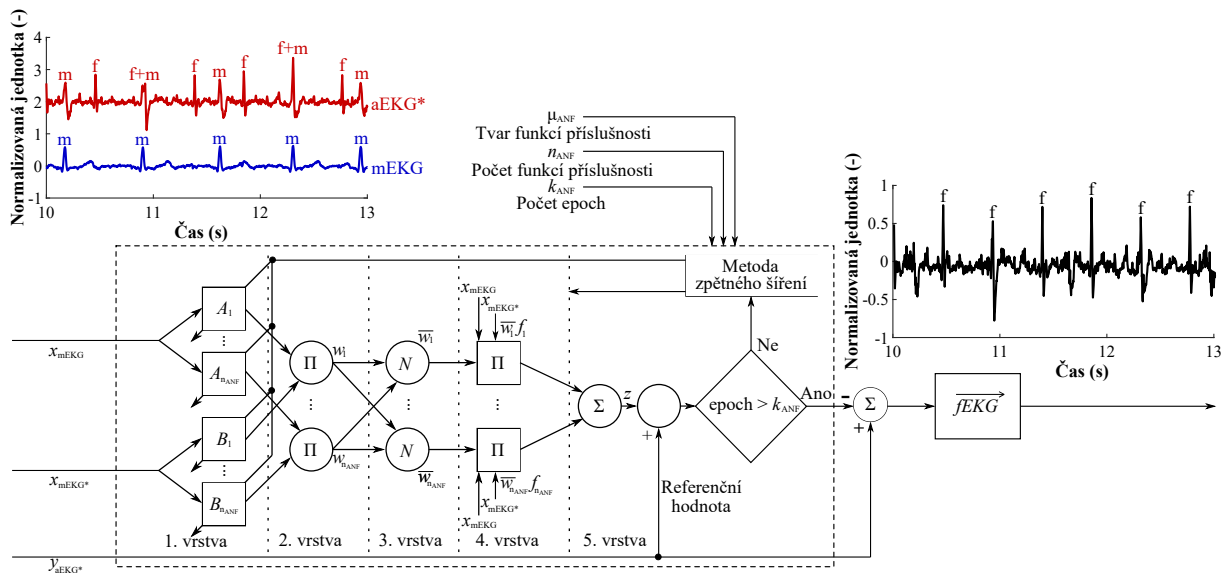
Po dokončení extrakce komponent pomocí ICA metody jsou výstupní signály vždy uloženy v rozdílném pořadí, mají rozdílnou velikost amplitudy vzhledem ke vstupním signálům (důvodem je normování v cyklu ICA metody), signály jsou časově posunuty a mají náhodnou polaritu. Signály je nutné nechat algoritmem pro automatické centrování upravit a vybrat z nich mEKG a aEKG* signál, viz obrázek 30.

V prvním kroku je jedna komponenta označena jako mEKG, druhá jako aEKG* a třetí jako šum. U signálu, který je označen jako mEKG, se určí pozice mQRS komplexů. Na základě těchto pozic se amplitudově a časově vyrovná signál mEKG se signálem aEKG*. Pokud selže automatické centrování, což lze poznat pouze vizuálně, je nutné použít manuální centrování signálů. Při manuálním centrování je mEKG a aEKG* signál zvolen subjektivně (je možné zvolit aEKG* signál ze vstupních aEKG signálů) a poté se provede ruční amplitudové a časové centrování. Z důvodu změny amplitud během centrování je následně opět provedena normalizace signálů.



Obrázek 31: Extrakce fEKG signálu z vycentrovaných signálů pomocí metody ANFIS.

Hlavní částí hybridního systému jsou adaptivní metody sloužící k extrakci fEKG signálu. Do tohoto bloku vstupují připravené signály po centrování a uživatel rozhoduje, zda se použije metoda ANFIS, viz obrázek 31, nebo RLS, viz obrázek 32. U metody ANFIS je potřeba nastavit tvar funkcí příslušnosti μ_{ANF} , počet funkcí příslušnosti n_{ANF} a počet epoch k_{ANF} . Při aplikaci metody ANFIS bylo využito hybridní kombinace metody zpětného šíření a LMS algoritmu. Jako vstup do metody ANFIS se využívá signál mEKG a signál mEKG*. Signál mEKG* je o jeden vzorek zpožděný signál mEKG a slouží k správnému odhadnutí mateřské komponenty jako je obsažená v signálu aEKG* před následným odečtením k odhadnutí fEKG signálu. Při aplikaci algoritmu RLS je potřeba nastavit řád filtru N_{RLS} a faktor zapomínání λ_{RLS} . Výhodou RLS v porovnání s metodou ANFIS je výrazně nižší výpočetní náročnost. V této práci bylo využito proměnlivé nastavení obou metod k nalezení nejlepšího nastavení za účelem dosažení co nejvyšší přesnosti extrakce fEKG signálu. Navíc bylo využito vyzkoušení všech možných kombinací vstupních signálů pro jednotlivé záznamy. Dohromady bylo pro každý záznam otestováno 11 možných kombinací elektrod. U metody ANFIS se měnilo nastavení $\mu_{ANF} = trimf$ (trojúhelníková funkce příslušnosti); $\mu_{ANF} = trapmf$ (lichoběžníková funkce příslušnosti); $\mu_{ANF} = gbellmf$ (zvonová funkce příslušnosti); $\mu_{ANF} = gaussmf$ (Gaussovská funkce příslušnosti), $n_{ANF} = 2$; $n_{ANF} = 4$; $n_{ANF} = 6$; $n_{ANF} = 8$; $n_{ANF} = 10$ a $k_{ANF} = 10$; $k_{ANF} = 20$; $k_{ANF} = 30$.



Obrázek 32: Extrakce fEKG signálu z vycentrovaných signálů pomocí RLS algoritmu.

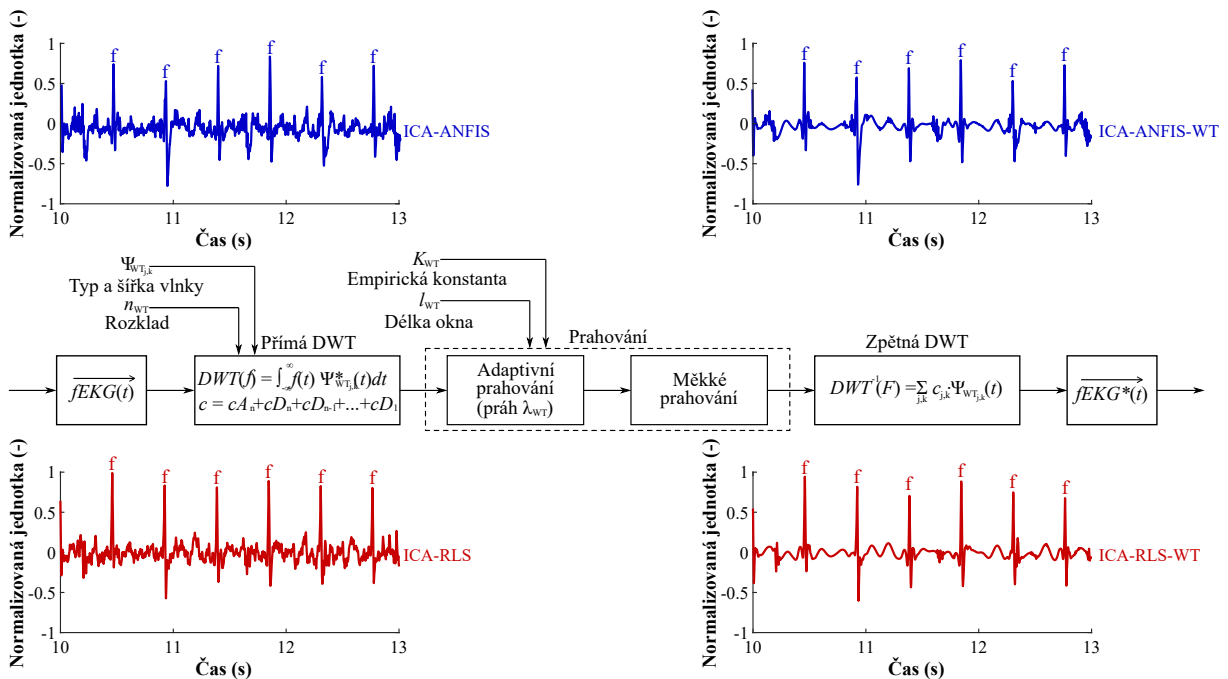
Kombinováním jednotlivých nastavení metody ANFIS vzniklo pro jednu kombinaci elektrod jednoho daného záznamu 45 výstupů. Dohromady 660 výstupů vzniklo pro každý záznam při aplikování zvolených nastavení metody ANFIS na všech 11 kombinacích elektrod. Nakonec bylo pro každý záznam tedy nalezeno optimální nastavení metody ANFIS a nejvhodnější kombinace vstupních signálů pro jednotlivé záznamy. Tabulka 7 zobrazuje počet uzlů, počet lineárních parametrů, počet nelineárních parametrů a počet fuzzy pravidel při aplikování zvoleného počtu funkcí příslušnosti n_{ANF} .

Tabulka 7: Nastavení parametrů metody ANFIS vzhledem k počtu funkcí příslušnosti n_{ANF} .

Počet funkcí příslušnosti	Počet uzlů	Počet lineárních parametrů	Počet nelineárních parametrů	Počet fuzzy pravidel
2	21	12	12	4
4	53	48	24	16
6	101	108	36	36
8	165	192	48	64
10	245	300	60	100

Obdobné proměnlivé nastavení bylo použito při testování algoritmu RLS, kdy se měnil řád filtru N_{RLS} v rozsahu od 2 do 100 s krokem 2. Koeficient zapomínání λ_{RLS} byl nastaven na hodnotu $\lambda_{RLS} = 1$. Tímto způsobem vzniklo pro jednu kombinaci elektrod 50 výstupů RLS algoritmu a celkově pro jeden záznam poté 550 výstupů. Nakonec bylo pro každý záznam nalezeno optimální nastavení algoritmu RLS a nejvhodnější kombinace vstupních signálů pro jednotlivé záznamy.

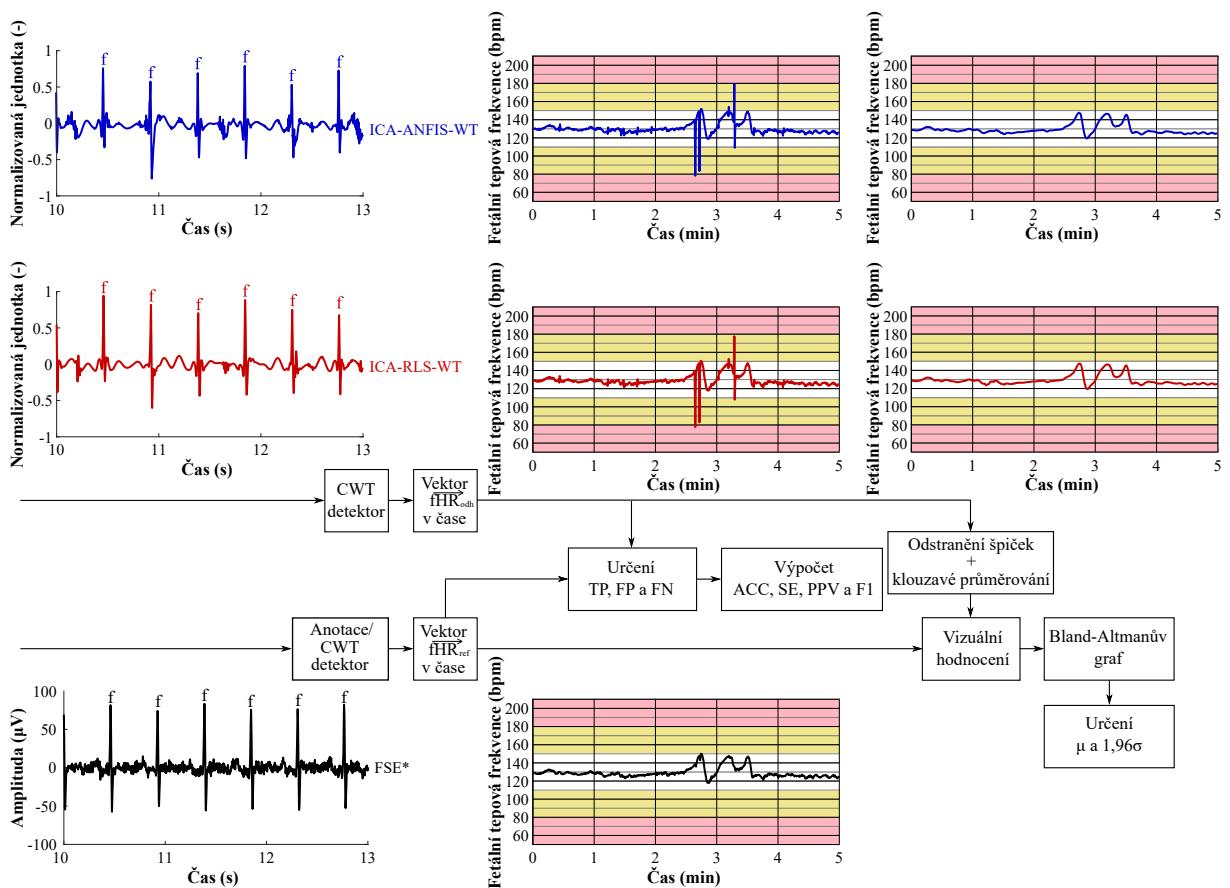
Extrahované fEKG signály z adaptivních metod jsou poté znovu normalizovány a vstupují do bloku WT, kde je provedeno vyhlazení fEKG signálů. Na obrázku 33 lze vidět aplikování WT algoritmu, kde fEKG je vstupní signál fEKG označený v obrázku jako ICA-ANFIS, pokud byla v předešlém kroku aplikována adaptivní metoda ANFIS, nebo jako ICA-RLS, pokud byl v předešlém kroku aplikován algoritmus RLS. Výstupem WT je signál fEKG*, což je vyhlazený fEKG signál označený v obrázku jako ICA-ANFIS-WT, pokud byla v předešlém kroku aplikována adaptivní metoda ANFIS, nebo jako ICA-RLS-WT, pokud byl v předešlém kroku aplikován algoritmus RLS. Vyhlazením dochází k zvýraznění R kmitů, což napomáhá přesnějšímu stanovení správných pozic R kmitů za účelem stanovení křivky fHR (stanovení fHR je primárním cílem této práce). U bloku WT je nutné zvolit typ mateřské vlnky Ψ_{WT} , úroveň rozkladu n_{WT} , délku okna l_{WT} pro adaptivní prahování a empirickou konstantou K_{WT} . Pro experimenty bylo nastaveno $\Psi_{WT} = db4$ (mateřská vlnka Daubechies se šířkou 4), $n_{WT} = 6$, $l_{WT} = 500$ a $K_{WT} = 2, 5$.



Obrázek 33: Vyhlazení fEKG signálu pomocí WT po výstupu z adaptivních filtrů.

Nastavení jednotlivých metod (bloků) bylo dáno experimentálně na všech záznamech z databáze ADFECGDB [13, 46, 47, 48, 49] a databáze EKG physionet challenge 2013 [49, 93]. Dále bylo využito nastavení jednotlivých parametrů na základě prostudované problematiky zpracování fEKG signálu pomocí použitých metod a na sérii provedených experimentů [RJ1, RJ3, RJ5, 136, 137, 138, 140, 152].

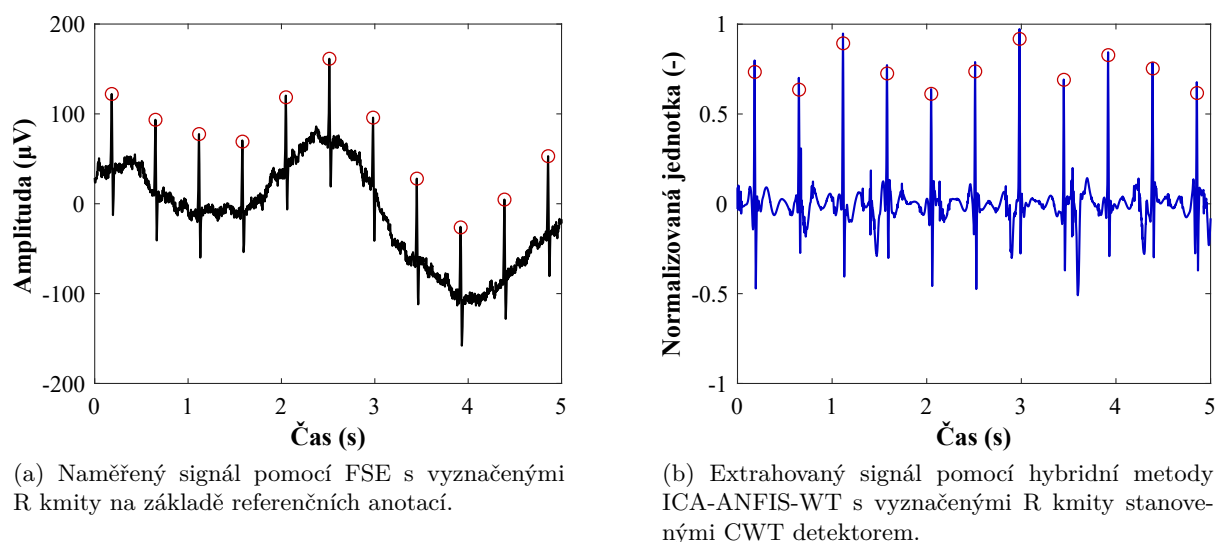
Statistické hodnocení kvality extrakce fEKG signálu vzhledem k referenci lze poté vidět na obrázku 34. V prvním kroku je provedena detekce pozic R kmitů pomocí detektoru založeném na CWT na extrahovaných signálech [159, 160, 161]. Pomocí stanovených pozic R kmitů je provedeno určení TP, FP a FN vůči referenčním anotacím (nebo detekovaným R kmitům v referenčním signálu, ke kterému nebyly poskytnuty referenční anotace). Následně je proveden výpočet ACC, SE, PPV a F1. V dalším kroku jsou na základě pozic R kmitů referenčního a extrahovaných signálů vytvořeny křivky fHR. Křivky fHR extrahovaných signálů jsou nejdříve upraveny a následně jsou vyneseny do grafů spolu s referenční křivkou fHR pro vizuální hodnocení. Nakonec jsou tyto křivky porovnány pomocí Bland-Altmanových grafů a jsou stanoveny střední hodnoty μ a hodnoty $1,96\sigma$. Hlubší popis detekce a úpravy křivek je proveden v následující podkapitole 6.2.



Obrázek 34: Schéma hodnocení kvality extrakce fEKG signálu pomocí obou hybridních metod.

6.2 Příprava dat

Po extrakci jednotlivých fEKG signálů pomocí obou hybridních metod následuje odhadnutí křivky fHR. Nejprve je provedeno automatické stanovení (detekce) pozic R kmitů ze všech extrahovaných fEKG signálů. Použitý detektor je založen na CWT [159, 160, 161], kdy se detektor snaží najít všechna lokální minima a maxima překračující stanovený práh. K tomu je využita Gaussova mateřská vlnka se šířkou 1 a stupněm rozkladu 5. V místě, kde mezi jedním lokálním minimem a lokálním maximem je vzdálenost maximálně 120 ms, je vzorek uznán za R kmit. Jedná se o velice přesný a efektivní detektor. Pozice R kmitů u referenčních signálů naměřených pomocí FSE (dále označovaných pouze jako referenční signály) jsou u záznamů r01, r04, r07, r08 a r10 zapsány u databáze, jsou stanoveny mediky a uznány jako správné anotace záznamů. U záznamů r02, r03, r05, r09, r11 a r12 nejsou k dispozici referenční anotace, proto bylo potřeba provést přesnou detekci R kmitů. Žádný ze záznamů z databáze EKG physionet challenge 2013 neobsahuje referenční signál naměřený pomocí FSE, ale všechny obsahují v databázi anotace pozic R kmitů. V této práci jsou v jednotlivých obrázcích referenční signály vykresleny černou barvou, extrahované signály pomocí hybridní metody ICA-ANFIS-WT vykresleny modrou barvou a extrahované signály pomocí hybridní metody ICA-RLS-WT vykresleny červenou barvou. Pomocí pozic R kmitů referenčního signálu a stanovených pozic u extrahovaného signálu se následně určí počet TP, FP a FN, jak bylo popsáno v podkapitole 5.7.1. Příklad anotací R kmitů u referenčního signálu ze záznamu r01 lze vidět na obrázku 35a a příklad detekce R kmitů z extrahovaného fEKG signálu ze záznamu r01 pomocí hybridní metody ICA-ANFIS-WT lze poté vidět na obrázku 35b.




Obrázek 35: Průběhy fEKG signálů ze záznamu r01 s vyznačenými pozicemi R kmitů.


V dalším kroku bylo potřeba provést stanovení intervalů mezi jednotlivými pozicemi R kmitů. Tím se vytvořil vektoru intervalů \vec{T} , který byl následně přepočítán na vektor aktuálních hodnot \vec{fHR} pomocí rovnice (112), kde n je počet stanovených R-R intervalů. Výsledek se násobí hodnotou 60, aby byl v jednotkách bpm.

$$\vec{T} = (T_1, T_2, \dots, T_n), \vec{fHR} = (fHR_1, fHR_2, \dots, fHR_n), \text{ kde } fHR_i = \frac{1}{T_i} \cdot 60. \quad (112)$$


Ukázku stanovení intervalů mezi dvěma R kmity a určení aktuálních hodnot fHR lze vidět na obrázku 36a. Pro tento obrázek byla vybrána část průběhu, kde lze pozorovat vynechaný R kmit (aktuální hodnota fHR je v tomto místě 78,0 bpm).




(a) Detekce R kmitů a stanovení vektoru aktuálních hodnot fHR.



(b) Vykreslení odhadnuté křivky fHR.



(c) Odstranění odlehlých hodnot z odhadnuté křivky fHR pomocí aproximace křivky.



(d) Aplikování klouzavého průměrování na odhadnutou křivku fHR.

Obrázek 36: Ukázka postupu odhadnutí křivky fHR z extrahovaného fEKG signálu ze záznamu r01 pomocí hybridní metody ICA-ANFIS-WT.

Vektor aktuálních hodnot fHR vyneseny do grafu lze vidět na obrázku 36b a znázorňuje křivku fHR extrahovaného fEKG signálu pomocí hybridní metody ICA-ANFIS-WT. Na tomto obrázku lze pozorovat, že i použitý efektivní CWT detektor v některých místech nesprávně odhadne R kmit a nastanou odlehlé hodnoty (špičky). Tyto odlehlé hodnoty je potřeba co nejvíce eliminovat, aby bylo dosaženo co nejpřesnější křivky fHR jako je u referenčního signálu. Je třeba také zdůraznit, že záznam r01 použitý na obrázku 36 vycházel nejlépe (u jiných záznamů byl počet odlehlých hodnot mnohem větší). Eliminace odlehlých hodnot byla provedena pomocí algoritmu, který hledá tyto odlehlé hodnoty a nahrazuje je aproximací křivky. Algoritmus vyhledává místa, kde je velký rozdíl mezi aktuální hodnotou fHR a následující hodnotou fHR. Takové nalezené hodnoty přepíše na průměrnou hodnotu vypočtenou z předešlé hodnoty před odlehlou hodnotou a následující hodnotou, která byla uznána za správnou na základě rozhodovacího procesu. Algoritmu je umožněno odstranit maximálně 5 odlehlých hodnot za sebou a nezáleží, zda jsou všechny odlehlé hodnoty kladně orientované, záporně orientované, nebo některé kladně a některé záporně orientované. Takto upravený signál lze pozorovat na obrázku 36c.

Posledním krokem úpravy signálu je provedení MA, což je filtrace prováděná v čase. Filtr klouže po pohyblivém okně o zvoleném počtu prvků a provádí průměrování. Pokud byl v předešlém kroku proveden menší počet eliminací odlehlých hodnot, než je pětina prvků vektoru \vec{fHR} , tak algoritmus provede MA 10 prvků. V opačném případě algoritmus provede MA 30 prvků. Finální signál po MA je zobrazen na obrázku 36d. Tyto úpravy signálu byly provedeny pro všechny extrahované fEKG signály získané z jednotlivých záznamů obou použitých databází pomocí obou hybridních metod. Po vykreslení křivek fHR následuje provedení Bland-Altmanových grafů mezi odhadnutými křivkami a referenčními křivkami fHR spolu se zaznamenáním středních hodnot μ a hodnot $1,96\sigma$.

Je potřeba zdůraznit, že vykreslením referenčních anotací z databáze ADFECGDB do grafu bylo zjištěno, že některé obsahují několik odlehlých hodnot. Tyto odlehlé hodnoty byly v anotacích této databáze nahrazeny pomocí průměrné hodnoty mezi předešlou a následující správnou hodnotou. Pokud by nebyl tento krok proveden, došlo by při vytvoření Bland-Altmanova grafu k ovlivnění výpočtu střední hodnoty μ a hodnot $1,96\sigma$.

7 Experimenty a výsledky

V této kapitole bude prokázána účinnost obou hybridních metod na reálných datech. Experiment bude nejprve proveden na databázi ADFECGDB a následně na databázi EKG physionet challenge 2013. Experimenty obsahují velké množství tabulek a obrázků (Bland-Altmanových grafů), proto v této kapitole budou zobrazeny pouze stěžejní výsledky a zbytek tabulek a obrázků bude možné vidět v příloze A a B. Experiment provedený v této práci je publikován ve studii [RJ2].

7.1 Experimenty na reálných datech z databáze ADFECGDB

Výsledky v této podkapitole se dělí do 3 částí. V první části bude provedeno stanovení TP, FP a FN (viz kapitola 5.7.1) ze všech extrahovaných fEKG signálů pomocí obou hybridních metod na 12 záznamech z databáze ADFECGDB a provede se výpočet parametrů ACC, SE, PPV a F1 k určení přesnosti detekce R kmitů. Ve druhé části této podkapitoly se vizuálně srovnají odhadnuté upravené křivky fHR pro subjektivní posouzení přesnosti filtrace vzhledem k referenčním křivkám fHR. Třetí část se bude zabývat sestavením Bland-Altmanových grafů (viz kapitola 5.7.2) pro posouzení přesnosti odhadnutí křivek fHR vzhledem k referenčním křivkám fHR a určí se střední hodnoty μ a hodnoty $1,96\sigma$.

7.1.1 Hodnocení na základě určení přesnosti detekce R kmitů

Nejdříve je provedeno nalezení ideálního nastavení adaptivních metod a vhodné kombinace elektrod jako vstupu do obou hybridních metod. Dle popsaného nastavení obou adaptivních metod v předešlé kapitole, bylo obdrženo (pro všech 11 kombinací elektrod jednotlivých záznamů) 60 fEKG signálů pro hybridní metodu ICA-ANFIS-WT a 50 fEKG signálů pro hybridní metodu ICA-RLS-WT. Následně byla provedena detekce R kmitů pomocí detektoru založeném na CWT. Na základě detekovaných pozic byl stanoven počet TP, FP a FN pro všechny extrahované signály, viz metodika na obrázku 25. Obdržením jednotlivých počtů TP, FP a FN pro všechny signály byl následně proveden výpočet zvolených parametrů ACC, SE, PPV a F1.

V dalším kroku byly zaznamenány nejlepší výsledky jednotlivých kombinací elektrod obou hybridních metod do tabulek v příloze A. V těchto tabulkách jsou zobrazeny nejlepší výsledky pro jednotlivé kombinace elektrod a zvýrazněny kombinace elektrod, které dosáhly největší přesnosti. Tyto nejlepší extrakce z jednotlivých záznamů pomocí obou hybridních metod byly uloženy a použity pro experimenty na reálných datech z databáze ADFECGDB.

Jako primární se hodnotí výsledek parametru ACC, protože ostatní parametry nemohou dosáhnout menší hodnoty než právě ACC. To znamená, pokud parametr ACC dosáhne hodnoty nad 95 %, tak i parametry SE, PPV a F1 dosáhnou přesnosti nad 95 %.

Výsledky pro hybridní metodu ICA-ANFIS-WT lze vidět v tabulce 8, která obsahuje nalezení optimální kombinace vstupních elektrod, tvar funkcí příslušnosti, počet funkcí příslušnosti

a počet epoch pro jednotlivé záznamy databáze ADFECGDB. Dále jsou v tabulce obsaženy výsledky stanovení TP, FP a FN a vypočtené hodnoty parametrů ACC, SE, PPV a F1. Lze vidět, že metoda fungovala na základě parametru ACC nad 95 % u záznamů r01, r02, r05 a r08, nad 90 % u záznamu r09 a nad 80 % u záznamu r03. U extrahovaného fEKG signálu ze záznamu r09 dosáhla hybridní metoda ICA-ANFIS-WT na základě parametru PPV a F1 hodnoty nad 95 %. Tento fakt značí, že v extrahovaném fEKG signálu na záznamu r09 byl určen nízký počet FP hodnot, ale vysoký počet FN. U ostatních 6 záznamů z celkového počtu 12 záznamů nedosáhla hybridní metoda ICA-ANFIS-WT dobrých výsledků, a tudíž nebyla jako extrakční metoda na tyto záznamy účinná.

Tabulka 8: Ideální kombinace elektrod a nastavení metody ANFIS pro jednotlivé záznamy databáze ADFECGDB. Stanovené počty TP, FP a FN na základě detekce pozic R kmitů v extrahovaných fEKG signálech pomocí hybridní metody ICA-ANFIS-WT vzhledem k referenčním pozicím R kmitů a výpočet parametrů ACC, SE, PPV a F1.

Záz.	Komb. elektr.	Tvar funkcí přísl.	Počet funkcí přísl.	Počet epoch	Počet R kmitů (anotace)	TP	FP	FN	ACC (%)	SE (%)	PPV (%)	F1 (%)
r01	1,3,4	gaussmf	2	10	644	643	1	1	99,69	99,85	99,85	99,85
r02	1,2,3,4	gbellmf	4	10	660	656	3	4	98,94	99,39	99,55	99,47
r03	2,4	gaussmf	6	30	684	619	48	65	84,56	90,50	92,80	91,64
r04	2,4	trimf	2	20	632	257	308	375	27,34	40,67	45,49	42,94
r05	1,4	gaussmf	4	20	645	634	3	11	97,84	98,29	99,53	98,91
r06	3,4	gbellmf	2	30	674	334	212	340	37,70	49,55	61,17	54,75
r07	1,3	trapmf	6	30	627	382	220	245	45,10	60,93	63,46	62,16
r08	1,4	gaussmf	2	10	651	650	1	1	99,69	99,85	99,85	99,85
r09	1,4	trapmf	2	20	657	624	13	33	93,13	94,98	97,96	96,45
r10	3,4	trimf	4	10	637	393	163	244	49,13	61,70	70,68	65,88
r11	1,4	gaussmf	10	30	705	291	293	414	29,16	41,28	49,83	45,15
r12	2,3	gbellmf	2	10	685	211	163	474	24,88	30,80	56,42	39,85

Stejné hodnocení bylo provedeno pro hybridní metodu ICA-RLS-WT a výsledky lze vidět v tabulce 9, která obsahuje nalezení optimální kombinace vstupních elektrod a řádu RLS algoritmu pro jednotlivé záznamy databáze ADFECGDB. Dále jsou v tabulce obsaženy výsledky stanovení TP, FP a FN a vypočtené hodnoty parametrů ACC, SE, PPV a F1. Na základě parametru ACC dosáhla tato metoda hodnoty nad 95 % u záznamů r01, r02, r05, r08 a r09, hodnoty nad 90 % u záznamů r03 a r10 a hodnoty nad 80 % u záznamů r06, r07 a r12. U extrahovaného fEKG signálu ze záznamu r03 dosáhla hybridní metoda ICA-RLS-WT na základě parametru PPV a F1 hodnoty nad 95 %. Tento fakt značí, že v extrahovaném fEKG signálu na záznamu r03 byl určen nízký počet FP hodnot, ale vysoký počet FN. U extrahovaného signálu na záznamu r10 dosáhla hybridní metoda ICA-RLS-WT na základě parametru SE hodnoty nad 95 %. Z tabulky je patrné, že na tomto záznamu metoda extrahovala fEKG signál, který obsahoval nízký počet FN, ale na druhou stranu vysoký počet FP. U ostatních záznamů r04 a r12 nebyla hybridní metoda ICA-RLS-WT účinná.

Tabulka 9: Ideální kombinace elektrod a nastavení algoritmu RLS pro jednotlivé záznamy databáze ADFECGDB. Stanovené počty TP, FP a FN na základě detekce pozic R kmitů v extrahovaných fEKG signálech pomocí hybridní metody ICA-RLS-WT vzhledem k referenčním pozicím R kmitů a výpočet parametrů ACC, SE, PPV a F1.

Záznam	Kombinace elektrod	Řád filtru	Počet R kmitů (anotace)	TP	FP	FN	ACC (%)	SE (%)	PPV (%)	F1 (%)
r01	1,3,4	2	644	643	1	1	99,69	99,85	99,85	99,85
r02	1,2,3,4	16	660	656	1	4	99,24	99,39	99,85	99,62
r03	2,4	86	684	647	4	37	94,04	94,59	99,39	96,93
r04	1,4	46	632	528	67	104	75,54	83,54	88,74	86,06
r05	1,4	16	645	644	1	1	99,69	99,85	99,85	99,85
r06	1,2,3,4	98	674	596	39	78	83,59	88,43	93,86	91,06
r07	1,4	46	627	567	61	60	82,41	90,43	90,29	90,36
r08	1,4	30	651	650	1	1	99,69	99,85	99,85	99,85
r09	1,2,4	16	657	626	1	31	95,14	95,28	99,84	97,51
r10	1,2,3,4	52	637	626	33	11	93,43	98,27	94,99	96,61
r11	1,2,3,4	80	705	322	267	383	33,13	45,67	54,67	49,77
r12	1,2,3,4	100	685	590	42	95	81,16	86,13	93,35	89,59


Během tohoto testování dosáhla hybridní metoda ICA-RLS-WT znatelně lepších výsledků než hybridní metoda ICA-ANFIS-WT. Lze vidět, že u 7 z 12 záznamů dokázala hybridní metoda ICA-RLS-WT extrahovat fEKG signály, které dosáhly na základě parametru ACC minimálně hodnoty 90 %, a ve výsledku u 10 z 12 záznamů dosáhla na základě parametru ACC minimálně hodnoty 80 %. Hybridní metoda ICA-ANFIS-WT dokázala extrahovat použitelné fEKG signály pouze u 6 z 12 záznamů.

7.1.2 Hodnocení na základě vizuálního srovnání


V této části hodnocení přesnosti extrakce fEKG signálů na záznamech z databáze ADFECGDB pomocí obou testovaných hybridních metod bylo nejdříve provedeno vytvoření křivek fHR pro jednotlivé extrahované fEKG signály. Následně bylo aplikováno odstranění odlehlých hodnot a MA na jednotlivé odhadnuté křivky fHR. U referenčních křivek fHR daných anotacemi (nebo určením pozic R kmitů pomocí detektoru založeném na CWT) bylo také provedeno v některých případech odstranění odlehlých hodnot.

Následně jsou jednotlivé křivky fHR získané pomocí metody ICA-ANFIS-WT spojeny za sebou do jednoho grafu spolu se spojenými křivkami fHR danými referenčními anotacemi. Vizuální hodnocení přesnosti odhadnutí křivek fHR pomocí metody ICA-ANFIS-WT lze vidět na obrázku 37a. V horní části obrázku jsou šipkou vyznačeny, které úseky jsou pro jednotlivé záznamy. Jeden záznam má délku 5 min, proto celkový signál složený z 12 záznamů má 60 min. Stejný postup je proveden pro vizuální hodnocení přesnosti odhadnutí křivek fHR pomocí metody ICA-RLS-WT, viz obrázek 37b. Grafické zobrazení je provedeno podle klasifikace FIGO [35]. Úsek pro hodnoty fHR od 110 do 150 bpm je označen bílou barvou a znázorňuje fyziologickou (normální) hodnotu fHR. Úsek pro hodnoty fHR od 150 do 180 bpm a od 90 do 110 bpm je označen žlutou barvou. Tato oblast upozorňuje na zvýšené riziko hypoxie plodu. Úsek

pro hodnoty fHR nad 180 a pod 80 bpm je označen růžovou barvou. Toto označení udává upozornění, že je plod v ohrožení z důvodu hypoxie, což může mít za následek nutnost operativního ukončení těhotenství. Z obrázku 37 je patrné, že hybridní metoda ICA-RLS-WT poskytuje podobnější křivku fHR vzhledem k referenční křivce, než hybridní metoda ICA-ANFIS-WT. Jedná se zejména o části signálů, kde je porovnán záznam r10 a r12. Lze tedy tvrdit, že na základě vizuálního hodnocení dosáhla hybridní metoda ICA-RLS-WT lepší přesnosti odhadnutí křivky fHR.



(a) Srovnání odhadnutých křivek fHR pomocí hybridní metody ICA-ANFIS-WT.

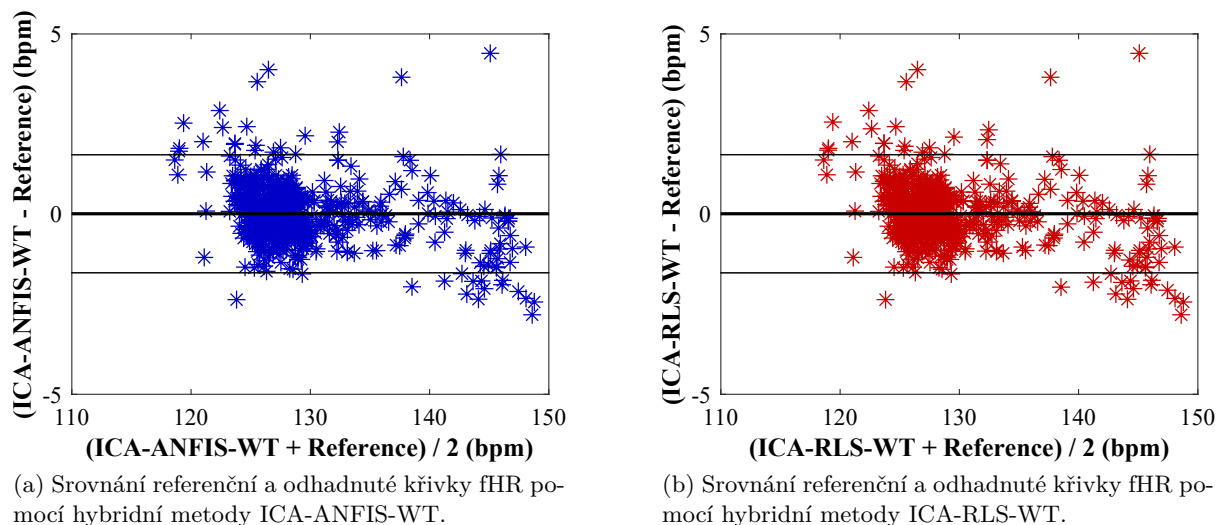


(b) Srovnání odhadnutých křivek fHR pomocí hybridní metody ICA-RLS-WT.


Obrázek 37: Grafické srovnání odhadnutých a referenčních křivek fHR ze všech 12 záznamů databáze ADFECGDB.

7.1.3 Hodnocení na základě sestrojení Bland-Altmanových grafů


V této části testování byly provedeny Bland-Altmanovy grafy mezi jednotlivými odhadnutými a referenčními křivkami fHR po úpravách. Nejdříve se před provedením Bland-Altmanových grafů vypočetly dva vektory mezi jednotlivými odhadnutými křivkami fHR pomocí obou hybridních metod a mezi referenčními křivkami fHR. První vektory diferencí \vec{D} byly provedeny pro osy Y, které znázorňují difference mezi hodnotami fHR referenčních a odhadnutých křivek fHR, viz rovnice (104). Druhé vektory \vec{M} byly provedeny pro osy X, které znázorňují průměry mezi hodnotami fHR referenčních a odhadnutých křivek fHR, viz rovnice (105). Prvky obou vektorů \vec{D} a \vec{M} byly následně vyneseny do jednotlivých Bland-Altmanových grafů. Hlavní součástí konstrukce Bland-Altmanova grafu je vypočtení střední hodnoty μ , která je v grafu znázorněna prostřední tlustou horizontální čarou. Následně se na základě této střední hodnoty μ a vypočtené směrodatné odchylky σ stanoví dva limity shody pomocí $\mu \pm 1,96\sigma$, které jsou v grafu znázorněny zbývajícími dvěma tenčími čarami. K výpočtu se použijí rovnice (109) až (111). Pro ukázkou byly zvoleny 2 záznamy, kde extrakce dosahovala nejlepších výsledků (záznam r01 a r08), viz obrázek 38 a 39, a 2 záznamy, kde extrakce dosahovala nejhorších výsledků (záznam r04 a r11), viz obrázek 40 a 41. Důvodem je, že pro každou odhadnutou křivku fHR ze všech 12 záznamů byl vytvořen samostatný obrázek a došlo by k velkému počtu grafů. Zbýlých 8 obrázků Bland-Altmanových grafů je možné vidět v příloze A.



Obrázek 38: Srovnání odhadnutých a referenčních křivek fHR ze záznamu r01 pomocí Bland-Altmanova grafu.




(a) Srovnání referenční a odhadnuté křivky fHR pomocí hybridní metody ICA-ANFIS-WT.




(b) Srovnání referenční a odhadnuté křivky fHR pomocí hybridní metody ICA-RLS-WT.

Obrázek 39: Srovnání odhadnutých a referenčních křivek fHR ze záznamu r08 pomocí Bland-Altmanova grafu.

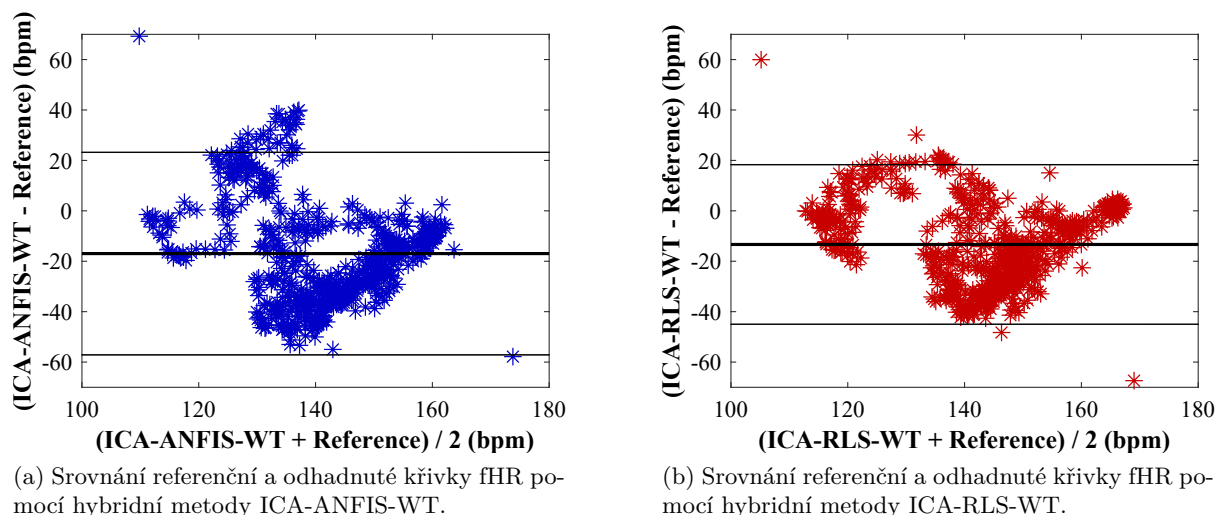


(a) Srovnání referenční a odhadnuté křivky fHR pomocí hybridní metody ICA-ANFIS-WT.



(b) Srovnání referenční a odhadnuté křivky fHR pomocí hybridní metody ICA-RLS-WT.

Obrázek 40: Srovnání odhadnutých a referenčních křivek fHR ze záznamu r04 pomocí Bland-Altmanova grafu.



Obrázek 41: Srovnání odhadnutých a referenčních křivek fHR ze záznamu r11 pomocí Bland-Altmanova grafu.

Jednotlivé stanovené střední hodnoty μ a hodnoty $1,96\sigma$ byly zaznamenány do tabulky 10. V této tabulce je potřeba sledovat, zda se střední hodnota μ blíží 0. Při vysoké kladné nebo záporné hodnotě střední hodnoty μ (v rozmezí $-0,5$ do $0,5$ bpm) bude zřejmé, že byly velké hodnoty ve vektoru diferencí \vec{D} . To značí velký rozdíl mezi křivkami odhadnutých a referenčních fHR. Podobného jevu pak lze sledovat v hodnotách $1,96\sigma$ (v rozmezí -5 do 5 bpm). Z tabulky 10 je patrné, že u záznamů r01, r02, r03, r05, r08 a r09 bylo dosaženo střední hodnoty μ v rozmezí $-0,5$ až $0,5$ bpm. U těchto záznamů lze předpokládat, že hybridní metoda ICA-ANFIS-WT byla účinná. Nicméně u záznamu r03 lze vidět, že má hodnotu $1,96\sigma$ mimo rozmezí -5 až 5 bpm, proto u tohoto záznamů je potřeba tento předpoklad vyvrátit. To znamená, že u záznamů r01, r02, r05, r08 a r09 lze na základě tohoto testování sledovat dobrou účinnost odhadnutí křivky fHR pomocí hybridní metody ICA-ANFIS-WT.

V tabulce 10 můžeme vidět obdobné výsledky pro hybridní metodu ICA-RLS-WT. Lze vidět, že tato hybridní metoda dosáhla u záznamů r01, r02, r03, r05, r06, r08, r09 a r10 střední hodnoty μ v rozmezí $-0,5$ až $0,5$ bpm. U těchto záznamů lze předpokládat, že hybridní metoda ICA-RLS-WT dokázala s velkou přesností odhadnout křivku fHR. U záznamů r03, r04 a r10 lze vidět, že mají hodnoty $1,96\sigma$ mimo rozmezí -5 až 5 bpm, proto u těchto záznamů je potřeba tento předpoklad vyvrátit. Hybridní metoda ICA-RLS-WT je tedy dle tohoto hodnocení účinná u záznamů r01, r02, r05, r08 a r09.

Tabulka 10: Zaznamenané střední hodnoty μ a hodnoty $1,96\sigma$ po provedení Bland-Altmanových grafů pro jednotlivé upravené odhadnuté křivky fHR pomocí obou hybridních metod vzhledem k referenčním křivkám fHR (databáze ADFECGDB).

Záznam	ICA-ANFIS-WT		ICA-RLS-WT	
	μ (bpm)	$1,96\sigma$ (bpm)	μ (bpm)	$1,96\sigma$ (bpm)
r01	0,01	1,64	0,01	1,64
r02	0,03	3,00	0,03	3,06
r03	0,46	5,15	0,12	5,31
r04	-1,94	25,63	1,28	8,84
r05	-0,02	2,38	0,01	1,91
r06	-2,08	15,84	0,27	10,40
r07	5,25	17,43	0,99	8,34
r08	0,01	1,92	0,02	1,91
r09	-0,15	4,28	-0,08	4,19
r10	6,12	19,31	0,11	7,81
r11	-15,12	37,79	-13,34	31,65
r12	-18,21	19,72	-1,56	20,25

7.2 Experimenty na reálných datech z databáze EKG physionet challenge 2013

Výsledky v této podkapitole budou rozděleny do 3 částí. V první části bude provedeno stanovení TP, FP a FN (viz kapitola 5.7.1) ze všech extrahovaných fEKG signálů pomocí obou hybridních metod na 25 záznamech z databáze EKG physionet challenge 2013 a bude proveden výpočet parametrů ACC, SE, PPV a F1 k určení přesnosti detekce R kmitů. Ve druhé části této podkapitoly bude provedeno vizuální srovnání odhadnutých upravených křivek fHR pro subjektivní posouzení přesnosti filtrace vzhledem k referenčním křivkám fHR. Třetí část se bude zabývat sestavením Bland-Altmanových grafů (viz kapitola 5.7.2) pro posouzení přesnosti odhadnutí křivek fHR vzhledem k referenčním křivkám fHR a určí se střední hodnoty μ a hodnoty $1,96\sigma$.

7.2.1 Hodnocení na základě určení přesnosti detekce R kmitů

Obdobně jako u testování na záznamech z databáze ADFECGDB je i zde provedeno nalezení ideálního nastavení adaptivních metod a vhodné kombinace elektrod jako vstupu do obou hybridních metod. Zaznamenané nejlepší výsledky do tabulek pro jednotlivé kombinace elektrod obou hybridních metod pro všech 25 záznamů lze vidět v příloze B. V těchto tabulkách jsou opět zvýrazněny kombinace elektrod, které dosáhly největší přesnosti. Tyto zvýrazněné kombinace značí optimální vstupy do dané hybridní metody pro jednotlivé záznamy. Nejlepší extrakce byly stejně jako u minulého experimentu uloženy a použity pro experimenty na reálných datech z databáze EKG physionet challenge 2013.

Výsledky pro hybridní metodu ICA-ANFIS-WT lze vidět v tabulce 11. Tato tabulka obsahuje nalezení optimální kombinace vstupních elektrod, tvar funkcí příslušnosti, počet funkcí příslušnosti a počet epoch pro jednotlivé záznamy databáze EKG physionet challenge 2013. Dále

jsou v tabulce obsaženy výsledky stanovení TP, FP a FN a vypočtené hodnoty parametrů ACC, SE, PPV a F1. Lze vidět, že metoda fungovala na základě parametru ACC nad 95 % u záznamů a04, a05, a08, a15, a17 a a22 a nad 80 % u záznamu a01. U extrahovaného fEKG signálu ze záznamu a01 dosáhla hybridní metoda ICA-ANFIS-WT na základě parametru PPV nad 95 %. Tento fakt značí, že v extrahovaném fEKG signálu na záznamu a01 byl určen nízký počet FP hodnot, ale vysoký počet FN. U ostatních záznamů z databáze EKG physionet challenge 2013 nedosáhla hybridní metoda ICA-ANFIS-WT dobrých výsledků, a tudíž nebyla jako extrakční metoda na tyto záznamy účinná.

Tabulka 11: Ideální kombinace elektrod a nastavení metody ANFIS pro jednotlivé záznamy databáze EKG physionet challenge 2013. Stanovené počty TP, FP a FN na základě detekce pozic R kmitů v extrahovaných fEKG signálech pomocí hybridní metody ICA-ANFIS-WT vzhledem k referenčním pozicím R kmitů a výpočet parametrů ACC, SE, PPV a F1.

Záz.	Komb. elektr.	Tvar funkcí přísl.	Počet funkcí přísl.	Počet epoch	Počet R kmitů (anotace)	TP	FP	FN	ACC (%)	SE (%)	PPV (%)	F1 (%)
a01	1,3,4	gaussmf	2	10	145	131	3	14	88,51	90,35	97,76	93,91
a02	1,3	trimf	8	20	160	33	94	127	12,99	20,63	25,98	23,00
a03	3,4	gaussmf	2	10	128	74	30	54	46,84	57,81	71,15	63,79
a04	1,2	gaussmf	2	10	129	129	0	0	100,00	100,00	100,00	100,00
a05	1,4	gaussmf	2	10	129	129	0	0	100,00	100,00	100,00	100,00
a06	2,4	gbellmf	6	30	160	101	29	59	53,44	63,13	77,69	69,66
a07	1,2,3,4	trapmf	2	10	130	81	58	49	43,09	62,31	58,27	60,22
a08	1,4	gaussmf	2	10	128	128	0	0	100,00	100,00	100,00	100,00
a09	1,3,4	trapmf	6	20	130	27	68	103	13,64	20,77	28,42	24,00
a10	1,2,3,4	gaussmf	8	10	175	139	12	36	74,33	79,43	92,05	85,28
a11	1,3,4	trimf	10	30	140	31	72	109	14,62	22,14	30,10	25,51
a12	3,4	gaussmf	10	30	138	68	7	70	46,90	49,28	90,67	63,85
a13	1,2,4	trimf	2	30	126	98	29	28	63,23	77,78	77,17	77,47
a14	2,3	trapmf	2	30	123	63	37	60	39,38	51,22	63,00	56,50
a15	1,4	gaussmf	2	10	134	134	0	0	100,00	100,00	100,00	100,00
a16	1,3,4	trapmf	10	30	130	28	63	102	14,51	21,54	30,77	25,34
a17	1,2,4	trimf	4	30	132	132	0	0	100,00	100,00	100,00	100,00
a18	1,3,4	trapmf	4	30	150	25	89	125	10,46	16,67	21,93	18,94
a19	1,2,4	trimf	2	30	127	100	26	27	65,36	78,74	79,37	79,05
a20	1,2,3	trimf	6	20	131	62	65	69	31,63	47,33	48,82	48,06
a21	1,3,4	gaussmf	2	30	145	109	14	36	68,55	75,17	88,62	81,34
a22	1,4	gaussmf	2	10	126	126	0	0	100,00	100,00	100,00	100,00
a23	2,3,4	trimf	2	30	126	107	23	19	71,81	84,92	82,31	83,59
a24	2,3,4	trimf	2	30	123	95	28	28	62,91	77,24	77,24	77,24
a25	2,3,4	trimf	2	20	125	101	29	24	65,58	80,80	77,69	79,22

Obdobné hodnocení bylo provedeno pro hybridní metodu ICA-RLS-WT a výsledky lze vidět v tabulce 12. Tato tabulka obsahuje nalezení optimální kombinace vstupních elektrod a řádu RLS algoritmu pro jednotlivé záznamy databáze EKG physionet challenge 2013. Dále jsou v tabulce obsaženy výsledky stanovení TP, FP a FN a vypočtené hodnoty parametrů ACC, SE, PPV a F1. Na základě parametru ACC dosáhla tato metoda hodnoty nad 95 % u záznamů a03, a04, a05, a08, a15, a17 a a22, hodnoty nad 90 % u záznamů a12, a19 a a24 a hodnoty nad 80 % u záznamů a01, a14 a a25. U extrahovaného fEKG signálu ze záznamu a12 dosáhla hybridní metoda ICA-RLS-WT na základě parametru PPV a F1 hodnoty nad 95 %. Tento fakt značí, že v extrahovaném fEKG signálu na záznamu r03 byl určen nízký počet FP hodnot, ale vysoký

počet FN. U extrahovaného signálu na záznamu a19 dosáhla hybridní metoda ICA-RLS-WT na základě parametru SE hodnoty nad 95 %. Z tabulky je patrné, že na tomto záznamu metoda extrahovala fEKG signál, který obsahoval nízký počet FN, ale na druhou stranu vyšší počet FP. U extrahovaného signálu na záznamu a24 dosáhla hybridní metoda ICA-RLS-WT na základě parametrů SE, PPV i F1 hodnoty nad 95 %. Na základě všech parametrů kromě ACC tedy metoda fungovalo dobře na záznamu a24. A nakonec u extrahovaného signálu na záznamu a14 dosáhla hybridní metoda ICA-RLS-WT na základě parametru SE hodnoty nad 95 %. Lze vidět, že na tomto záznamu metoda extrahovala fEKG signál, který obsahoval nízký počet FN, ale na vyšší počet FP. U ostatních záznamů z databáze EKG physionet challenge 2013 nebyla hybridní metoda ICA-RLS-WT účinná.



Tabulka 12: Ideální kombinace elektrod a nastavení řádu filtru algoritmu RLS pro jednotlivé záznamy databáze EKG physionet challenge 2013. Stanovené počty TP, FP a FN na základě detekce pozic R kmitů v extrahovaných fEKG signálech pomocí hybridní metody ICA-RLS-WT vzhledem k referenčním pozicím R kmitů a výpočet parametrů ACC, SE, PPV a F1.

Záznam	Kombinace elektrod	Řád filtru	Počet R kmitů (anotace)	TP	FP	FN	ACC (%)	SE (%)	PPV (%)	F1 (%)
a01	1,3,4	10	145	126	7	19	82,90	86,90	94,74	90,65
a02	1,2,4	2	160	31	90	129	12,40	19,38	25,62	22,06
a03	1,4	100	128	126	2	2	96,92	98,44	98,44	98,44
a04	1,2	64	129	129	0	0	100,00	100,00	100,00	100,00
a05	1,4	100	129	129	0	0	100,00	100,00	100,00	100,00
a06	2,4	24	160	95	39	65	47,74	59,38	70,90	64,63
a07	1,2,3,4	66	130	71	68	59	35,86	54,62	51,08	52,79
a08	1,4	100	128	128	0	0	100,00	100,00	100,00	100,00
a09	1,3,4	26	130	31	75	99	15,12	23,85	29,25	26,27
a10	1,2,3,4	6	175	130	17	45	67,71	74,29	88,44	80,75
a11	1,3,4	42	140	45	68	95	21,64	32,14	39,82	35,57
a12	1,3,4	14	138	130	2	8	92,86	94,20	98,49	96,30
a13	1,4	96	126	111	14	15	79,29	88,10	88,80	88,45
a14	1,3,4	10	123	117	12	6	86,67	95,12	90,70	92,86
a15	1,4	94	134	134	0	0	100,00	100,00	100,00	100,00
a16	1,4	40	130	21	22	109	13,82	16,15	48,84	24,28
a17	1,4	100	132	132	0	0	100,00	100,00	100,00	100,00
a18	1,3,4	68	150	27	89	123	11,30	18,00	23,28	20,30
a19	2,3	74	127	122	8	5	90,37	96,06	93,85	94,94
a20	2,3	94	131	92	14	39	63,45	70,23	86,79	77,64
a21	2,3,4	4	145	108	20	37	65,46	74,48	84,38	79,12
a22	1,4	32	126	126	0	0	100,00	100,00	100,00	100,00
a23	1,4	92	126	112	21	14	76,19	88,89	84,21	86,49
a24	1,3	50	123	117	3	6	92,86	95,12	97,50	96,30
a25	2,3	94	125	117	10	8	86,67	93,60	92,13	92,86

Během tohoto testování dosáhla hybridní metoda ICA-RLS-WT znatelně lepších výsledků než hybridní metoda ICA-ANFIS-WT. Celkově u 10 z 25 záznamů dokázala hybridní metoda ICA-RLS-WT extrahovat fEKG signály, které dosáhly na základě parametru ACC minimálně hodnoty 90 %, a ve výsledku u 13 z 25 záznamů dosáhla na základě parametru ACC minimálně hodnoty 80 %. Hybridní metoda ICA-ANFIS-WT dokázala extrahovat použitelné fEKG signály pouze u 7 z 25 záznamů.

7.2.2 Hodnocení na základě vizuálního srovnání

Pro provedení vizuálního hodnocení přesnosti extrakce fEKG signálů na záznamech z databáze EKG physionet challenge 2013 pomocí obou testovaných hybridních metod bylo opět nejdříve provedeno vytvoření křivek fHR pro jednotlivé extrahované fEKG signály. Obdobně byl použit algoritmus pro odstranění odlehlých hodnot a použito MA na jednotlivé odhadnuté křivky fHR.



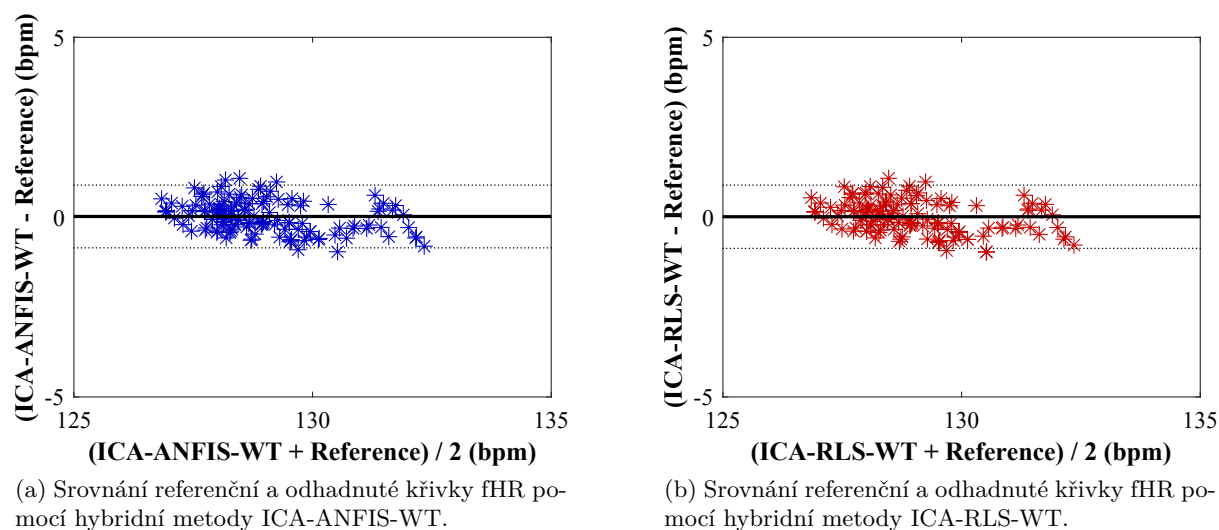
Obrázek 42: Grafické srovnání odhadnutých a referenčních křivek fHR ze všech 25 záznamů databáze EKG physionet challenge 2013.

Jednotlivé křivky fHR získané pomocí jednotlivých hybridních metod byly sloučeny za sebou do jednoho grafu spolu se sloučenými křivkami fHR danými referenčními anotacemi. Vizuální


hodnocení přesnosti odhadnutí křivek fHR pomocí hybridní metody ICA-ANFIS-WT lze vidět na obrázku 42a a pomocí hybridní metody ICA-ANFIS-WT lze vidět na obrázku 42b. V horní části obrázků jsou šipkou vyznačeny, které úseky jsou pro jednotlivé záznamy. Jeden záznam má délku 1 min, proto celkový signál složený z 25 záznamů má 25 min. Grafické zobrazení je provedeno opět podle klasifikace FIGO [35]. Z obrázku 42 je patrné, že hybridní metody dokázaly u některých záznamů extrahovat velice přesnou křivku vzhledem k referenční, ale u některých fungovaly nepřesně. Při tomto hodnocení je velice obtížné určit, která hybridní metoda dosáhla lepšího odhadnutí křivky fHR vzhledem k referenční křivce fHR. Například u záznamu a23 lze vidět lepší odhadnutí křivky fHR u hybridní metody ICA-ANFIS-WT, ale u záznamu a14 naopak tato metoda fungovala hůře.

7.2.3 Hodnocení na základě sestavení Bland-Altmanových grafů


Toto testování obsahuje sestavení Bland-Altmanových grafů mezi jednotlivými odhadnutými a referenčními křivkami fHR po úpravách. Sestavení bylo provedeno stejným postupem jako bylo vysvětleno u testování na databázi ADFECGDB. Pro ukázkou byly zvoleny 2 záznamy, kde extrakce dosahovala nejlepších výsledků (záznam a05 a a08), viz obrázek 43 a 44, a 2 záznamy, kde extrakce dosahovala nejhorších výsledků (záznam a02 a a18), viz obrázek 45 a 46. Zbýlých 21 obrázků Bland-Altmanových grafů je možné vidět v příloze B.



Obrázek 43: Srovnání odhadnutých a referenčních křivek fHR ze záznamu a05 pomocí Bland-Altmanova grafu.




(a) Srovnání referenční a odhadnuté křivky fHR pomocí hybridní metody ICA-ANFIS-WT.




(b) Srovnání referenční a odhadnuté křivky fHR pomocí hybridní metody ICA-RLS-WT.

Obrázek 44: Srovnání odhadnutých a referenčních křivek fHR ze záznamu a08 pomocí Bland-Altmanova grafu.

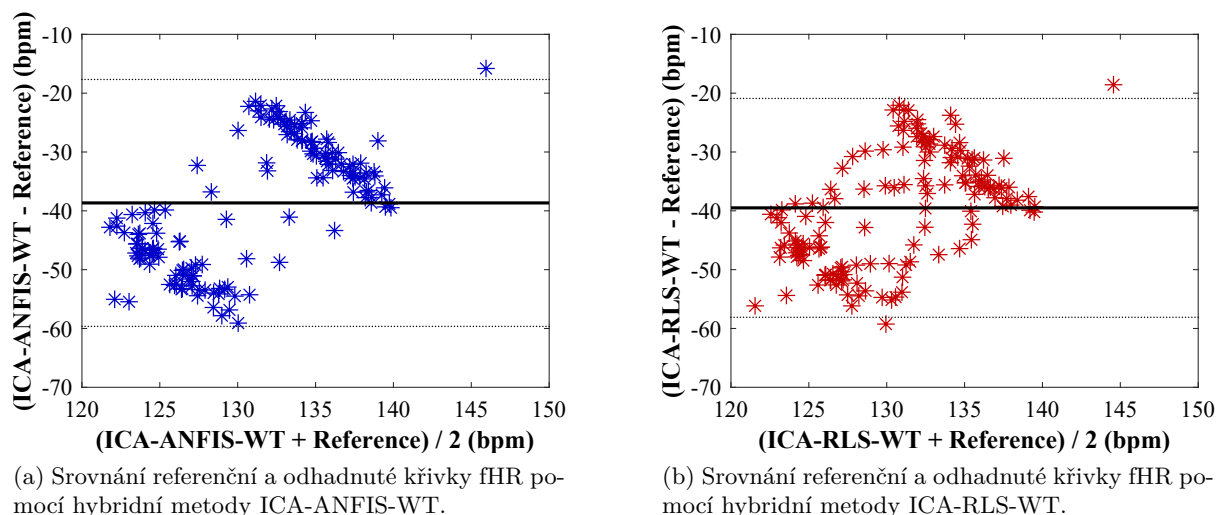


(a) Srovnání referenční a odhadnuté křivky fHR pomocí hybridní metody ICA-ANFIS-WT.



(b) Srovnání referenční a odhadnuté křivky fHR pomocí hybridní metody ICA-RLS-WT.

Obrázek 45: Srovnání odhadnutých a referenčních křivek fHR ze záznamu a02 pomocí Bland-Altmanova grafu.



Obrázek 46: Srovnání odhadnutých a referenčních křivek fHR ze záznamu a18 pomocí Bland-Altmanova grafu.

Tabulka 13: Zaznamenané střední hodnoty μ a hodnoty $1,96\sigma$ po provedení Bland-Altmanových grafů pro jednotlivé upravené odhadnuté křivky fHR pomocí obou hybridních metod vzhledem k referenčním křivkám fHR (databáze EKG physionet challenge 2013).

Záznam	ICA-ANFIS-WT		ICA-RLS-WT	
	μ (bpm)	$1,96\sigma$ (bpm)	μ (bpm)	$1,96\sigma$ (bpm)
a1	1,22	11,96	1,35	11,89
a2	-33,48	30,96	-33,38	30,69
a3	9,21	31,82	0,13	4,50
a4	0,01	2,29	0,01	2,33
a5	0,02	0,87	0,01	0,88
a6	-6,80	16,88	-7,36	16,96
a7	0,67	16,01	15,27	20,98
a8	0,02	1,01	0,04	1,05
a9	-28,68	23,39	-18,28	16,37
a10	-7,86	20,31	-13,97	14,56
a11	-34,96	12,95	-17,65	25,50
a12	-5,01	16,04	-0,27	4,45
a13	5,88	12,80	0,92	5,23
a14	6,28	16,73	3,29	16,44
a15	-0,05	2,10	-0,05	2,10
a16	-12,22	41,04	-26,30	27,52
a17	0,04	1,47	0,05	1,46
a18	-35,80	22,30	-39,50	18,60
a19	3,24	8,57	0,28	2,75
a20	0,85	26,04	-2,23	8,97
a21	-1,18	10,94	-5,12	12,28
a22	0,04	1,35	0,05	1,33
a23	-0,03	4,18	2,72	15,27
a24	0,76	5,51	0,48	4,04
a25	0,60	4,41	0,77	6,50


Stanovené střední hodnoty μ a hodnoty $1,96\sigma$ ze všech 25 záznamů jsou zaznamenány v tabulce 13. V tabulce 13 lze vidět, že u 14 záznamů (a01, a04, a05, a07, a08, a15, a17, a19, a20, a21, a22, a23, a24 a a25) bylo dosaženo střední hodnoty μ v rozmezí -0,5 až 0,5 bpm. U těchto

záznamů lze předpokládat, že hybridní metoda ICA-ANFIS-WT byla účinná. Nicméně u záznamů a01, a07, a19, a20, a21 a a24 lze vidět, že mají hodnotu $1,96\sigma$ mimo rozmezí -5 až 5 bpm. U těchto záznamů je potřeba předpoklad správné extrakce křivky fHR vyvrátit. Dobrou účinnost odhadnutí křivky fHR pomocí hybridní metody ICA-ANFIS-WT lze tedy sledovat na základě tohoto testování pouze u 8 záznamů (a04, a05, a08, a15, a17, a22, a23 a a25).

V druhé části tabulky 13 můžeme vidět obdobné výsledky pro hybridní metodu ICA-RLS-WT. Lze vidět, že tato hybridní metoda dosáhla u 16 záznamů (a01, a03, a04, a05, a08, a12, a13, a14, a15, a17, a19, a20, a22, a23, a24 a a25) střední hodnoty μ v rozmezí -0,5 až 0,5 bpm. U těchto záznamů lze předpokládat, že hybridní metoda ICA-RLS-WT dokázala s velkou přesností odhadnout křivku fHR. Avšak u záznamů a01, a13, a14, a20, a23 a 25 lze vidět, že mají hodnotu $1,96\sigma$ mimo rozmezí -5 až 5 bpm, proto u těchto záznamů je potřeba tento předpoklad vyvrátit. Hybridní metoda ICA-RLS-WT je tedy dle tohoto hodnocení účinná u 10 záznamů z databáze EKG physionet challenge 2013. Toto hodnocení ovšem opět dokazuje lepší přesnost hybridní metody ICA-RLS-WT v porovnání s hybridní metodou ICA-ANFIS-WT.

8 Diskuze

Výsledky v předchozí podkapitole a v přílohách A a B ukazují, že představené hybridní metody jsou velmi účinné na většinu testovaných záznamů. Pro některé záznamy, či jejich úseky, je však jejich efektivita omezená. Jako příklad je v této kapitole nejdříve detailně rozebrán záznam r10 ve spojitosti s metodou ICA-RLS-WT, a poté záznamy r03, a08 a a18 k porovnání účinnosti filtrace obou hybridních metod.

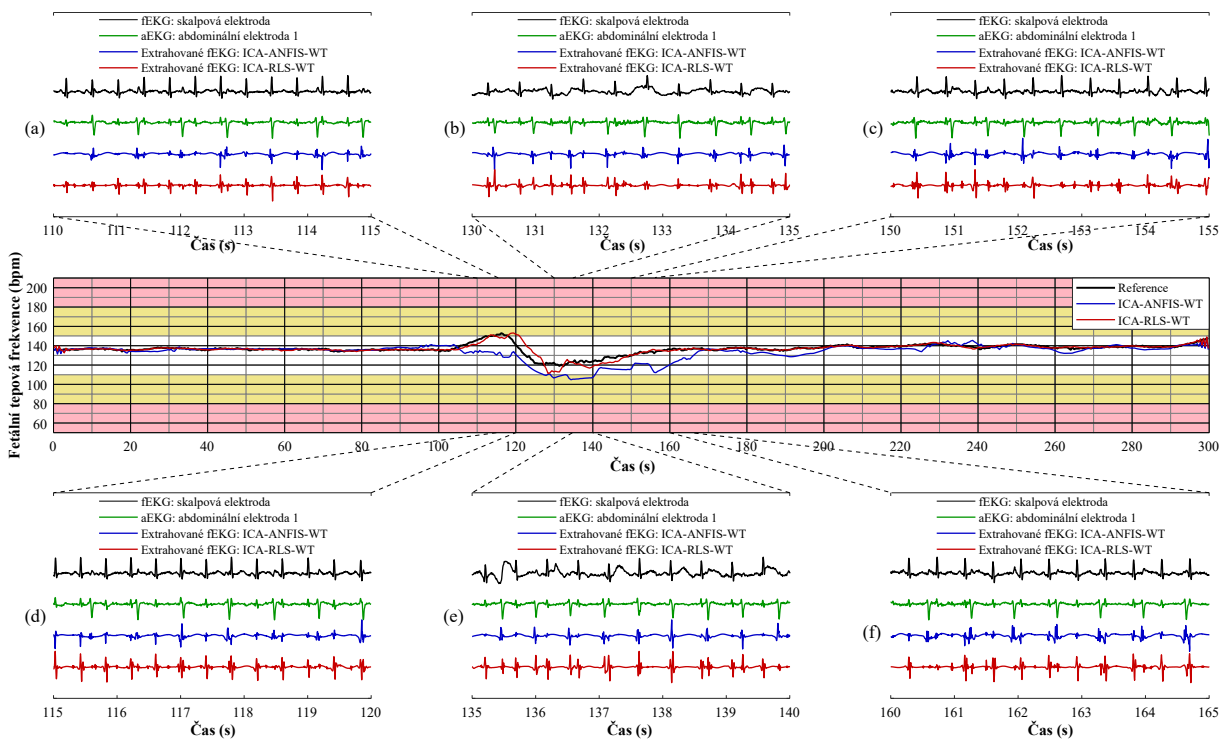


Obrázek 47: Odhadnutá křivka fHR pomocí metody ICA-RLS-WT na záznamu r10. Grafy (a), (b) a (c) znázorňují 3 vybrané úseky, kde filtrace nefungovala, a grafy (d), (e) a (f) znázorňují 3 vybrané úseky, kde filtrace fungovala správně.

Obrázek 47 zobrazuje odhadnutou křivku fHR pomocí hybridní metody ICA-RLS-WT pro porovnání s referenční křivkou fHR získanou ze záznamu r10 pomocí anotací. Dále tento obrázek obsahuje šest vybraných úseků o délce 5 s. Tři úseky se vztahují k případům, kdy se výsledná křivka fHR výrazně odchýlila od referenční a v případě delšího trvání by mohla vést ke špatné diagnostice hypoxie plodu. Zbývající tři úseky se pak vztahují k případům, kde se určená křivka fHR shodovala s referenční. Analýza těchto šesti úseků obsahuje ukázkou tří signálů z daného časového intervalu: referenční fEKG signál z FSE, aEKG signál naměřený abdominální elektrodou 1 a fEKG signál odhadnutý pomocí hybridní metody ICA-RLS-WT. Z těchto ukázek je zřejmé, že kvalita extrakce je závislá na kvalitě vstupních aEKG signálů. V případě úseků, kde byla kvalita vstupních aEKG signálů neadekvátní, nebyla hybridní metoda ICA-RLS-WT schopna správně extrahovat fEKG signál. To vedlo ke zvýšení množství hodnot FP, a tudíž i ke snížení

parametrů hodnotící kvalitu extrakce (ACC, PPV a F1), viz obrázek 47(a) až obrázek 47(c). U úseků s kvalitními aEKG signály, byl neužitečný signál potlačen do té míry, že bylo možné dosáhnout úspěšné detekce R kmitů, viz obrázek 47(d) až obrázek 47(f). Určená křivka fHR se v těchto místech tudíž shoduje s referenční křivkou fHR. V případě klinického použití této hybridní metody, je tudíž zásadní zachovat vysokou kvalitu aEKG signálů. Tu negativně ovlivňuje zejména nedostatečné přilnutí měřicích elektrod a jejich rozmístění, pozice plodu, pohyb matky a popřípadě zvolená vzorkovací frekvence.

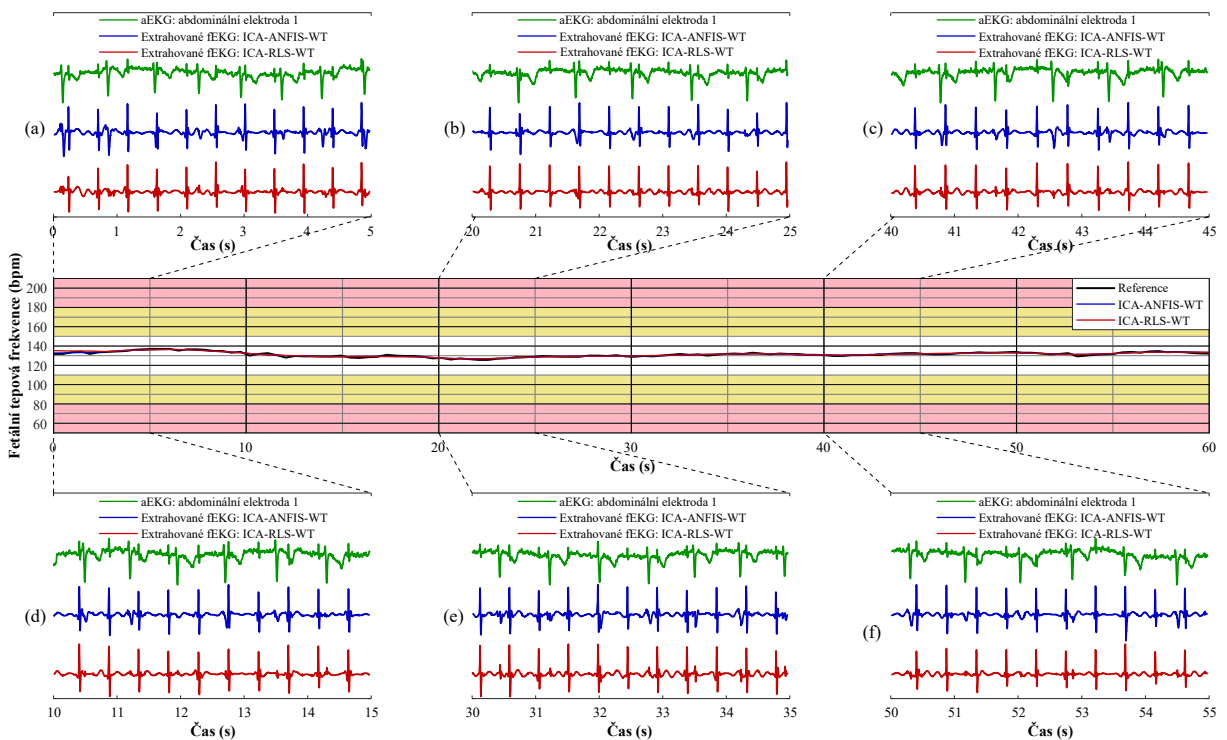
Dalším z faktorů, který má obrovský vliv na kvalitu extrakce pomocí zde představeného hybridního systému, je optimální nastavení adaptivních metod. Jak bylo zkoumáno ve studii [137], toto nastavení se mění v závislosti na rozmístění vstupních elektrod (mEKG a aEKG signály). V této práci je však referenční mEKG signál odhadnut pomocí ICA metody. Cílem budoucí práce je tudíž nutné provést podrobnější optimalizaci nastavení adaptivních metod zejména v závislosti na různých faktorech, jako je například výběru množství a umístění vstupních elektrod hybridního systému, gestační věk plodu nebo jeho poloha. Zároveň je třeba otestovat a porovnat kombinace různých metod v každém bloku hybridního extrakčního systému v závislosti na výše zmíněných faktorech. Jednotlivé složky systému je totiž možné nahradit jinou metodou, která by převzala jeho funkci.



Obrázek 48: Odhadnutá křivka fHR pomocí hybridních metod ICA-ANFIS-WT a ICA-RLS-WT na záznamu r03. Grafy (a) až (f) znázorňují vybrané úseky pro srovnání účinnosti obou metod.

Obrázek 48 ukazuje srovnání určených křivek fHR pomocí testovaných hybridních metod ICA-ANFIS-WT a ICA-RLS-WT na záznamu r03 v porovnání s referenční křivkou fHR získanou

ze záznamu pomocí anotací. Obrázky 48(a) až 48(f) obsahují srovnání 6 úseků referenčního fEKG signálu z FSE, aEKG signálu naměřeného abdominální elektrodou 1 a fEKG signálů odhadnutých pomocí hybridní metody ICA-ANFIS-WT a ICA-RLS-WT. Lze konstatovat, že hybridní metoda ICA-RLS-WT je více schopná kopírovat trend v rámci výsledné křivky fHR. Hybridní metoda využívající ANFIS nebyla v některých úsecích schopna potlačit mateřskou komponentu z aEKG signálu. Výsledná křivka fHR tudíž korelovala s mHR, která má nižší hodnoty než fHR. Oproti tomu hybridní metoda ICA-RLS-WT byla, až na výjimky, viz úsek v obrázku 48(e), schopna úspěšně potlačit mateřskou komponentu do té míry, že neovlivňovala následnou detekci R-R intervalů, a tudíž i stanovení výsledné křivky fHR.

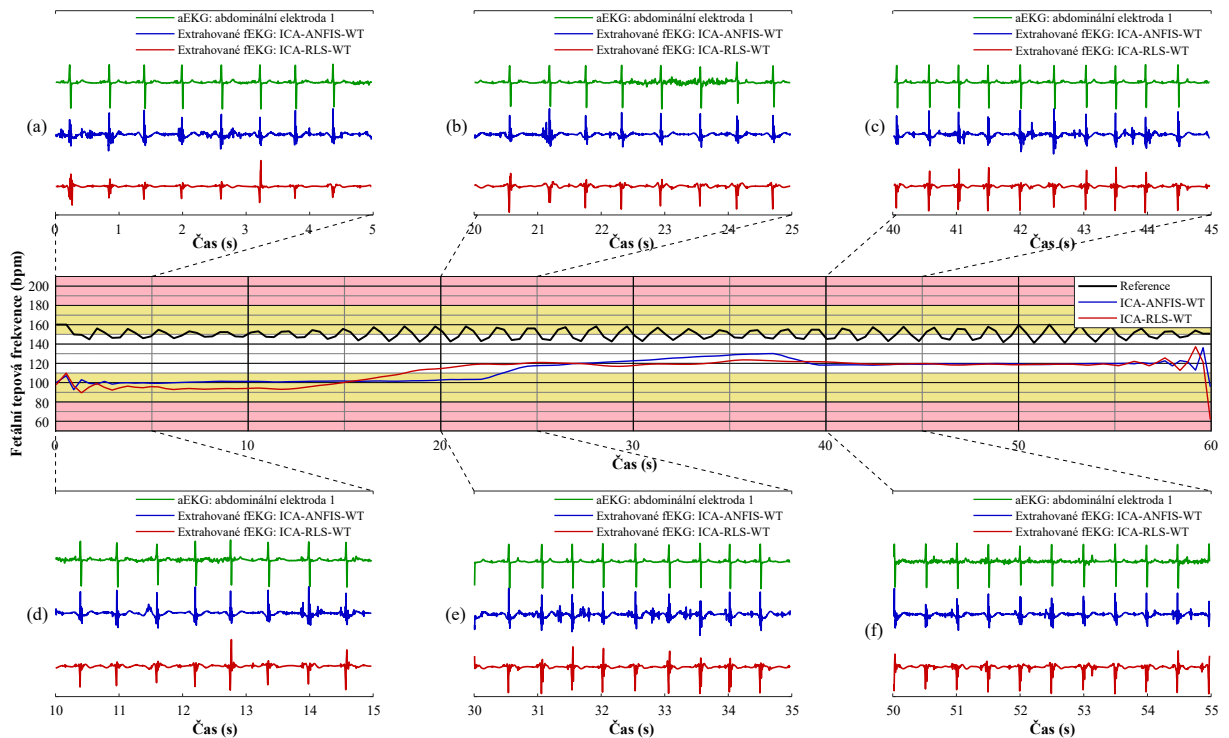


Obrázek 49: Odhadnutá křivka fHR pomocí hybridních metod ICA-ANFIS-WT a ICA-RLS-WT na záznamu a08. Grafy (a) až (f) znázorňují vybrané úseky, kde filtraci obou hybridních metod fungovala správně.

Obrázek 49 zobrazuje srovnání referenční křivky fHR s odhadnutými křivkami fHR pomocí hybridních metod ICA-ANFIS-WT a ICA-RLS-WT na záznamu a08. Obrázky 49(a) až 49(f) obsahují srovnání 6 úseků aEKG signálu naměřeného abdominální elektrodou 1 a fEKG signálů odhadnutých pomocí hybridní metody ICA-ANFIS-WT a ICA-RLS-WT. Na tomto záznamu dosáhla filtrace 100 % pro všechny hodnotící parametry. Lze vidět, že stanovená křivka fHR pomocí obou hybridních metod je zde téměř totožná s referenční křivkou fHR. Také lze pozorovat na obrázcích 49(a) až 49(f), že z extrahovaných fEKG signálu je snadné přesně stanovit správné pozice R kmitů.

Obrázek 50 zobrazuje srovnání referenční křivky fHR s odhadnutými křivkami fHR pomocí

hybridních metod ICA-ANFIS-WT a ICA-RLS-WT na záznamu a18, což byl záznam, kde obě hybridní metody dosáhly nejhorších výsledků. Obrázky 50(a) až 50(f) obsahují srovnání 6 úseků aEKG signálu naměřeného abdominální elektrodou 1 a fEKG signálů odhadnutých pomocí hybridní metody ICA-ANFIS-WT a ICA-RLS-WT. Je možné si všimnout, že ve vstupním aEKG signálu je fetální složka prakticky nepatrná ve srovnání s materskou složkou. Pro takový signál je extrakce náročná a prakticky nemožná. V obrázcích 50(a) až 50(f) lze vidět tvar aEKG signálu ve srovnání s odhadnutými křivkami. Lze vidět, že takový vstupní aEKG signál je opravdu pro extrakci nepoužitelný, proto extrahované fEKG signály vypadají nepozměněny v porovnání s tímto aEKG signálem.



Obrázek 50: Odhadnutá křivka fHR pomocí hybridních metod ICA-ANFIS-WT a ICA-RLS-WT na záznamu a18. Grafy (a) až (f) znázorňují vybrané úseky, kde filtraci obou hybridních metod nefungovala.

Je třeba poznamenat, že databáze EKG physionet challenge 2013 se skládá z různých záznamů. Část záznamů je převzata z různých fEKG databází pomocí různých rozmístění elektrod, zatímco jiné záznamy jsou syntetické. Lze si všimnout, že signály ve velkém množství záznamů se výrazně liší od skutečných nahrávek. V obrázku 50 lze vidět, že referenční křivka fHR má po celou 1 min prakticky sinusovou fHRV. Při vykreslení křivek fHR jednotlivých záznamů z databáze EKG physionet challenge 2013 byl tento fenomén vypořizován u 10 z 25 záznamů (a01, a02, a06, a07, a09, a10, a11, a16, a18 a a21). U těchto záznamů lze vidět i z tabulky 11 a 12, že na nich obě hybridní metody dosáhly nejhorších výsledků. Výjimkou je záznam a01, u kterého obě hybridní metody dosáhly přesnosti nad 80 %. Tímto se vysvětluje, proč hybridní me-

toda ICA-RLS-WT, která předčila výkonnostně hybridní metodu ICA-ANFIS-WT při testování na databázi ADFECGDB, byla schopná extrahovat použitelné záznamy jen u 13 z 25 záznamů.

Tato doktorská disertační práce se zabývala využitím hybridních metod pro zpracování fEKG signálu. Téma zpracování fEKG signálu je velmi aktuální a řešené výzkumnými týmy po celém světě. Současné přístupy ovšem nejsou stále schopny extrahovat kvalitní fEKG signál, který by byl vhodný k provedení hlubší morfologické analýzy (ST segment analýzy, QT segment analýzy, a podobně). To by vedlo k lepšímu monitorování hypoxie plodu a ke snížení počtu zbytečně provedených operativních ukončení těhotenství pro domnělou hypoxii určenou na základě stanovení fHR.

Velkým problémem současného vývoje je kvalita naměřených aEKG signálů. Může za to rozmístění elektrod, zvolená vzorkovací frekvence, pohyby matky a plodu, poloha plodu, a podobně. Naměřené aEKG signály, kde má plodová složka amplitudu aspoň poloviční v porovnání s mateřskou složkou, jsou ideální pro hybridní systémy. Další výhodou je, když má plodová a mateřská komponenta v těchto signálech stejnou polaritu. V případě, kdy polarita plodu je v jednom vstupním aEKG signálu směrem nahoru a v druhém směrem dolů, je velice obtížné pro navržené hybridní metody provést správnou extrakci fEKG signálu. Je vhodné tedy mít více vstupních aEKG signálů, kdy si uživatel zvolí dle vizuální kontroly (nebo rozhodovacím algoritmem), které vstupní aEKG signály použije. V praxi je vhodné zvolit počet elektrod tak, aby splňoval kompromis mezi nutností použití více vstupních aEKG signálů a mezi vysokým odběrem energie. Velký počet měřících elektrod by mohl být neideální pro implementované hybridní metody na programovatelná hradlová pole z důvodu velkého odběru energie. Hlavním cílem výzkumu je primárně vytvořit novou diagnostickou metodu založenou na NI-fEKG.

9 Závěr

Prostudováním současného stavu řešení problematiky extrakce fEKG signálu pomocí různých neadaptivních a hybridních metod bylo stanoveno 5 hlavních cílů, viz kapitola 4. Všechny stanovené cíle doktorské disertační práce byly splněny. Níže jsou zmíněny všechny stanovené cíle a postup jejich splnění.

1. *Provedení hloubkové rešerše současného stavu problematiky extrakce fEKG signálu s využitím hybridních metod pro zpracování fEKG signálu.*

Tento cíl byl splněn v kapitole 3, kde byla provedena rešerše a popis používaných jednonábových neadaptivních metod, vícekanálových neadaptivních metod a hybridních metod zpracování fEKG signálu. V kapitole 1 byl proveden úvod do této práce a v kapitole 2 byly rozebrány používané metody monitorování stavu plodu v klinické praxi.

2. *Návrh a realizace nového typu hybridních metod pro zpracování fEKG signálů, které budou kombinovat výhody jednotlivých metod.*

Tento bod byl splněn výběrem a naprogramováním 4 extrakčních metod (ICA, ANFIS, RLS a WT), které byly propojeny mezi bloky, aby výstup z jedné metody byl vždy vstupem do druhé. Tímto byly vytvořeny hybridní metody ICA-ANFIS-WT a ICA-RLS-WT založené v první části na vytvoření aEKG* a mEKG signálu pomocí ICA metody. Tyto dva signály byly následně přivedeny na vstup adaptivních metod, kde byla provedena extrakce fEKG signálu a tento signál byl následně vyhlazen pomocí WT. Podrobný popis jednotlivých použitých metod byl proveden v kapitole 5.

3. *Návrh a realizace modulární softwarové aplikace pro testování zkoumaných hybridních metod.*

Tento cíl byl splněn v kapitole 6. V této kapitole je proveden rozbor všech částí hybridních systémů pro možné zopakování experimentu. Jednotlivé bloky hybridních metod obsahují naprogramované metody sloužící pro úpravu signálu během chodu extrakce fEKG signálu a stanovení křivky fHR. Ke každému bloku je proveden náčrt blokového schématu včetně změny tvaru signálu pro lepší pochopení funkčnosti hybridních metod.

4. *Realizace série experimentů na reálných datech z klinické praxe (databáze ADFECGDB [13, 46, 47, 48, 49] a databáze EKG physionet challenge 2013 [49, 93]). Velká část současných publikací využívá totiž pro ověření teoretického výzkumu pouze simulace. Řada metod, které v simulacích vykazují velice dobré výsledky, není možno v reálných aplikacích použít.*

Realizace experimentů byla provedena v programu MATLAB 2018b. Důvodem použití těchto databází je, že jsou velice často využívány ve studiích zaměřených na zpracování fEKG signálu, proto lze provést srovnání dosažených výsledků s jinou prací. Simulovaná data nebyly použita, protože řada metod, které v simulacích vykazují velice dobré výsledky, není možno v reálných aplikacích použít. Pro testování bylo použito všech 12 záznamů z databáze ADFECGDB (5 veřejně dostupných na stránkách physionetu a zbylých 7 poskytl profesor Janusz Jezewski z Ústavu lékařské technologie a vybavení z Polského

města Zabrze) a na setu A z databáze EKG physionet challenge 2013, který obsahuje 25 záznamů. Experimenty byly provedeny na vysoce výkonném počítači, kde v cyklech probíhaly několikadenní testy.

5. *Provedení objektivního hodnocení úspěšnosti extrakce fEKG signálu pomocí hybridních metod podle autorem navržené metodiky.*

Pro splnění tohoto cíle bylo zvoleno hodnocení na základě určení přesnosti detekce R kmitů, srovnání odhadnutých a referenčních křivek fHR a sestrojením Bland-Altmanových grafů. Výsledky experimentů byly zaznamenány v kapitole 7 spolu s ukázkami důležitých obrázků a shrnujících tabulek. Zbytek obrázků a tabulek, které jsou určeny spíš pro doplnění představy o výsledcích, jsou uvedeny v přílohách A a B.

Výsledky experimentů dokazují, že navržené hybridní metody dosáhly lepších výsledků, než jednotlivé metody v předchozích studiích a mají velkou perspektivu pro budoucí využití v klinické praxi pro vytvoření nové neinvazivní diagnostické metody založené na zpracování NI-fEKG signálu. Při srovnání hybridní metody ICA-ANFIS-WT a ICA-RLS-WT bylo prokázáno, že využití adaptivní metody ANFIS jako hlavní části hybridních metod není v tomto případě stejně efektivní jako využití RLS algoritmu. Během experimentů na záznamech z databáze ADFECGDB dosáhla hybridní metoda ICA-RLS-WT hodnoty $ACC > 80\%$ u 10 z 12 záznamů a hybridní metoda ICA-ANFIS-WT hodnoty $ACC > 80\%$ pouze u 6 z 12 záznamů. Na základě tohoto dobrého výsledku byl proveden experiment na záznamech z databáze EKG physionet challenge 2013. Hybridní metoda ICA-RLS-WT dosáhla hodnoty $ACC > 80\%$ u 13 z 25 záznamů a hybridní metoda ICA-ANFIS-WT hodnoty $ACC > 80\%$ pouze u 7 z 25 záznamů. Tento méně přesvědčivý výsledek v porovnání s databází ADFECGDB byl diskutován v kapitole 8. U 10 záznamů z databáze EKG physionet challenge 2013 bylo vypořádáno, že křivka fHR má prakticky sinusovou fHRV. U těchto záznamů hybridní metody nebyly schopny provést správnou extrakci fEKG signálu. Záznamy z databáze EKG physionet challenge 2013 nelze považovat v porovnání s databází ADFECGDB za příliš dobré k otestování funkčnosti použitých metod zpracování fEKG signálu.

Hybridní metody spojují pozitiva adaptivních i neadaptivních přístupů, jako je přesnost, stabilita a minimalizace počtu měřicích elektrod. Tato studie ukazuje, že tento přístup je velice slibný pro extrakci fEKG signálu a velmi přesný pro potřeby stanovení fHR, jakožto hlavního parametru sledovaného v současné klinické praxi. Předmětem dalšího výzkumu by měla být hlubší morfologická analýza, jako je ST segment analýza, QT segment analýza, a podobně. To by vedlo k vytvoření nové diagnostické metody (neinvazivní varianty ST segment analyzátoru) a tím zlepšení diagnostiky fetální hypoxie.

V této práci byla pozornost soustředěna zejména na přesné určení fHR. Nicméně v klinické praxi se při elektronické monitoraci plodu pomocí KTG sleduje jak fHR, tak děložní kontrakce. V případě systému na bázi fEKG by bylo možné elektrický signál produkovaný stahující se dělohy nahrávat metodou označovanou jako elektrohysterografie (EHG), jejíž účinnost byla ověřena

ve studiích [162, 163, 164]. Pro budoucí výzkum je nezbytné zakomponovat měření a filtraci děložních kontrakcí do komplexního systému pro monitoraci plodu na bázi NI-fEKG.

Navrhovaný hybridní systém by mohl být vylepšen úpravou jeho jednotlivých částí. Adaptivní metody by mohly být nahrazeny odlišnými typy jako je například LMS, normalizované LMS, QR-RLS, ADALINE, a podobně. Velké množství známých adaptivních metod je totiž součástí knihovny digitálního zpracování signálu v programu MATLAB. Výhodou využití adaptivní metody jako hlavní součásti hybridního systému je, že kompenzuje zpoždění a rušení.

Počáteční blok extrakčního systému prováděný pomocí metody ICA a sloužící pro odhad vstupů mEKG a aEKG* do adaptivních metod může být například nahrazen jinou metodou schopnou odhadnout mateřskou složku. K tomuto účelu by mohla být například použita metoda PCA. Největší výhodou použití neadaptivní metody ICA (nebo metody PCA) je, že vyžaduje jako vstup pouze břišní elektrody. V provedené hloubkové rešerši bylo zmíněno, že existuje mnoho metod založených na metodě ICA, které by mohla být využity k účelu odhadnutí potřebných signálů. Patří mezi ně metody FastICA, SCICA, JADE, InfoMax, MeRMaId, MICA, NpICA, FlexiICA, OgICA, FastAdaptOgICA, a podobně.

V této práci byla v posledním kroku použita WT. Tato metoda je velice účinná pro účely detekce R kmitů, které jsou důležité pro stanovení fHR. Na druhou stranu má tato metoda negativní účinky na morfologii fEKG křivky. Pro účely neinvazivní varianty ST segment analyzátoru by se tedy v budoucnosti musela v tomto hybridním systému najít náhrada pro konečný krok zpracování fEKG signálu. Alternativou je využití WT pouze k přesnému nalezení poloh R-kmitů. Následná morfologická analýza by byla provedena pouze na fEKG signálech, které nebyly zpracovány pomocí WT (hybridní metody ICA-ANFIS a ICA-RLS).

Nicméně lze konstatovat, že konstrukce hybridních metod dosahuje slibné účinnosti extrakce fEKG signálu. Některé již mnohokrát otestované metody dosahují také dobré účinnosti extrakce fEKG signálu, ale pouze pro záznamy naměřené s dostatečným GA, kdy je plodová komponenta výrazná. Pro nižší GA pracují s dobrou přesností pouze hybridní metody, což je jejich velkou výhodou. Lze předpokládat, že by tyto metody mohly být použity v klinické praxi jako náhrada klasického KTG. Před zavedením těchto metod do klinické praxe je však potřeba se vypořádat s negativními faktory ovlivňujícími efektivitu extrakčního systému. Jedná se zejména o kvalitu aEKG záznamů, která je ovlivněna především umístěním a přilnutím měřicích elektrod, zvolenou vzorkovací frekvencí, pohybem matky či pohybem plodu. Současně s tou doktorskou disertační prací je dalším členem našeho výzkumného týmu řešena doktorská disertační práce, která se zaměřuje na optimální rozmístění elektrod a optimalizaci nastavení jednotlivých dílčích adaptivních metod.

Budoucí výzkum by samozřejmě mohl být zaměřen také na vyzkoušení a modifikování úplně jiného typu hybridního systému. Z provedené rešerše v teoretické části této práce je zřejmé, že existuje velké množství různých hybridních metod [RJ1]. Většina v současnosti dostupných hybridních metod využívá ICA metodu. Velmi zajímavé hybridní metody jsou například hybridní metody ICA-EEMD-WS [108], FAMC-AFE-ICA [110], ICA-PF [111], BM-ZM [119], a podobně.

Literatura

1. SMYTH, C. Experimental electrocardiography of the foetus. *The Lancet*. 1953, roč. 261, č. 6771, s. 1124–1126. ISSN 0140-6736. Dostupné z DOI: 10.1016/S0140-6736(53)92309-5.
2. MARTIN, C. B. Electronic fetal monitoring: a brief summary of its development, problems and prospects. *European Journal of Obstetrics & Gynecology and Reproductive Biology*. 1998, roč. 78, č. 2, s. 133–140. ISSN 0301-2115. Dostupné z DOI: 10.1016/S0301-2115(98)00059-1.
3. PETITTI, D.; OLSON, R. O.; WILLIAMS, R. L. Cesarean section in California–1960 through 1975. *American Journal of Obstetrics and Gynecology*. 1979, roč. 133, č. 4, s. 391–397. ISSN 0002-9378. Dostupné z DOI: 10.1016/0002-9378(79)90058-9.
4. WILLIAMS, R. L.; HAWES, W. E. Cesarean section, fetal monitoring, and perinatal mortality in California. *American Journal of Public Health*. 1979, roč. 69, č. 9, s. 864–870. ISSN 1541-0048. Dostupné z DOI: 10.2105/AJPH.69.9.864.
5. TAFFEL, S. M.; PLACEK, P. J.; MOIEN, M.; KOSARY, C. L. 1989 US cesarean section rate steadies–VBAC rate rises to nearly one in five. *Birth*. 1991, roč. 18, č. 2, s. 73–77. ISSN 1523-536X. Dostupné z DOI: 10.1111/j.1523-536X.1991.tb00063.x.
6. TAFFEL, S. M.; PLACEK, P. J.; LISS, T. Trends in the United States cesarean section rate and reasons for the 1980-85 rise. *American Journal of Public Health*. 1987, roč. 77, č. 8, s. 955–959. ISSN 1541-0048. Dostupné z DOI: 10.2105/AJPH.77.8.955.
7. CUNNINGHAM, F.; LEVENO, K.; BLOOM, S.; SPONG, C. Y.; DASHE, J. *Williams obstetrics, 24e*. Mcgraw-hill, 2014.
8. JAGANNATH, D.; SELVAKUMAR, A. I. Issues and research on foetal electrocardiogram signal elicitation. *Biomedical Signal Processing and Control*. 2014, roč. 10, s. 224–244. ISSN 1746-8094. Dostupné z DOI: 10.1016/j.bspc.2013.11.001.
9. SAMENI, R.; CLIFFORD, G. D. A Review of Fetal ECG Signal Processing Issues and Promising Directions. *The Open Pacing, Electrophysiology & Therapy Journal*. 2010, roč. 3, s. 4–20. ISSN 1876-536X. Dostupné z DOI: 10.2174/1876536X01003010004.
10. VERDURMEN, K. M. J.; LEMPERSZ, C.; VULLINGS, R.; SCHROER, C.; DELHAAS, T.; LAAR, J. O. E. H. van; OEI, S. G. Normal ranges for fetal electrocardiogram values for the healthy fetus of 18–24 weeks of gestation: a prospective cohort study. *BMC Pregnancy and Childbirth*. 2016, roč. 16, č. 1, s. 227. ISSN 1471-2393. Dostupné z DOI: 10.1186/s12884-016-1021-x.

11. KARVOUNIS, E. C.; TSIPOURAS, M. G.; PAPALOUKAS, C.; TSALIKAKIS, D. G.; NAKA, K. K.; FOTIADIS, D. I. A Non-invasive Methodology for Fetal Monitoring during Pregnancy. *Methods of Information in Medicine*. 2010, roč. 49, č. 03, s. 238–253. ISSN 0026-1270. Dostupné z DOI: 10.3414/ME09-01-0041.
12. JEZEWSKI, J.; WROBEL, J.; HOROBA, K. Comparison of Doppler ultrasound and direct electrocardiography acquisition techniques for quantification of fetal heart rate variability. *IEEE Transactions on Biomedical Engineering*. 2006, roč. 53, č. 5, s. 855–864. ISSN 0018-9294. Dostupné z DOI: 10.1109/TBME.2005.863945.
13. JEZEWSKI, J.; MATONIA, A.; KUPKA, T.; ROJ, D.; CZABANSKI, R. Determination of fetal heart rate from abdominal signals: evaluation of beat-to-beat accuracy in relation to the direct fetal electrocardiogram. *Biomedizinische Technik/Biomedical Engineering*. 2012, roč. 57, č. 5. ISSN 1862-278X. Dostupné z DOI: 10.1515/bmt-2011-0130.
14. MATONIA, A.; KUPKA, T.; JEZEWSKI, J.; MOMOT, A.; JEŻEWSKI, M.; BERNYS, M. Comparison of instantaneous fetal heart rate extracted from abdominal and direct fetal electrocardiograms. *Journal of Medical Informatics & Technologies*. 2012, roč. 19, s. 101–107. ISSN 1642-6037. Dostupné také z: <http://yadda.icm.edu.pl/baztech/element/bwmeta1.element.baztech-article-PWA4-0026-0011>.
15. CHETLUR ADITHYA, P.; SANKAR, R.; MORENO, W. A.; HART, S. Trends in fetal monitoring through phonocardiography: Challenges and future directions. *Biomedical Signal Processing and Control*. 2017, roč. 33, s. 289–305. ISSN 1746-8094. Dostupné z DOI: 10.1016/j.bspc.2016.11.007.
16. KOVÁCS, F.; HORVÁTH, C.; BALOGH, Á. T.; HOSSZÚ, G. Fetal phonocardiography—Past and future possibilities. *Computer Methods and Programs in Biomedicine*. 2011, roč. 104, č. 1, s. 19–25. ISSN 0169-2607. Dostupné z DOI: 10.1016/j.cmpb.2010.10.006.
17. MARTINEK, R.; NEDOMA, J.; FAJKUS, M.; KAHÁNKOVÁ, R.; KONEČNÝ, J.; JANKŮ, P.; KEPÁK, S.; BILÍK, P.; NAZERAN, H. A Phonocardiographic-Based Fiber-Optic Sensor and Adaptive Filtering System for Noninvasive Continuous Fetal Heart Rate Monitoring. *Sensors*. 2017, roč. 17, č. 4, s. 890. ISSN 1424-8220. Dostupné z DOI: 10.3390/s17040890.
18. VÁRADY, P.; WILDT, L.; BENYÓ, Z.; HEIN, A. An advanced method in fetal phonocardiography. *Computer Methods and Programs in Biomedicine*. 2003, roč. 71, č. 3, s. 283–296. ISSN 0169-2607. Dostupné z DOI: 10.1016/S0169-2607(02)00111-6.
19. ZHANG, D.; ZHANG, Y.; REN, W.; SUN, F.; GUO, Y.; SUN, W.; WANG, Y.; HUANG, L.; CAI, A. Prenatal Diagnosis of Fetal Interrupted Aortic Arch Type A by Two-Dimensional Echocardiography and Four-Dimensional Echocardiography with B-

- Flow Imaging and Spatiotemporal Image Correlation. *Echocardiography*. 2016, roč. 33, č. 1, s. 90–98. ISSN 0742-2822. Dostupné z DOI: 10.1111/echo.12996.
20. AIUM Practice Guideline for the Performance of Fetal Echocardiography. *Journal of Ultrasound in Medicine*. 2011, roč. 30, č. 1, s. 127–136. ISSN 0278-4297. Dostupné z DOI: 10.7863/jum.2011.30.1.127.
 21. PERSICO, N.; MORATALLA, J.; LOMBARDI, C. M.; ZIDERE, V.; ALLAN, L.; NICOLAIDES, K. H. Fetal echocardiography at 11-13 weeks by transabdominal high-frequency ultrasound: Fetal echocardiography at 11-13 weeks. *Ultrasound in Obstetrics & Gynecology*. 2011, roč. 37, č. 3, s. 296–301. ISSN 0960-7692. Dostupné z DOI: 10.1002/uog.8934.
 22. QUARTERO, H. W. P.; STINSTRA, J. G.; GOLBACH, E. G. M.; MEIJBOOM, E. J.; PETERS, M. J. Clinical implications of fetal magnetocardiography: Clinical use of Fetal MCG. *Ultrasound in Obstetrics and Gynecology*. 2002, roč. 20, č. 2, s. 142–153. ISSN 0960-7692. Dostupné z DOI: 10.1046/j.1469-0705.2002.00754.x.
 23. GRIMM, B.; HAUEISEN, J.; HUOTILAINEN, M.; LANGE, S.; LEEUWEN, P. V.; MENENDEZ, T.; PETERS, M. J.; SCHLEUSSNER, E.; SCHNEIDER, U. Recommended Standards for Fetal Magnetocardiography. *Pacing and Clinical Electrophysiology*. 2003, roč. 26, č. 11, s. 2121–2126. ISSN 0147-8389. Dostupné z DOI: 10.1046/j.1460-9592.2003.00330.x.
 24. LEEUWEN, P.; HALIER, B.; BADER, W.; GEISLER, J.; TROWITZSCH, E.; GRO-NEMEYER, D. H. W. Magnetocardiography in the diagnosis of fetal arrhythmia. *BJOG: An International Journal of Obstetrics and Gynaecology*. 1999, roč. 106, č. 11, s. 1200–1208. ISSN 1470-0328. Dostupné z DOI: 10.1111/j.1471-0528.1999.tb08149.x.
 25. JEZEWSKI, J.; WROBEL, J.; MATONIA, A.; HOROBA, K.; MARTINEK, R.; KUPKA, T.; JEZEWSKI, M. Is Abdominal Fetal Electrocardiography an Alternative to Doppler Ultrasound for FHR Variability Evaluation? *Frontiers in Physiology*. 2017, roč. 8, s. 305. ISSN 1664-042X. Dostupné z DOI: 10.3389/fphys.2017.00305.
 26. JEZEWSKI, J.; ROJ, D.; WROBEL, J.; HOROBA, K. A novel technique for fetal heart rate estimation from Doppler ultrasound signal. *BioMedical Engineering OnLine*. 2011, roč. 10, č. 1, s. 92. ISSN 1475-925X. Dostupné z DOI: 10.1186/1475-925X-10-92.
 27. WROBEL, J.; KUPKA, T.; HOROBA, K.; MATONIA, A.; ROJ, D.; JEZEWSKI, J. Recognition of Fetal Movements—Automated Detection from Doppler Ultrasound Signals Compared to Maternal Perception. *Journal of Medical Imaging and Health Informatics*. 2015, roč. 5, č. 6, s. 1319–1326. ISSN 2156-7018. Dostupné z DOI: 10.1166/jmihi.2015.1535.
 28. *Fetomat Foundation - Fetal Echocardiography [online] [cit. 2019-08-10]*. Dostupné také z: <http://www.fetomat.com/fetal-echocardiography.html>.

29. SULLIVAN, C. A. *SADS - SADS Foundation [online] [cit. 2019-08-10]*. Dostupné také z: <https://www.sads.org/Living-with-SADS/Pregnancy/Pregnancy---LQTS--A-Personal-Account#.XU6vbeZPY>.
30. TANG, H.; LI, T.; QIU, T.; PARK, Y. Fetal Heart Rate Monitoring from Phonocardiograph Signal Using Repetition Frequency of Heart Sounds. *Journal of Electrical and Computer Engineering*. 2016, roč. 2016, s. 1–6. ISSN 2090-0147. Dostupné z DOI: 10.1155/2016/2404267.
31. *Medicine - CTG (cardiotocography) pre prístroje [online] [cit. 2019-08-10]*. 2018. Dostupné také z: <http://sk-medicine.info/gynecology/ctg-cardiotocography-pre-pristroje-a-ktory-ukazuje-ako-sa-vyskum.html>.
32. VAISMAN, S.; YANIV SALEM, S.; HOLCBERG, G.; GEVA, A. B. Passive fetal monitoring by adaptive wavelet denoising method. *Computers in Biology and Medicine*. 2012, roč. 42, č. 2, s. 171–179. ISSN 0010-4825. Dostupné z DOI: 10.1016/j.combiomed.2011.11.005.
33. AYRES-DE-CAMPOS, D.; SPONG, C. Y.; CHANDRAHARAN, E.; FIGO INTRAPARTUM FETAL MONITORING EXPERT CONSENSUS PANEL. FIGO consensus guidelines on intrapartum fetal monitoring: Cardiotocography. *International Journal of Gynecology & Obstetrics*. 2015, roč. 131, č. 1, s. 13–24. ISSN 0020-7292. Dostupné z DOI: 10.1016/j.ijgo.2015.06.020.
34. PARER, J. T. Electronic Fetal Heart Rate Monitoring: Research Guidelines for Interpretation: The National Institute of Child Health and Human Development Research Planning Workshop. *Journal of Obstetric, Gynecologic & Neonatal Nursing*. 1997, roč. 26, č. 6, s. 635–640. ISSN 0884-2175. Dostupné z DOI: 10.1111/j.1552-6909.1997.tb02737.x.
35. KAZMI, T.; RADFER, F.; KHAN, S. ST Analysis of the Fetal ECG, as an Adjunct to Fetal Heart Rate Monitoring in Labour: A Review. *Oman Medical Journal*. 2011, roč. 26, č. 6, s. 459–460. ISSN 1999-768X. Dostupné z DOI: 10.5001/omj.2011.118.
36. WILLIAMS, K. P.; GALERNEAU, F. Intrapartum fetal heart rate patterns in the prediction of neonatal acidemia. *American Journal of Obstetrics and Gynecology*. 2003, roč. 188, č. 3, s. 820–823. ISSN 0002-9378. Dostupné z DOI: 10.1067/mob.2003.183.
37. MODANLOU, H. D.; FREEMAN, R. K. Sinusoidal fetal heart rate pattern: Its definition and clinical significance. *American Journal of Obstetrics and Gynecology*. 1982, roč. 142, č. 8, s. 1033–1038. ISSN 0002-9378. Dostupné z DOI: 10.1016/0002-9378(82)90789-X.
38. COLETTA, J.; MURPHY, E.; RUBEO, Z.; GYAMFI-BANNERMAN, C. The 5-tier system of assessing fetal heart rate tracings is superior to the 3-tier system in identifying fetal acidemia. *American Journal of Obstetrics and Gynecology*. 2012, roč. 206, č. 3, s. 226.e1–226.e5. ISSN 0002-9378. Dostupné z DOI: 10.1016/j.ajog.2011.12.014.

39. PARER, J. T.; IKEDA, T. A framework for standardized management of intrapartum fetal heart rate patterns. *American Journal of Obstetrics and Gynecology*. 2007, roč. 197, č. 1, s. 26.e1–26.e6. ISSN 0002-9378. Dostupné z DOI: 10.1016/j.ajog.2007.03.037.
40. MOGHAVVEMI, M.; TAN, B.; TAN, S. A non-invasive PC-based measurement of fetal phonocardiography. *Sensors and Actuators A: Physical*. 2003, roč. 107, č. 1, s. 96–103. ISSN 0924-4247. Dostupné z DOI: 10.1016/S0924-4247(03)00254-1.
41. CESARELLI, M.; RUFFO, M.; ROMANO, M.; BIFULCO, P. Simulation of foetal phonocardiographic recordings for testing of FHR extraction algorithms. *Computer Methods and Programs in Biomedicine*. 2012, roč. 107, č. 3, s. 513–523. ISSN 0169-2607. Dostupné z DOI: 10.1016/j.cmpb.2011.11.008.
42. CHOURASIA, V. S.; TIWARI, A. K.; GANGOPADHYAY, R. A novel approach for phonocardiographic signals processing to make possible fetal heart rate evaluations. *Digital Signal Processing*. 2014, roč. 30, s. 165–183. ISSN 1051-2004. Dostupné z DOI: 10.1016/j.dsp.2014.03.009.
43. ZAHORIAN, S. A.; ZUCKERWAR, A. J.; KARNJANADECHA, M. Dual transmission model and related spectral content of the fetal heart sounds. *Computer Methods and Programs in Biomedicine*. 2012, roč. 108, č. 1, s. 20–27. ISSN 0169-2607. Dostupné z DOI: 10.1016/j.cmpb.2011.12.006.
44. ZHDANOV, D.; BUREEV, A.; KOSTELEY, Y. 24-Hour Fetal/Maternal Monitoring System Based on Phonocardiogram Analysis. *MATEC Web of Conferences*. 2018, roč. 155, s. 01046. ISSN 2261-236X. Dostupné z DOI: 10.1051/mateconf/201815501046.
45. VARADY, P. Wavelet-based adaptive denoising of phonocardiographic records. In: *2001 Conference Proceedings of the 23rd Annual International Conference of the IEEE Engineering in Medicine and Biology Society*. Istanbul, Turkey: IEEE, 2001, s. 1846–1849. ISBN 978-0-7803-7211-5. Dostupné z DOI: 10.1109/IEMBS.2001.1020582.
46. MATONIA, A.; JEZEWSKI, J.; KUPKA, T.; HOROBA, K.; WROBEL, J.; GACEK, A. The influence of coincidence of fetal and maternal QRS complexes on fetal heart rate reliability. *Medical & Biological Engineering & Computing*. 2006, roč. 44, č. 5, s. 393–403. ISSN 0140-0118. Dostupné z DOI: 10.1007/s11517-006-0054-0.
47. KOTAS, M.; JEZEWSKI, J.; MATONIA, A.; KUPKA, T. Towards noise immune detection of fetal QRS complexes. *Computer Methods and Programs in Biomedicine*. 2010, roč. 97, č. 3, s. 241–256. ISSN 0169-2607. Dostupné z DOI: 10.1016/j.cmpb.2009.09.005.
48. KOTAS, M.; JEZEWSKI, J.; HOROBA, K.; MATONIA, A. Application of spatio-temporal filtering to fetal electrocardiogram enhancement. *Computer Methods and Programs in Biomedicine*. 2011, roč. 104, č. 1, s. 1–9. ISSN 0169-2607. Dostupné z DOI: 10.1016/j.cmpb.2010.07.004.

49. GOLDBERGER, A. L.; AMARAL, L. A. N.; GLASS, L.; HAUSDORFF, J. M.; IVANOV, P. C.; MARK, R. G.; MIETUS, J. E.; MOODY, G. B.; PENG, C.-K.; STANLEY, H. E. PhysioBank, PhysioToolkit, and PhysioNet: Components of a New Research Resource for Complex Physiologic Signals. *Circulation*. 2000, roč. 101, č. 23. ISSN 0009-7322. Dostupné z DOI: 10.1161/01.CIR.101.23.e215.
50. *Monica Healthcare - Fetal Monitor & Pregnancy Monitoring Equipment [online] [cit. 2019-08-10]*. Dostupné také z: <http://www.monicahealthcare.com/>.
51. *Mindchild Medical [online] [cit. 2019-08-10]*. Dostupné také z: <http://www.mindchild.com/>.
52. *Nemo Healthcare [online] [cit. 2019-08-10]*. Dostupné také z: <https://nemohealthcare.com/en/>.
53. *STAN S31 - Neoventa Medical [online] [cit. 2019-08-10]*. Dostupné také z: <https://www.neoventa.com/products/stan/>.
54. CLIFFORD, G. D.; SILVA, I.; BEHAR, J.; MOODY, G. B. Non-invasive fetal ECG analysis. *Physiological Measurement*. 2014, roč. 35, č. 8, s. 1521–1536. ISSN 0967-3334. Dostupné z DOI: 10.1088/0967-3334/35/8/1521.
55. COHEN, W. R.; HAYES-GILL, B. Influence of maternal body mass index on accuracy and reliability of external fetal monitoring techniques. *Acta Obstetrica et Gynecologica Scandinavica*. 2014, roč. 93, č. 6, s. 590–595. ISSN 0001-6349. Dostupné z DOI: 10.1111/aogs.12387.
56. SÄNGER, N.; HAYES-GILL, B.; SCHIERMEIER, S.; HATZMANN, W.; YUAN, J.; HERRMANN, E.; LOUWEN, F.; REINHARD, J. Prenatal Foetal Non-invasive ECG instead of Doppler CTG - A Better Alternative? *Geburtshilfe und Frauenheilkunde*. 2012, roč. 72, č. 07, s. 630–633. ISSN 0016-5751. Dostupné z DOI: 10.1055/s-0032-1315012.
57. HASSANPOUR, H.; PARSAEI, A. Fetal ECG Extraction Using Wavelet Transform. In: *2006 International Conference on Computational Intelligence for Modelling Control and Automation and International Conference on Intelligent Agents Web Technologies and International Commerce (CIMCA'06)*. Sydney, NSW: IEEE, 2006, s. 179–179. ISBN 978-0-7695-2731-4. Dostupné z DOI: 10.1109/CIMCA.2006.98.
58. BHOKER, R.; GAWANDE, J. P. Fetal ECG extraction using wavelet transform. *ITSI Transactions on Electrical and Electronics Engineering*. 2013, roč. 1, č. 4, s. 2320–8945. Dostupné také z: <https://pdfs.semanticscholar.org/c701/8ca4fe2e4e56507efaa454f9f106a2013650.pdf>.
59. RAVINDRAKUMAR, S.; RAJA, K. B. Fetal ECG extraction and enhancement in prenatal monitoring—Review and implementation issues. In: *Trendz in Information Sciences & Computing(TISC2010)*. Chennai, India: IEEE, 2010, s. 16–20. ISBN 978-1-4244-9007-3. Dostupné z DOI: 10.1109/TISC.2010.5714599.

60. DE MOOR, B.; DE GERSEM, P.; DE SCHUTTER, B.; FAVOREEL, W. DAISY: A database for identification of systems. *Journal A*. 1997, roč. 38, č. 3, s. 4–5. Dostupné také z: <https://pdfs.semanticscholar.org/07a8/5578601f5f1ab9a52375a9ead67422768050.pdf>.
61. SOBER, M. M.; MARCO, J. G. *Non-Invasive Fetal Electrocardiogram Database*. physi-onet.org, 2007. Dostupné z DOI: 10.13026/c2x30h. type: dataset.
62. KARVOUNIS, E.; PAPALOUKAS, C.; FOTIADIS, D.; MICHALIS, L. Fetal heart rate extraction from composite maternal ECG using complex continuous wavelet transform. In: *Computers in Cardiology, 2004*. Chicago, IL, USA: IEEE, 2004, s. 737–740. ISBN 978-0-7803-8927-4. Dostupné z DOI: 10.1109/CIC.2004.1443044.
63. PIÉRI, J. F.; CROWE, J. A.; HAYES-GILL, B. R.; SPENCER, C. J.; BHOGAL, K.; JAMES, D. K. Compact long-term recorder for the transabdominal foetal and maternal electrocardiogram. *Medical & Biological Engineering & Computing*. 2001, roč. 39, č. 1, s. 118–125. ISSN 0140-0118. Dostupné z DOI: 10.1007/BF02345275.
64. KUMAR, P.; SHARMA, S. K.; PRASAD, S. CAD for Detection of Fetal Electrocardiogram by using Wavelets and Neuro-Fuzzy Systems. *International Journal of Applied Engineering Research*. 2016, roč. 11, č. 4, s. 2321–2326. ISSN 0973-4562. Dostupné také z: <https://pdfs.semanticscholar.org/37b1/96528ce88d789cfe1842bea56fddc2cf1824.pdf>.
65. VAN BEMMEL, J. H. Detection of Weak Foetal Electrocardiograms by Autocorrelation and Crosscorrelation of Envelopes. *IEEE Transactions on Biomedical Engineering*. 1968, roč. BME-15, č. 1, s. 17–23. ISSN 0018-9294. Dostupné z DOI: 10.1109/TBME.1968.4502528.
66. BERGVELD, P.; MEIJER, W. J. H. A New Technique for the Suppression of the MECG. *IEEE Transactions on Biomedical Engineering*. 1981, roč. BME-28, č. 4, s. 348–354. ISSN 0018-9294. Dostupné z DOI: 10.1109/TBME.1981.324803.
67. LEVKOV, C.; MIHOV, G.; IVANOV, R.; DASKALOV, I.; CHRISTOV, I.; DOTSINSKY, I. Removal of power-line interference from the ECG: a review of the subtraction procedure. *BioMedical Engineering OnLine*. 2005, roč. 4, č. 1, s. 50. ISSN 1475-925X. Dostupné z DOI: 10.1186/1475-925X-4-50.
68. HON, E. H.; LEE, S. T. Averaging techniques in fetal electrocardiography. *Medical Electronics & Biological Engineering*. 1964, roč. 2, č. 1, s. 71–76. ISSN 0368-9271. Dostupné z DOI: 10.1007/BF02474362.
69. ALCARAZ, R.; RIETA, J. Adaptive singular value QRST cancellation for the analysis of short single lead atrial fibrillation electrocardiograms. In: *2007 Computers in Cardiology*. Durham, NC, USA: IEEE, 2007, s. 513–516. ISBN 978-1-4244-2533-4. Dostupné z DOI: 10.1109/CIC.2007.4745535.

70. CHMELKA, L.; KOZUMPLIK, J. Wavelet-based wiener filter for electrocardiogram signal denoising. In: *Computers in Cardiology, 2005*. Lyon, France: IEEE, 2005, s. 771–774. ISBN 978-0-7803-9337-0. Dostupné z DOI: 10.1109/CIC.2005.1588218.
71. SUN, Y.; CHAN, K. L.; KRISHNAN, S. M. ECG signal conditioning by morphological filtering. *Computers in Biology and Medicine*. 2002, roč. 32, č. 6, s. 465–479. ISSN 0010-4825. Dostupné z DOI: 10.1016/S0010-4825(02)00034-3.
72. MOODY, G.; MARK, R. The impact of the MIT-BIH Arrhythmia Database. *IEEE Engineering in Medicine and Biology Magazine*. 2001, roč. 20, č. 3, s. 45–50. ISSN 0739-5175. Dostupné z DOI: 10.1109/51.932724.
73. SU, L.; WU, H.-T. Extract Fetal ECG from Single-Lead Abdominal ECG by De-Shape Short Time Fourier Transform and Nonlocal Median. *Frontiers in Applied Mathematics and Statistics*. 2017, roč. 3. ISSN 2297-4687. Dostupné z DOI: 10.3389/fams.2017.00002.
74. AGOSTINELLI, A.; GRILLO, M.; BIAGINI, A.; GIULIANI, C.; BURATTINI, L.; FIORETTI, S.; DI NARDO, F.; GIANNUBILO, S. R.; CIAVATTINI, A.; BURATTINI, L. Noninvasive Fetal Electrocardiography: An Overview of the Signal Electrophysiological Meaning, Recording Procedures, and Processing Techniques: Noninvasive Fetal Electrocardiography. *Annals of Noninvasive Electrocardiology*. 2015, roč. 20, č. 4, s. 303–313. ISSN 1082-720X. Dostupné z DOI: 10.1111/anec.12259.
75. AGOSTINELLI, A.; SBROLLINI, A.; BURATTINI, L.; FIORETTI, S.; DI NARDO, F.; BURATTINI, L. Noninvasive Fetal Electrocardiography Part II: Segmented-Beat Modulation Method for Signal Denoising. *The Open Biomedical Engineering Journal*. 2017, roč. 11, č. 1, s. 25–35. ISSN 1874-1207. Dostupné z DOI: 10.2174/1874120701711010025.
76. MATONIA, A.; JEZEWSKI, J.; HOROBA, K.; GACEK, A.; LABAJ, P. The Maternal ECG Suppression Algorithm for Efficient Extraction of the Fetal ECG from Abdominal Signal. In: *2006 International Conference of the IEEE Engineering in Medicine and Biology Society*. New York, NY: IEEE, 2006, s. 3106–3109. ISBN 978-1-4244-0032-4. Dostupné z DOI: 10.1109/IEMBS.2006.260221.
77. WARBHE, A. D.; DHARASKAR, R. V.; KALAMBHE, B. A Single Channel Phonocardiograph Processing Using EMD, SVD, and EFICA. In: *2010 3rd International Conference on Emerging Trends in Engineering and Technology*. Goa: IEEE, 2010, s. 578–581. ISBN 978-1-4244-8481-2. Dostupné z DOI: 10.1109/ICETET.2010.171.
78. SOHEILI NAJAFABADI, F.; ZAHEDI, E.; MOHD ALI, M. A Novel Model for Abdominal Electrocardiography of a Pregnant Woman. In: *2005 Asian Conference on Sensors and the International Conference on New Techniques in Pharmaceutical and Biomedical Research*. Kuala Lumpur, Malaysia: IEEE, 2005, s. 64–68. ISBN 978-0-7803-9370-7. Dostupné z DOI: 10.1109/ASENSE.2005.1564507.

79. AHUJA, E.; SHAIKH, F. I. A Novel Approach to FEG Extraction Based on Fast ICA. *International Research Journal of Engineering and Technology*. 2016, roč. 3, č. 4, s. 2450–2453. ISSN 2395-0056. Dostupné také z: <https://www.irjet.net/archives/V3/i4/IRJET-V3I4584.pdf>.
80. PANI, D.; ARGIOLAS, S.; RAFFO, L. A DSP algorithm and system for real-time fetal ECG extraction. In: *2008 Computers in Cardiology*. Bologna, Italy: IEEE, 2008, s. 1065–1068. ISBN 978-1-4244-3706-1. Dostupné z DOI: 10.1109/CIC.2008.4749229.
81. BIOMED. Biomed Database, Katholieke Universiteit Leuven, Belgium. 2005. Dostupné také z: <http://homes.esat.kuleuven.be/%E2%88%BCbiomed/biosource/data006/foetal%20ecg.dat>.
82. DE LATHAUWER, L. Private communication. 2010. Dostupné také z: ftp://ftp.esat.kuleuven.ac.be/pub/SISTA/%20delathauwer/data/foetal_ecg.dat.
83. ANANTHANAG, K.; SAHAMBI, J. Investigation of blind source separation methods for extraction of fetal ECG. In: *CCECE 2003 - Canadian Conference on Electrical and Computer Engineering. Toward a Caring and Humane Technology (Cat. No.03CH37436)*. Montreal, Que., Canada: IEEE, 2003, sv. 3, s. 2021–2024. ISBN 978-0-7803-7781-3. Dostupné z DOI: 10.1109/CCECE.2003.1226312.
84. MAROSSERO, D.; ERDOGMUS, D.; EULIANO, N.; PRINCIPE, J.; HILD, K. Independent components analysis for fetal electrocardiogram extraction: a case for the data efficient Mermaid algorithm. In: *2003 IEEE XIII Workshop on Neural Networks for Signal Processing (IEEE Cat. No.03TH8718)*. Toulouse, France: IEEE, 2003, s. 399–408. ISBN 978-0-7803-8177-3. Dostupné z DOI: 10.1109/NNSP.2003.1318039.
85. CAMARGO-OLIVARES, J. L.; MARTÍN-CLEMENTE, R.; HORNILLO-MELLADO, S.; ELENA, M. M.; ROMÁN, I. The Maternal Abdominal ECG as Input to MICA in the Fetal ECG Extraction Problem. *IEEE Signal Processing Letters*. 2011, roč. 18, č. 3, s. 161–164. ISSN 1070-9908. Dostupné z DOI: 10.1109/LSP.2011.2104415.
86. SEVIM, Y.; ATASOY, A. Performance evaluation of nonparametric ICA algorithm for fetal ECG extraction. *Turkish Journal of Electrical Engineering & Computer Sciences*. 2011, roč. 19, č. 4, s. 657–666. Dostupné z DOI: 10.3906/elk-0912-311.
87. YE, Y.; ZHANG, Z.-L.; ZENG, J.; PENG, L. A fast and adaptive ICA algorithm with its application to fetal electrocardiogram extraction. *Applied Mathematics and Computation*. 2008, roč. 205, č. 2, s. 799–806. ISSN 0096-3003. Dostupné z DOI: 10.1016/j.amc.2008.05.117.
88. CICHOCKI, A.; AMARI, S.-I.; SIWEK, K.; TANAKA, T.; PHAN, A. H.; BAKAR-DJIAN, H.; RUTKOWSKI, T.; CHOI, S.; BELOUCHRANI, A.; BARROS, A.; THAWONMAS, R.; HOYA, T.; HASHIMOTO, W.; TERAZONO, Y. *ICALAB toolboxes*

- [online] [cit. 2019-08-10]. 2007. Dostupné také z: https://www.researchgate.net/publication/233906595_ICALAB_toolboxes.
89. LEACH, S. Singular Value Decomposition - a Primer. *Department of Computer Science, Brown University, Providence, RI, USA*. 1995. Dostupné také z: <http://www.citeline.org/group/474/article/493979>.
 90. DE LATHAUWER, L.; DE MOOR, B.; VANDEWALLE, J. SVD-based methodologies for fetal electrocardiogram extraction. In: *2000 IEEE International Conference on Acoustics, Speech, and Signal Processing. Proceedings (Cat. No.00CH37100)*. Istanbul, Turkey: IEEE, 2000, sv. 6, s. 3771–3774. ISBN 978-0-7803-6293-2. Dostupné z DOI: 10.1109/ICASSP.2000.860223.
 91. ROMERO, I. PCA-based noise reduction in ambulatory ECGs. In: *2010 Computing in Cardiology*. IEEE, 2010, sv. 37, s. 677–680. Dostupné také z: <https://ieeexplore.ieee.org/abstract/document/5738063/>.
 92. RAJ, C. G.; HARSHA, V. S.; GOWTHAMI, B. S.; SUNITHA R. Virtual Instrumentation Based Fetal ECG Extraction. *Procedia Computer Science*. 2015, roč. 70, s. 289–295. ISSN 1877-0509. Dostupné z DOI: 10.1016/j.procs.2015.10.093.
 93. SILVA, I.; BEHAR, J.; SAMENI, R.; ZHU, T.; OSTER, J.; CLIFFORD, G. D.; MOODY, G. B. Noninvasive fetal ECG: the PhysioNet/computing in cardiology challenge 2013. In: *Computing in Cardiology 2013*. IEEE, 2013, s. 149–152. Dostupné také z: <https://ieeexplore.ieee.org/abstract/document/6712433/>.
 94. BACHARAKIS, E.; NANDI, A. K.; ZARZOSO, V. Foetal ECG extraction using blind source separation methods. In: *1996 8th European Signal Processing Conference (EU-SIPCO 1996)*. IEEE, 1996, s. 1–4. Dostupné také z: <https://ieeexplore.ieee.org/abstract/document/7083076>.
 95. KHARABIAN, S.; SHAMSOLLAHI, M.; SAMENI, R. Fetal R-wave detection from multichannel abdominal ECG recordings in low SNR. In: *2009 Annual International Conference of the IEEE Engineering in Medicine and Biology Society*. Minneapolis, MN: IEEE, 2009, s. 344–347. Dostupné z DOI: 10.1109/IEMBS.2009.5333578.
 96. MARTENS, S. M.; RABOTTI, C.; MISCHI, M.; SLUIJTER, R. J. A robust fetal ECG detection method for abdominal recordings. *Physiological measurement*. 2007, roč. 28, č. 4, s. 373. Dostupné také z: <https://iopscience.iop.org/article/10.1088/0967-3334/28/4/004/meta>.
 97. BARROS, A. K.; CICHOCKI, A. Extraction of Specific Signals with Temporal Structure. *Neural Computation*. 2001, roč. 13, č. 9, s. 1995–2003. ISSN 0899-7667. Dostupné z DOI: 10.1162/089976601750399272.

98. ZHI-LIN ZHANG; YALAN YE. Extended Barros's extraction algorithm with its application in fetal ECG extraction. In: *2005 International Conference on Neural Networks and Brain*. Beijing, China: IEEE, 2005, sv. 2, s. 1077–1080. ISBN 978-0-7803-9422-3. Dostupné z DOI: 10.1109/ICNNB.2005.1614804.
99. ZHANG, Z.-L.; YI, Z. Extraction of a source signal whose kurtosis value lies in a specific range. *Neurocomputing*. 2006, roč. 69, č. 7-9, s. 900–904. ISSN 0925-2312. Dostupné z DOI: 10.1016/j.neucom.2005.07.002.
100. JAFARI, F.; TINATI, M. A.; MOZAFFARI, B. A new fetal ECG extraction method using its skewness value which lies in specific range. In: *2010 18th Iranian Conference on Electrical Engineering*. Isfahan, Iran: IEEE, 2010, s. 30–34. ISBN 978-1-4244-6760-0. Dostupné z DOI: 10.1109/IRANIANCEE.2010.5507111.
101. LUCIA BILLECI; MAURIZIO VARANINI. A Combined Independent Source Separation and Quality Index Optimization Method for Fetal ECG Extraction from Abdominal Maternal Leads. *Sensors*. 2017, roč. 17, č. 5, s. 1135. ISSN 1424-8220. Dostupné z DOI: 10.3390/s17051135.
102. VARANINI, M.; TARTARISCO, G.; BALOCCHI, R.; MACERATA, A.; PIOGGIA, G.; BILLECI, L. A new method for QRS complex detection in multichannel ECG: Application to self-monitoring of fetal health. *Computers in Biology and Medicine*. 2017, roč. 85, s. 125–134. ISSN 0010-4825. Dostupné z DOI: 10.1016/j.compbiomed.2016.04.008.
103. REDIF, S. Fetal electrocardiogram estimation using polynomial eigenvalue decomposition. *Turkish Journal of Electrical Engineering & Computer Sciences*. 2016, roč. 24, č. 4, s. 2483–2497. ISSN 1300-0632. Dostupné z DOI: 10.3906/elk-1401-19.
104. TAN, B.; PENG, Q.; LIN, J.; LI, M. A novel method for estimating source number of fetal ECG. In: *2015 International Conference on Wireless Communications & Signal Processing (WCSP)*. Nanjing, China: IEEE, 2015, s. 1–6. ISBN 978-1-4673-7687-7. Dostupné z DOI: 10.1109/WCSP.2015.7341070.
105. DA POIAN, G.; BERNARDINI, R.; RINALDO, R. Separation and Analysis of Fetal-ECG Signals From Compressed Sensed Abdominal ECG Recordings. *IEEE Transactions on Biomedical Engineering*. 2016, roč. 63, č. 6, s. 1269–1279. ISSN 0018-9294. Dostupné z DOI: 10.1109/TBME.2015.2493726.
106. AKBARI, H.; SHAMSOLLAHI, M. B.; PHLIPO, R. Fetal ECG extraction using π Tucker decomposition. In: *2015 International Conference on Systems, Signals and Image Processing (IWSSIP)*. London, United Kingdom: IEEE, 2015, s. 174–178. ISBN 978-1-4673-8353-0. Dostupné z DOI: 10.1109/IWSSIP.2015.7314205.

107. GUPTA, P.; SHARMA, K.; JOSHI, S. Fetal heart rate extraction from abdominal electrocardiograms through multivariate empirical mode decomposition. *Computers in Biology and Medicine*. 2016, roč. 68, s. 121–136. ISSN 0010-4825. Dostupné z DOI: 10.1016/j.compbiomed.2015.11.007.
108. LIU, G.; LUAN, Y. An adaptive integrated algorithm for noninvasive fetal ECG separation and noise reduction based on ICA-EEMD-WS. *Medical & Biological Engineering & Computing*. 2015, roč. 53, č. 11, s. 1113–1127. ISSN 0140-0118. Dostupné z DOI: 10.1007/s11517-015-1389-1.
109. BEHAR, J.; ANDREOTTI, F.; ZAUNSEDER, S.; LI, Q.; OSTER, J.; CLIFFORD, G. D. An ECG simulator for generating maternal-foetal activity mixtures on abdominal ECG recordings. *Physiological Measurement*. 2014, roč. 35, č. 8, s. 1537–1550. ISSN 0967-3334. Dostupné z DOI: 10.1088/0967-3334/35/8/1537.
110. GUPTA, A.; SRIVASTAVA, M. C.; KHANDELWAL, V.; GUPTA, A. A novel approach to fetal ECG extraction and enhancement using blind source separation (BSS-ICA) and adaptive fetal ECG enhancer (AFE). In: *2007 6th International Conference on Information, Communications & Signal Processing*. Singapore: IEEE, 2007, s. 1–4. ISBN 978-1-4244-0982-2. Dostupné z DOI: 10.1109/ICICS.2007.4449716.
111. KOTAS, M. Combined application of independent component analysis and projective filtering to fetal ECG extraction. *Biocybernetics and Biomedical Engineering*. 2008, roč. 28, č. 1, s. 75. Dostupné také z: http://www.ibib.waw.pl/images/ibib/grupy/Wydawnictwa-Tomy/dokumenty/2008/BBE_28_1_075_FT.pdf.
112. BERGVELD, P.; KOLLING, A. J.; PEUSCHER, J. H. J. Real-Time Fetal ECG Recording. *IEEE Transactions on Biomedical Engineering*. 1986, roč. BME-33, č. 5, s. 505–509. ISSN 0018-9294. Dostupné z DOI: 10.1109/TBME.1986.325737.
113. SAMENI, R.; JUTTEN, C.; SHAMSOLLAHI, M. Multichannel Electrocardiogram Decomposition Using Periodic Component Analysis. *IEEE Transactions on Biomedical Engineering*. 2008, roč. 55, č. 8, s. 1935–1940. ISSN 0018-9294. Dostupné z DOI: 10.1109/TBME.2008.919714.
114. MARTÍN-CLEMENTE, R.; CAMARGO-OLIVARES, J. L.; HORNILLO-MELLADO, S.; ELENA, M.; ROMÁN, I. Fast Technique for Noninvasive Fetal ECG Extraction. *IEEE Transactions on Biomedical Engineering*. 2011, roč. 58, č. 2, s. 227–230. ISSN 0018-9294. Dostupné z DOI: 10.1109/TBME.2010.2059703.
115. ZARZOSO, V.; NANDI, A. Noninvasive fetal electrocardiogram extraction: blind separation versus adaptive noise cancellation. *IEEE Transactions on Biomedical Engineering*. 2001, roč. 48, č. 1, s. 12–18. ISSN 0018-9294. Dostupné z DOI: 10.1109/10.900244.

116. PING GAO; EE-CHIEN CHANG; WYSE, L. Blind separation of fetal ECG from single mixture using SVD and ICA. In: *Fourth International Conference on Information, Communications and Signal Processing, 2003 and the Fourth Pacific Rim Conference on Multimedia. Proceedings of the 2003 Joint*. Singapore: IEEE, 2003, sv. 3, s. 1418–1422. ISBN 978-0-7803-8185-8. Dostupné z DOI: 10.1109/ICICS.2003.1292699.
117. AYAT, M.; ASSALEH, K.; NASHASH, H. Fetal ECG extraction from a single abdominal ECG signal using SVD and polynomial classifiers. In: *2008 IEEE Workshop on Machine Learning for Signal Processing*. Cancun, Mexico: IEEE, 2008, s. 250–254. ISBN 978-1-4244-2375-0. Dostupné z DOI: 10.1109/MLSP.2008.4685488.
118. AYAT, M.; ASSALEH, K.; AL-NASHASH, H. Extracting fetal ECG from a single maternal abdominal record. In: *2015 IEEE 8th GCC Conference & Exhibition*. Muscat, Oman: IEEE, 2015, s. 1–4. ISBN 978-1-4799-8422-0. Dostupné z DOI: 10.1109/IEEEGCC.2015.7060027.
119. MA, M.; YANG, Y.-L.; LEI, S.-Y. Blind Extraction of FECG Combining Periodicity and Kurtosis. In: *2009 3rd International Conference on Bioinformatics and Biomedical Engineering*. Beijing, China: IEEE, 2009, s. 1–4. ISBN 978-1-4244-2901-1. Dostupné z DOI: 10.1109/ICBBE.2009.5162460.
120. ANDREOTTI, F.; BEHAR, J.; ZAUNSEDER, S.; OSTER, J.; CLIFFORD, G. D. An open-source framework for stress-testing non-invasive foetal ECG extraction algorithms. *Physiological measurement*. 2016, roč. 37, č. 5, s. 627. Dostupné také z: <https://iopscience.iop.org/article/10.1088/0967-3334/37/5/627/pdf>.
121. HE, P. J.; CHEN, X. M.; LIANG, Y.; ZENG, H. Z. Extraction for fetal ECG using single channel blind source separation algorithm based on multi-algorithm fusion. *MATEC Web of Conferences*. 2016, roč. 44, s. 01026. ISSN 2261-236X. Dostupné z DOI: 10.1051/mateconf/20164401026.
122. LEE, K.; LEE, B. Sequential Total Variation Denoising for the Extraction of Fetal ECG from Single-Channel Maternal Abdominal ECG. *Sensors*. 2016, roč. 16, č. 7, s. 1020. ISSN 1424-8220. Dostupné z DOI: 10.3390/s16071020.
123. BASKA-VINCZE, B.; BASKA, F.; SZENCI, O. Fetal heart rate and fetal heart rate variability in Lipizzaner broodmares. *Acta Veterinaria Hungarica*. 2015, roč. 63, č. 1, s. 89–99. ISSN 0236-6290. Dostupné z DOI: 10.1556/AVet.2015.007.
124. MAHESHWARI, P.; ALPHONSE, J.; HENRY, A.; WANG, J.; REDMOND, S. J.; WELSH, A. W. Beat-to-beat variability of fetal myocardial performance index: Beat-to-beat variability of MPI. *Ultrasound in Obstetrics & Gynecology*. 2017, roč. 50, č. 2, s. 215–220. ISSN 0960-7692. Dostupné z DOI: 10.1002/uog.16012.

125. FRUHMANN, G.; GAVARD, J. A.; MCCORMICK, K.; WILSON-GRIFFIN, J.; AMON, E.; GROSS, G. A. Standard External Doppler Fetal Heart Tracings (eFHR) Versus External Fetal ECG (fECG) in Premature Gestations [17Q]: *Obstetrics & Gynecology*. 2016, roč. 127, s. 143S. ISSN 0029-7844. Dostupné z DOI: 10.1097/01.AOG.0000483575.77421.68.
126. BECKER, J. H.; KRIKHAAR, A.; SCHUIT, E.; MÅRTENDAL, A.; MARŠÁL, K.; KWEE, A.; VISSER, G. H. A.; AMER-WÅHLIN, I. The added predictive value of biphasic events in ST analysis of the fetal electrocardiogram for intrapartum fetal monitoring. *Acta Obstetrica et Gynecologica Scandinavica*. 2015, roč. 94, č. 2, s. 175–182. ISSN 0001-6349. Dostupné z DOI: 10.1111/aogs.12548.
127. SACCO, A.; MUĞLU, J.; NAVARATNARAJAH, R.; HOGG, M. ST analysis for intrapartum fetal monitoring. *The Obstetrician & Gynaecologist*. 2015, roč. 17, č. 1, s. 5–12. ISSN 1467-2561. Dostupné z DOI: 10.1111/tog.12154.
128. FUCHS, T.; GROBELAK, K.; POMORSKI, M.; ZIMMER, M. Fetal Heart Rate Monitoring Using Maternal Abdominal Surface Electrodes in Third Trimester: Can We Obtain Additional Information Other than CTG Trace? *Advances in clinical and experimental medicine: official organ Wroclaw Medical University*. 2016, roč. 25, č. 2, s. 309–316. Dostupné také z: <https://europepmc.org/abstract/med/27627565>.
129. STROUHAL, A. Úzkopásmové filtry pro signály ekg. *Vysoké učení technické v Brně. Bakalářská práce. Vedoucí práce: doc. Ing. Jiří Kozumplík*. 2009. Dostupné také z: <https://core.ac.uk/download/pdf/30279942.pdf>.
130. LUO, D. Research and application of fetal electrocardiogram blind signal separation technology. *Journal of Applied Science, Engineering and Technology*. 2012, roč. 4, č. 14, s. 2231–2235. ISSN 2040-7467. Dostupné také z: <https://pdfs.semanticscholar.org/dea9/65d95a6e82834f2bff9afd848abd3d47d5cd.pdf>.
131. SAMENI, R.; JUTTEN, C.; SHAMSOLLAHI, M. B. What ICA Provides for ECG Processing: Application to Noninvasive Fetal ECG Extraction. In: *2006 IEEE International Symposium on Signal Processing and Information Technology*. Vancouver, BC: IEEE, 2006, s. 656–661. ISBN 978-0-7803-9753-8. Dostupné z DOI: 10.1109/ISSPIT.2006.270882.
132. HYVÄRINEN, A.; OJA, E. Independent component analysis: algorithms and applications. *Neural Networks*. 2000, roč. 13, č. 4-5, s. 411–430. ISSN 0893-6080. Dostupné z DOI: 10.1016/S0893-6080(00)00026-5.
133. KANDPAL, N.; MADHUSUDAN RAO, B. Implementation of PCA & ICA for voice recognition and separation of speech. In: *2010 IEEE International Conference on Advanced Management Science(ICAMS 2010)*. Chengdu, China: IEEE, 2010, s. 536–538. ISBN 978-1-4244-6931-4. Dostupné z DOI: 10.1109/ICAMS.2010.5553181.

134. WIDROW, B.; WINTER, R. Neural nets for adaptive filtering and adaptive pattern recognition. *Computer*. 1988, roč. 21, č. 3, s. 25–39. ISSN 0018-9162. Dostupné z DOI: 10.1109/2.29.
135. MARTINEK, R. Využití komplexních adaptivních metod zpracování signálů pro zpřesnění diagnostické kvality abdominálního fetálního elektrokardiogramu. *VŠB - Technická univerzita Ostrava. Doktorská disertační práce. Vedoucí práce: doc. Ing. Jan Žídek, CSc.* 2014. Dostupné také z: https://dspace.vsb.cz/bitstream/handle/10084/105753/MAR944_FEI_P1807_2601V018_2014.pdf?sequence=1.
136. MARTINEK, R.; ŽÍDEK, J.; BILÍK, P.; MAŇAS, J.; KOZIOREK, J.; TENG, Z.; WEN, H. The Use of LMS and RLS Adaptive Algorithms for an Adaptive Control Method of Active Power Filter. *Energy and Power Engineering*. 2013, roč. 05, č. 04, s. 1126–1133. ISSN 1949-243X. Dostupné z DOI: 10.4236/epe.2013.54B215.
137. MARTINEK, R.; KAHÁNKOVÁ, R.; NAZERAN, H.; KONEČNÝ, J.; JEZEWSKI, J.; JANKŮ, P.; BILÍK, P.; ŽÍDEK, J.; NEDOMA, J.; FAJKUS, M. 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. *Sensors*. 2017, roč. 17, č. 5, s. 1154. ISSN 1424-8220. Dostupné z DOI: 10.3390/s17051154.
138. KAHÁNKOVÁ, R.; MARTINEK, R.; BILÍK, P. Fetal ECG extraction from abdominal ECG using RLS based adaptive algorithms. In: *2017 18th International Carpathian Control Conference (ICCC)*. Sinaia, Romania: IEEE, 2017, s. 337–342. ISBN 978-1-5090-4862-5. Dostupné z DOI: 10.1109/CarpathianCC.2017.7970422.
139. JANG, J.-S. ANFIS: adaptive-network-based fuzzy inference system. *IEEE Transactions on Systems, Man, and Cybernetics*. 1993, roč. 23, č. 3, s. 665–685. ISSN 0018-9472. Dostupné z DOI: 10.1109/21.256541.
140. MARTINEK, R.; ŽÍDEK, J. Refining the diagnostic quality of the abdominal fetal electrocardiogram using the techniques of artificial intelligence. 2012. ISSN 0033-2097. Dostupné také z: <https://dspace.vsb.cz/bitstream/handle/10084/96226/przeglad-elektrotech-2012-88-12b-155-martinek.pdf?sequence=1>.
141. ASSALEH, K. Extraction of Fetal Electrocardiogram Using Adaptive Neuro-Fuzzy Inference Systems. *IEEE Transactions on Biomedical Engineering*. 2007, roč. 54, č. 1, s. 59–68. ISSN 0018-9294. Dostupné z DOI: 10.1109/TBME.2006.883728.
142. ASSALEH, K. Adaptive Neuro-Fuzzy Inference Systems for Extracting Fetal Electrocardiogram. In: *2006 IEEE International Symposium on Signal Processing and Information Technology*. Vancouver, BC, Canada: IEEE, 2006, s. 122–126. ISBN 978-0-7803-9754-5. Dostupné z DOI: 10.1109/ISSPIT.2006.270782.

143. ZADEH, L. Fuzzy sets. *Information and Control*. 1965, roč. 8, č. 3, s. 338–353. ISSN 0019-9958. Dostupné z DOI: 10.1016/S0019-9958(65)90241-X.
144. POKORNÝ, M.; KRIŠOVÁ, Z. Znalostní systémy. 2016. Dostupné také z: <https://mvso.cz/wp-content/uploads/2017/10/Znalostn%C3%AD-syst%C3%A9my.pdf>.
145. TANAKA, K.; WANG, H. O. *Fuzzy control systems design and analysis: a linear matrix inequality approach*. John Wiley & Sons, 2004. Dostupné také z: http://inis.jinr.ru/sl/tot_ra/0/0/3/Tanaka-Fuzzy.pdf.
146. WIDROW, B.; LEHR, M. 30 years of adaptive neural networks: perceptron, Madaline, and backpropagation. *Proceedings of the IEEE*. 1990, roč. 78, č. 9, s. 1415–1442. ISSN 0018-9219. Dostupné z DOI: 10.1109/5.58323.
147. VONDRÁK, I. *Umělá inteligence a neuronové sítě: Určeno pro posl. 4. roč. Fak. elektrotechniky a informatiky*. VŠB - Technická univerzita Ostrava, 1994.
148. WERBOS, P. Backpropagation through time: what it does and how to do it. *Proceedings of the IEEE*. 1990, roč. 78, č. 10, s. 1550–1560. ISSN 0018-9219. Dostupné z DOI: 10.1109/5.58337.
149. NASIRI, M.; FAEZ, K.; NASRABADI, A. M. A new method for extraction of fetal electrocardiogram signal based on Adaptive Nero-Fuzzy Inference System. In: *2011 IEEE International Conference on Signal and Image Processing Applications (ICSIPA)*. Kuala Lumpur, Malaysia: IEEE, 2011, s. 456–461. ISBN 978-1-4577-0242-6. Dostupné z DOI: 10.1109/ICSIPA.2011.6144151.
150. CHOURASIA, V. S.; TIWARI, A. K. Design Methodology of a New Wavelet Basis Function for Fetal Phonocardiographic Signals. *The Scientific World Journal*. 2013, roč. 2013, s. 1–12. ISSN 1537-744X. Dostupné z DOI: 10.1155/2013/505840.
151. CHOUAKRI, S.; BEREKSI-REGUIG, F.; AHMALDI, S.; FOKAPU, O. Wavelet denoising of the electrocardiogram signal based on the corrupted noise estimation. In: *Computers in Cardiology, 2005*. Lyon, France: IEEE, 2005, s. 1021–1024. ISBN 978-0-7803-9337-0. Dostupné z DOI: 10.1109/CIC.2005.1588284.
152. MARTINEK, R.; KAHÁNKOVÁ, R.; NEDOMA, J.; FAJKUS, M.; CHOLEVOVÁ, K. Fetal ECG Preprocessing Using Wavelet Transform. In: *Proceedings of the 10th International Conference on Computer Modeling and Simulation - ICCMS 2018*. Sydney, Australia: ACM Press, 2018, s. 39–43. ISBN 978-1-4503-6339-6. Dostupné z DOI: 10.1145/3177457.3177503.
153. VALENCIA, D.; OREJUELA, D.; SALAZAR, J.; VALENCIA, J. Comparison analysis between rigrsure, sqtwolog, heursure and minimaxi techniques using hard and soft thresholding methods. In: *2016 XXI Symposium on Signal Processing, Images and Artificial Vision (STSIVA)*. Bucaramanga, Colombia: IEEE, 2016, s. 1–5. ISBN 978-1-5090-3797-1. Dostupné z DOI: 10.1109/STSIVA.2016.7743309.

154. TASWELL, C. The what, how, and why of wavelet shrinkage denoising. *Computing in Science & Engineering*. 2000, roč. 2, č. 3, s. 12–19. ISSN 1521-9615. Dostupné z DOI: 10.1109/5992.841791.
155. LITSCHMANNOVÁ, M. Úvod do statistiky. *VŠB - Technická univerzita Ostrava*. 2011. Dostupné také z: http://mi21.vsb.cz/sites/mi21.vsb.cz/files/unit/%20interaktivni_uvod_do_statistiky.pdf.
156. BLAND, J. M.; ALTMAN, D. G. Measuring agreement in method comparison studies. *Statistical Methods in Medical Research*. 1999, roč. 8, č. 2, s. 135–160. ISSN 0962-2802. Dostupné z DOI: 10.1177/096228029900800204.
157. FAJKUS, M.; NEDOMA, J.; MARTINEK, R.; VAŠINEK, V.; NAZERAN, H.; ŠIŠKA, P. A Non-Invasive Multichannel Hybrid Fiber-Optic Sensor System for Vital Sign Monitoring. *Sensors*. 2017, roč. 17, č. 12, s. 111. ISSN 1424-8220. Dostupné z DOI: 10.3390/s17010111.
158. BRIŠ, R.; LITSCHMANNOVÁ, M. Statistika I. *Pro kombinované a distanční studium, VŠB - Technická univerzita Ostrava*. 2004. Dostupné také z: <https://am.vsb.cz/bris>.
159. CUIWEI LI; CHONGXUN ZHENG; CHANGFENG TAI. Detection of ECG characteristic points using wavelet transforms. *IEEE Transactions on Biomedical Engineering*. 1995, roč. 42, č. 1, s. 21–28. ISSN 0018-9294. Dostupné z DOI: 10.1109/10.362922.
160. GHAFFARI, A.; GOLBAYANI, H.; GHASEMI, M. A new mathematical based QRS detector using continuous wavelet transform. *Computers & Electrical Engineering*. 2008, roč. 34, č. 2, s. 81–91. ISSN 0045-7906. Dostupné z DOI: 10.1016/j.compeleceng.2007.10.005.
161. DU, P.; KIBBE, W. A.; LIN, S. M. Improved peak detection in mass spectrum by incorporating continuous wavelet transform-based pattern matching. *Bioinformatics*. 2006, roč. 22, č. 17, s. 2059–2065. ISSN 1367-4803. Dostupné z DOI: 10.1093/bioinformatics/bt1355.
162. YE-LIN, Y.; GARCIA-CASADO, J.; PRATS-BOLUDA, G.; ALBEROLA-RUBIO, J.; PERALES, A. Automatic Identification of Motion Artifacts in EHG Recording for Robust Analysis of Uterine Contractions. *Computational and Mathematical Methods in Medicine*. 2014, roč. 2014, s. 1–11. ISSN 1748-670X. Dostupné z DOI: 10.1155/2014/470786.
163. JACOD, B. C.; GRAATSMA, E. M.; VAN HAGEN, E.; VISSER, G. H. A. A validation of electrohysterography for uterine activity monitoring during labour. *The Journal of Maternal-Fetal & Neonatal Medicine*. 2010, roč. 23, č. 1, s. 17–22. ISSN 1476-7058. Dostupné z DOI: 10.3109/14767050903156668.

164. GARCIA-GONZALEZ, M. T.; CHARLESTON-VILLALOBOS, S.; VARGAS-GARCIA, C.; GONZALEZ-CAMARENA, R.; ALJAMA-CORRALES, T. Characterization of EHG contractions at term labor by nonlinear analysis. In: *2013 35th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)*. Osaka: IEEE, 2013, s. 7432–7435. ISBN 978-1-4577-0216-7. Dostupné z DOI: 10.1109/EMBC.2013.6611276.

Autorovy publikace zaměřené na problematiku disertační práce

- RJ1. **JAROŠ**, R.; MARTINEK, R.; KAHÁNKOVÁ, R. Non-Adaptive Methods for Fetal ECG Signal Processing: A Review and Appraisal. *Sensors (WoS, SCOPUS, IF=3,031)*. 2018, roč. 18, č. 11, s. 3648. ISSN 1424-8220. Dostupné z DOI: 10.3390/s18113648.
- RJ2. **JAROŠ**, R.; MARTINEK, R.; KAHÁNKOVÁ, R.; KOZIOREK, J. Novel Hybrid Extraction Systems for Fetal Heart Rate Variability Monitoring based on Non-Invasive Fetal Electrocardiogram. *IEEE Access (IF=4,098)*. 2019, s. 1–1. ISSN 2169-3536. Dostupné z DOI: 10.1109/ACCESS.2019.2933717.
- RJ3. MARTINEK, R.; KAHÁNKOVÁ, R.; JEZEWSKI, J.; **JAROŠ**, R.; MOHYLOVÁ, J.; FAJKUS, M.; NEDOMA, J.; JANKŮ, P.; NAZERAN, H. Comparative Effectiveness of ICA and PCA in Extraction of Fetal ECG From Abdominal Signals: Toward Non-invasive Fetal Monitoring. *Frontiers in Physiology (WoS, SCOPUS, IF=3,201)*. 2018, roč. 9, s. 648. ISSN 1664-042X. Dostupné z DOI: 10.3389/fphys.2018.00648.
- RJ4. KAHÁNKOVÁ, R.; MARTINEK, R.; **JAROŠ**, R.; BEHBEHANI, K.; MATONIA, A.; JEZEWSKI, M.; BEHAR, J. A. A Review of Signal Processing Techniques for Non-Invasive Fetal Electrocardiography. *IEEE Reviews in Biomedical Engineering*. 2019, s. 1–1. ISSN 1937-3333. Dostupné z DOI: 10.1109/RBME.2019.2938061.
- RJ5. KAHÁNKOVÁ, R.; **JAROŠ**, R.; MARTINEK, R.; JEZEWSKI, J.; WEN, H.; JEZEWSKI, M.; KAWALA-JANIK, A. Non-Adaptive Methods of Fetal ECG Signal Processing. *Advances in Electrical and Electronic Engineering (WoS, SCOPUS)*. 2017, roč. 15, č. 3, s. 476–490. ISSN 1804-3119. Dostupné z DOI: 10.15598/aeee.v15i3.2196.
- RJ6. KAHÁNKOVÁ, R.; MARTINEK, R.; MIKOLÁŠOVÁ, M.; **JAROŠ**, R. Adaptive Linear Neuron for Fetal Electrocardiogram Extraction. In: *2018 IEEE 20th International Conference on e-Health Networking, Applications and Services (Healthcom) (SCOPUS)*. Ostrava: IEEE, 2018, s. 1–5. ISBN 978-1-5386-4294-8. Dostupné z DOI: 10.1109/HealthCom.2018.8531135.
- RJ7. **JAROŠ**, R.; KAHÁNKOVÁ, R.; MARTINEK, R.; NEDOMA, J.; FAJKUS, M.; SLANINA, Z. Fetal phonocardiography signal processing from abdominal records by non-adaptive methods. In: *Photonics Applications in Astronomy, Communications, Industry, and High-Energy Physics Experiments 2018 (WoS, SCOPUS)*. Wilga, Poland: SPIE, 2018, s. 118. ISBN 978-1-5106-2203-6. Dostupné z DOI: 10.1117/12.2501550.
- RJ8. **JAROŠ**, R.; MARTINEK, R.; KAHÁNKOVÁ, R.; FAJKUS, M.; NEDOMA, J. Use of a FIR filter for fetal phonocardiography processing. In: *2018 IEEE 20th International Conference on e-Health Networking, Applications and Services (Healthcom) (SCO-*

- PUS*). Ostrava: IEEE, 2018, s. 1–6. ISBN 978-1-5386-4294-8. Dostupné z DOI: 10.1109/HealthCom.2018.8531091.
- RJ9. **JAROŠ**, R.; MARTINEK, R.; KAHÁNKOVÁ, R.; VAŇUŠ, J.; FAJKUS, M.; NEDOMA, J. Comparison of fetal phonocardiography de-noising by wavelet transform and the FIR filter. In: *2018 IEEE 20th International Conference on e-Health Networking, Applications and Services (Healthcom) (SCOPUS)*. Ostrava: IEEE, 2018, s. 1–5. ISBN 978-1-5386-4294-8. Dostupné z DOI: 10.1109/HealthCom.2018.8531111.
- RJ10. KAHÁNKOVÁ, R.; MARTINEK, R.; **JAROŠ**, R.; NEDOMA, J.; FAJKUS, M.; VAŇUŠ, J. Least Mean Squares Adaptive Algorithms Optimization for Fetal Phonocardiogram Extraction. *IFAC-PapersOnLine (WoS, SCOPUS)*. 2018, roč. 51, č. 6, s. 60–65. ISSN 2405-8963. Dostupné z DOI: 10.1016/j.ifacol.2018.07.130.
- RJ11. ŠKUTOVÁ, H.; MARTINEK, R.; **JAROŠ**, R.; KAHÁNKOVÁ, R. A Noise Suppression Technique for Fetal Phonocardiogram Monitoring Using Adaptive Neuro-Fuzzy Interference System. *IFAC-PapersOnLine (WoS, SCOPUS)*. 2018, roč. 51, č. 6, s. 456–461. ISSN 2405-8963. Dostupné z DOI: 10.1016/j.ifacol.2018.07.103.
- RJ12. JOSEPH, A.; MARTINEK, R.; KAHÁNKOVÁ, R.; **JAROŠ**, R.; NEDOMA, J.; FAJKUS, M. Simulator of Foetal Phonocardiographic Recordings and Foetal Heart Rate Calculator. *Journal of Biomimetics, Biomaterials and Biomedical Engineering (WoS, SCOPUS)*. 2018, roč. 39, s. 57–64. ISSN 2296-9845. Dostupné z DOI: 10.4028/www.scientific.net/JBBBE.39.57.
- RJ13. MARTINEK, R.; **JAROŠ**, R.; BILÍK, P.; PUČAN, T.; FAJKUS, M.; NEDOMA, J. Use of wavelet transform for fetal phonocardiography processing. In: *2018 International Conference on Intelligent Systems (IS) (WoS, SCOPUS)*. Funchal - Madeira, Portugal: IEEE, 2018, s. 39–44. ISBN 978-1-5386-7097-2. Dostupné z DOI: 10.1109/IS.2018.8710506.

Autorovy ostatní publikace

- RJ14. **JAROŠ**, R.; MARTINEK, R.; DANYS, L. Comparison of Different Electrocardiography with Vectorcardiography Transformations. *Sensors (WoS, SCOPUS, IF=3,031)*. 2019, roč. 19, č. 14, s. 3072. ISSN 1424-8220. Dostupné z DOI: 10.3390/s19143072.
- RJ15. MARTINEK, R.; BRABLÍK, J.; KOLAŘÍK, J.; LÁDROVÁ, M.; NEDOMA, J.; **JAROŠ**, R.; ŠOUSTEK, L.; KAHÁNKOVÁ, R.; FAJKUS, M.; VOJTÍŠEK, L.; HANZLÍKOVÁ, P.; KRUPA, P. A Low-Cost System for Seismocardiography-Based Cardiac Triggering: A Practical Solution for Cardiovascular Magnetic Resonance Imaging at 3 Tesla. *IEEE Access (IF=4,098)*. 2019, roč. 7, s. 118608–118629. ISSN 2169-3536. Dostupné z DOI: 10.1109/ACCESS.2019.2936184.
- RJ16. MARTINEK, R.; RZIDKY, J.; **JAROŠ**, R.; BILÍK, P.; LÁDROVÁ, M. Least Mean Squares and Recursive Least Squares Algorithms for Total Harmonic Distortion Reduction Using Shunt Active Power Filter Control. *Energies (WoS, SCOPUS, IF=2,707)*. 2019, roč. 12, č. 8, s. 1545. ISSN 1996-1073. Dostupné z DOI: 10.3390/en12081545.
- RJ17. MARTINEK, R.; DANYS, L.; **JAROŠ**, R. Visible Light Communication System Based on Software Defined Radio: Performance Study of Intelligent Transportation and Indoor Applications. *Electronics (WoS, SCOPUS, IF=1,764)*. 2019, roč. 8, č. 4, s. 433. ISSN 2079-9292. Dostupné z DOI: 10.3390/electronics8040433.
- RJ18. LÁDROVÁ, M.; MARTINEK, R.; **JAROŠ**, R. Power Line Interference Elimination in ECG Signals. *Journal of Biomimetics, Biomaterials and Biomedical Engineering (WoS)*. 2019, roč. 41, s. 105–115. ISSN 2296-9845. Dostupné z DOI: 10.4028/www.scientific.net/JBBBE.41.105.
- RJ19. ŠIDIKOVÁ, M.; MARTINEK, R.; **JAROŠ**, R.; KONEČNÝ, J.; AUGUSTYNEK, M. Designing and Testing of the Software Module Evaluation of Visual Acuity for Information System Eye Center. *Journal of Biomimetics, Biomaterials and Biomedical Engineering (WoS)*. 2019, roč. 41, s. 117–127. ISSN 2296-9845. Dostupné z DOI: 10.4028/www.scientific.net/JBBBE.41.117.
- RJ20. MARTINEK, R.; **JAROŠ**, R.; BILÍK, P.; LANČOVÁ, J.; FAJKUS, M.; NEDOMA, J. Ballistocardiography Signal Processing by Wavelet Transform. In: *2018 International Conference on Intelligent Systems (IS) (WoS, SCOPUS)*. Funchal - Madeira, Portugal: IEEE, 2018, s. 45–49. ISBN 978-1-5386-7097-2. Dostupné z DOI: 10.1109/IS.2018.8710478.
- RJ21. NEDOMA, J.; FAJKUS, M.; ČUBÍK, J.; KEPÁK, S.; MARTINEK, R.; VAŇUŠ, J.; **JAROŠ**, R. SMART medical polydimethylsiloxane for monitoring vital signs of the human body. In: *2018 IEEE 20th International Conference on e-Health Networking*,

- Applications and Services (Healthcom) (SCOPUS)*. Ostrava: IEEE, 2018, s. 1–4. ISBN 978-1-5386-4294-8. Dostupné z DOI: 10.1109/HealthCom.2018.8531190.
- RJ22. NEDOMA, J.; FAJKUS, M.; MARTINEK, R.; VAŇUŠ, J.; KEPÁK, S.; KAHÁNKOVÁ, R.; **JAROŠ**, R.; CVEJN, D.; PRAUZEK, M. Analysis of the use of fiber-optic sensors in the road traffic. *IFAC-PapersOnLine (WoS, SCOPUS)*. 2018, roč. 51, č. 6, s. 420–425. ISSN 2405-8963. Dostupné z DOI: 10.1016/j.ifacol.2018.07.117.
- RJ23. NEDOMA, J.; FAJKUS, M.; MARTINEK, R.; ŽABKA, S.; NOVÁK, M.; **JAROŠ**, R. Analysis the effect of thermal load on the insertion loss of the optical couplers. In: *Optical Materials and Biomaterials in Security and Defence Systems Technology XV (WoS, SCOPUS)*. Berlin, Germany: SPIE, 2018, s. 13. ISBN 978-1-5106-2185-5. Dostupné z DOI: 10.1117/12.2501767.
- RJ24. NEDOMA, J.; FAJKUS, M.; ŽABKA, S.; NOVÁK, M.; **JAROŠ**, R.; MARTINEK, R. Fiber-optic sensors encapsulated into biocompatible polymer material for monitoring the heart rate of the human body. In: *Optical Materials and Biomaterials in Security and Defence Systems Technology XV (WoS, SCOPUS)*. Berlin, Germany: SPIE, 2018, s. 9. ISBN 978-1-5106-2185-5. Dostupné z DOI: 10.1117/12.2325039.
- RJ25. WITAS, K.; STOLÁRIK, M.; PINKA, M.; ŽABKA, S.; JALOWICZOR, J.; NOVÁK, M.; **JAROŠ**, R. Perimetric monitoring: A comparison of a classical seismic sensor and fiber-optic interferometric sensor. In: *Optical Sensors 2019 (WoS, SCOPUS)*. Prague, Czech Republic: SPIE, 2019, s. 101. ISBN 978-1-5106-2722-2. Dostupné z DOI: 10.1117/12.2522309.
- RJ26. WITAS, K.; ŽABKA, S.; FRNDA, J.; NOVÁK, M.; JALOWICZOR, J.; STOLÁRIK, M.; **JAROŠ**, R. Analysis of the effect of long-time thermal load on the total losses of the selected fiber-optic couplers. In: *Integrated Optics: Design, Devices, Systems, and Applications V (WoS)*. Prague, Czech Republic: SPIE, 2019, s. 50. ISBN 978-1-5106-2728-4. Dostupné z DOI: 10.1117/12.2519836.
- RJ27. MEC, P.; FAJKUS, M.; ŽABKA, S.; NOVÁK, M.; **JAROŠ**, R. Design of encapsulation of fiber Bragg grating for the traffic applications. In: *Optical Sensors 2019 (WoS)*. Prague, Czech Republic: SPIE, 2019, s. 127. ISBN 978-1-5106-2722-2. Dostupné z DOI: 10.1117/12.2521026.

Životopis

Osobní údaje

Jméno a příjmení Ing. René Jaroš
Datum narození 9. 12. 1992
Národnost Česká



Kontaktní údaje

Adresa Vrablovecká 909/24, Ludgeřovice 747 14
Telefon +420 774 650 522
E-mail rene.jaros@vsb.cz, rene.jaros@email.cz

Vzdělání

2017-dosud Vysoká škola Báňská – Technická univerzita Ostrava.
Fakulta elektrotechniky a informatiky.
Katedra kybernetiky a biomedicínského inženýrství.
Doktorské studium. Obor: Technická kybernetika.
Název práce: *Využití hybridních metod pro zpracování plodového elektrokardiogramu.*

2015-2017 Vysoká škola Báňská – Technická univerzita Ostrava.
Fakulta elektrotechniky a informatiky.
Katedra kybernetiky a biomedicínského inženýrství.
Magisterské studium. Obor: Biomedicínské inženýrství.
Ukončeno státní zkouškou. Titul inženýr.
Název práce: *Neadaptivní metody zpracování plodového elektrokardiogramu.*

2012-2015 Vysoká škola Báňská – Technická univerzita Ostrava.
Fakulta elektrotechniky a informatiky.
Katedra kybernetiky a biomedicínského inženýrství.
Bakalářské studium. Obor: Biomedicínský technik.
Ukončeno státní zkouškou. Titul bakalář.
Název práce: *Transformace 12-svodového EKG do VKG.*

2008-2012 Střední zdravotnická škola a Vyšší odborná škola zdravotnická.
Středoškolské studium. Obor: Zdravotnický asistent.
Ukončeno státní maturitní zkouškou.

Současná pozice

2018-dosud Vysoká škola Báňská – Technická univerzita Ostrava.
Fakulta elektrotechniky a informatiky.
Katedra kybernetiky a biomedicínského inženýrství.
Výzkumný a vývojový pracovník.

Výuka

2018-dosud Základy programování řídicích systémů (ZPŘS).

2017 Modulované signály (MoSi).

Řešené projekty

2019-2020 HS pro Baby Patron s.r.o. a vývoj domácího systému pro monitorování plodu.

2019-2023 Chytrý systém pro řízení energie energetických sítí. Typ THÉTA.

2018-2022 Centrum výzkumu pokročilých mechatronických systémů, registrační číslo projektu CZ.02.1.01/0.0/0.0/16_019/0000867, realizovaného v rámci Operačního programu Výzkum, vývoj a vzdělávání.

2018-2019 Pokročilé metody zpracování signálů, projekt SGS SP2019/85.

2018-2019 Virtuální instrumentace pro oblast měření a testování V., SP2018/170 systému studentských grantů.

2017-2018 Virtuální instrumentace pro oblast měření a testování IV., SP2017/128 systému studentských grantů.

Hirschův index

SCOPUS 2

WoS 2

Specializace

Pokročilé metody zpracování signálů. Plodová elektrokardiografie. Monitorování plodu. Programování v programech MATLAB, C a LaTeX.

A Experimenty na reálných datech z databáze ADFECGDB

Tato příloha obsahuje výsledky obdržené během testování hybridních metod na databázi ADFECGDB. Výsledky hodnocení na základě určení přesnosti detekce R kmitů obsahovaly velké množství tabulek, proto bylo rozhodnuto přesunout zde všechny tabulky, ze kterých vznikly shrnující tabulky. Shrnující tabulky zobrazovaly ideální kombinaci elektrod a nastavení adaptivních metod pro jednotlivé záznamy. Tabulky 14 až 37 zobrazují jaké bylo ideální nastavení adaptivních metod pro jednotlivé kombinace elektrod. Každá tabulka obsahuje 11 řádku pro všechny možné kombinace elektrod a každá z těchto tabulek je vytvořena zvlášť pro jednotlivé záznamy a hybridní metody. Zvýrazněný řádek v tabulkách značí, kterou kombinací elektrod bylo dosaženo nejlepšího výsledku na základě parametru ACC. V případě, kdy bylo dosaženo pro 2 a více kombinací stejného výsledku, byl brán zřetel na rychlost výpočtu a popřípadě počet použitých elektrod. U metody ANFIS hraje největší roli počet funkcí příslušnosti a poté počet epoch. U RLS algoritmu se vybral v případě stejného výsledku ten, který byl vytvořen s nižším řádem filtru. Dále tato příloha obsahuje Bland-Altmany grafy pro zbylých 8 záznamů z databáze ADFECGDB, které nebyly ukázány v experimentech, viz obrázky 51 až 58.

Tabulka 14: Ideální nastavení metody ANFIS pro všechny možné kombinace elektrod u záznamu r01. Stanovené počty TP, FP a FN na základě detekce pozic R kmitů v extrahovaných fEKG signálech pomocí hybridní metody ICA-ANFIS-WT vzhledem k referenčním pozicím R kmitů a výpočet parametrů ACC, SE, PPV a F1.

Kombinace elektrod	Tvar funkcí příslušnosti	Počet epoch	Počet funkcí příslušnosti	TP	FP	FN	ACC (%)	SE (%)	PPV (%)	F1 (%)
1,2	gbellmf	2	20	621	9	23	95,10	96,43	98,57	97,49
1,3	trapmf	8	20	585	41	59	85,40	90,84	93,45	92,13
1,4	gaussmf	6	20	643	2	1	99,54	99,85	99,69	99,77
2,3	trapmf	6	10	404	82	240	55,65	62,73	83,13	71,50
2,4	gbellmf	10	10	624	12	20	95,12	96,89	98,11	97,50
3,4	gbellmf	2	10	584	49	60	84,27	90,68	92,26	91,46
1,2,3	gbellmf	2	30	611	22	33	91,74	94,88	96,52	95,69
1,2,4	trapmf	10	30	643	2	1	99,54	99,85	99,69	99,77
1,3,4	gaussmf	2	10	643	1	1	99,69	99,85	99,85	99,85
2,3,4	gaussmf	2	10	639	3	5	98,76	99,22	99,53	99,38
1,2,3,4	gbellmf	2	30	642	2	2	99,38	99,69	99,69	99,69

Tabulka 15: Ideální nastavení řádu filtru algoritmu RLS pro všechny možné kombinace elektrod u záznamu r01. Stanovené počty TP, FP a FN na základě detekce pozic R kmitů v extrahovaných fEKG signálech pomocí hybridní metody ICA-RLS-WT vzhledem k referenčním pozicím R kmitů a výpočet parametrů ACC, SE, PPV a F1.

Kombinace elektrod	Řád filtru	TP	FP	FN	ACC (%)	SE (%)	PPV (%)	F1 (%)
1,2	4	617	9	27	94,49	95,81	98,56	97,17
1,3	32	566	33	78	83,60	87,89	94,49	91,07
1,4	2	640	3	4	98,92	99,38	99,53	99,46
2,3	8	237	103	407	31,73	36,80	69,71	48,17
2,4	26	638	5	6	98,31	99,07	99,22	99,15
3,4	32	632	13	12	96,20	98,14	97,98	98,06
1,2,3	2	599	22	45	89,94	93,01	96,46	94,70
1,2,4	2	640	4	4	98,77	99,38	99,38	99,38
1,3,4	2	643	1	1	99,69	99,85	99,85	99,85
2,3,4	34	642	3	2	99,23	99,69	99,54	99,61
1,2,3,4	2	640	4	4	98,77	99,38	99,38	99,38

Tabulka 16: Ideální nastavení metody ANFIS pro všechny možné kombinace elektrod u záznamu r02. Stanovené počty TP, FP a FN na základě detekce pozic R kmitů v extrahovaných fEKG signálech pomocí hybridní metody ICA-ANFIS-WT vzhledem k referenčním pozicím R kmitů a výpočet parametrů ACC, SE, PPV a F1.

Kombinace elektrod	Tvar funkcí příslušnosti	Počet epoch	Počet funkcí příslušnosti	TP	FP	FN	ACC (%)	SE (%)	PPV (%)	F1 (%)
1,2	gbellmf	2	10	507	32	153	73,27	76,82	94,06	84,57
1,3	gbellmf	4	30	471	163	189	57,23	71,36	74,29	72,80
1,4	trapmf	6	10	635	27	25	92,43	96,21	95,92	96,07
2,3	trimf	2	10	320	339	340	32,03	48,49	48,56	48,52
2,4	trapmf	10	20	595	73	65	81,17	90,15	89,07	89,61
3,4	gaussmf	10	30	478	209	182	55,01	72,42	69,58	70,97
1,2,3	trapmf	6	10	554	52	106	77,81	83,94	91,42	87,52
1,2,4	trimf	8	30	624	37	36	89,53	94,55	94,40	94,47
1,3,4	trapmf	6	20	627	38	33	89,83	95,00	94,29	94,64
2,3,4	trapmf	4	30	607	26	53	88,48	91,97	95,89	93,89
1,2,3,4	gbellmf	4	10	656	3	4	98,94	99,39	99,55	99,47

Tabulka 17: Ideální nastavení řádu filtru algoritmu RLS pro všechny možné kombinace elektrod u záznamu r02. Stanovené počty TP, FP a FN na základě detekce pozic R kmitů v extrahovaných fEKG signálech pomocí hybridní metody ICA-RLS-WT vzhledem k referenčním pozicím R kmitů a výpočet parametrů ACC, SE, PPV a F1.

Kombinace elektrod	Řád filtru	TP	FP	FN	ACC (%)	SE (%)	PPV (%)	F1 (%)
1,2	12	564	20	96	82,94	85,46	96,58	90,68
1,3	20	575	55	85	80,42	87,12	91,27	89,15
1,4	16	657	4	3	98,95	99,55	99,40	99,47
2,3	4	358	302	302	37,21	54,24	54,24	54,24
2,4	42	620	37	40	88,95	93,94	94,37	94,15
3,4	98	615	51	45	86,50	93,18	92,34	92,76
1,2,3	16	597	15	63	88,44	90,46	97,55	93,87
1,2,4	30	650	6	10	97,60	98,49	99,09	98,78
1,3,4	16	654	4	6	98,49	99,09	99,39	99,24
2,3,4	20	631	25	29	92,12	95,61	96,19	95,90
1,2,3,4	16	656	1	4	99,24	99,39	99,85	99,62

Tabulka 18: Ideální nastavení metody ANFIS pro všechny možné kombinace elektrod u záznamu r03. Stanovené počty TP, FP a FN na základě detekce pozic R kmitů v extrahovaných fEKG signálech pomocí hybridní metody ICA-ANFIS-WT vzhledem k referenčním pozicím R kmitů a výpočet parametrů ACC, SE, PPV a F1.

Kombinace elektrod	Tvar funkcí příslušnosti	Počet epoch	Počet funkcí příslušnosti	TP	FP	FN	ACC (%)	SE (%)	PPV (%)	F1 (%)
1,2	trapmf	6	10	58	370	626	5,50	8,48	13,55	10,43
1,3	trimf	2	30	312	187	372	35,82	45,61	62,53	52,75
1,4	gaussmf	2	10	45	376	639	4,25	6,58	10,69	8,15
2,3	trimf	2	30	279	275	405	29,09	40,79	50,36	45,07
2,4	gaussmf	6	30	619	48	65	84,56	90,50	92,80	91,64
3,4	trimf	4	10	333	152	351	39,83	48,68	68,66	56,97
1,2,3	trimf	2	30	63	365	621	6,01	9,21	14,72	11,33
1,2,4	trimf	2	10	259	285	425	26,73	37,87	47,61	42,18
1,3,4	trimf	6	10	48	373	636	4,54	7,02	11,40	8,69
2,3,4	trimf	2	20	334	305	350	33,77	48,83	52,27	50,49
1,2,3,4	gaussmf	10	10	52	369	632	4,94	7,60	12,35	9,41

Tabulka 19: Ideální nastavení řádu filtru algoritmu RLS pro všechny možné kombinace elektrod u záznamu r03. Stanovené počty TP, FP a FN na základě detekce pozic R kmitů v extrahovaných fEKG signálech pomocí hybridní metody ICA-RLS-WT vzhledem k referenčním pozicím R kmitů a výpočet parametrů ACC, SE, PPV a F1.

Kombinace elektrod	Řád filtru	TP	FP	FN	ACC (%)	SE (%)	PPV (%)	F1 (%)
1,2	70	473	56	211	63,92	69,15	89,41	77,99
1,3	2	242	195	442	27,53	35,38	55,38	43,18
1,4	16	647	16	37	92,43	94,59	97,59	96,07
2,3	2	193	358	491	18,52	28,22	35,03	31,26
2,4	86	647	4	37	94,04	94,59	99,39	96,93
3,4	14	265	172	419	30,96	38,74	60,64	47,28
1,2,3	78	498	34	186	69,36	72,81	93,61	81,91
1,2,4	10	261	127	423	32,18	38,16	67,27	48,69
1,3,4	28	547	21	137	77,59	79,97	96,30	87,38
2,3,4	84	615	6	69	89,13	89,91	99,03	94,25
1,2,3,4	14	478	26	206	67,32	69,88	94,84	80,47

Tabulka 20: Ideální nastavení metody ANFIS pro všechny možné kombinace elektrod u záznamu r04. Stanovené počty TP, FP a FN na základě detekce pozic R kmitů v extrahovaných fEKG signálech pomocí hybridní metody ICA-ANFIS-WT vzhledem k referenčním pozicím R kmitů a výpočet parametrů ACC, SE, PPV a F1.

Kombinace elektrod	Tvar funkcí příslušnosti	Počet epoch	Počet funkcí příslušnosti	TP	FP	FN	ACC (%)	SE (%)	PPV (%)	F1 (%)
1,2	trimf	2	20	150	334	482	15,53	23,73	30,99	26,88
1,3	trimf	2	10	185	305	447	19,74	29,27	37,76	32,98
1,4	trimf	2	10	233	260	399	26,12	36,87	47,26	41,42
2,3	trimf	2	30	179	325	453	18,70	28,32	35,52	31,51
2,4	trimf	2	20	257	308	375	27,34	40,67	45,49	42,94
3,4	trimf	2	10	175	300	457	18,78	27,69	36,84	31,62
1,2,3	trimf	2	20	164	328	468	17,08	25,95	33,33	29,18
1,2,4	trimf	2	10	177	325	455	18,50	28,01	35,26	31,22
1,3,4	trimf	10	20	123	230	509	14,27	19,46	34,84	24,98
2,3,4	trimf	2	10	191	324	441	19,98	30,22	37,09	33,30
1,2,3,4	trimf	2	10	181	325	451	18,91	28,64	35,77	31,81

Tabulka 21: Ideální nastavení řádu filtru algoritmu RLS pro všechny možné kombinace elektrod u záznamu r04. Stanovené počty TP, FP a FN na základě detekce pozic R kmitů v extrahovaných fEKG signálech pomocí hybridní metody ICA-RLS-WT vzhledem k referenčním pozicím R kmitů a výpočet parametrů ACC, SE, PPV a F1.

Kombinace elektrod	Řád filtru	TP	FP	FN	ACC (%)	SE (%)	PPV (%)	F1 (%)
1,2	70	444	200	188	53,37	70,25	68,94	69,59
1,3	42	470	94	162	64,74	74,37	83,33	78,60
1,4	46	528	67	104	75,54	83,54	88,74	86,06
2,3	98	504	135	128	65,71	79,75	78,87	79,31
2,4	92	456	180	176	56,16	72,15	71,70	71,92
3,4	36	366	125	266	48,35	57,91	74,54	65,18
1,2,3	88	494	149	138	63,25	78,17	76,83	77,49
1,2,4	100	396	220	236	46,48	62,66	64,29	63,46
1,3,4	38	253	182	379	31,08	40,03	58,16	47,42
2,3,4	96	418	207	214	49,82	66,14	66,88	66,51
1,2,3,4	94	387	216	245	45,64	61,23	64,18	62,67

Tabulka 22: Ideální nastavení metody ANFIS pro všechny možné kombinace elektrod u záznamu r05. Stanovené počty TP, FP a FN na základě detekce pozic R kmitů v extrahovaných fEKG signálech pomocí hybridní metody ICA-ANFIS-WT vzhledem k referenčním pozicím R kmitů a výpočet parametrů ACC, SE, PPV a F1.

Kombinace elektrod	Tvar funkcí příslušnosti	Počet epoch	Počet funkcí příslušnosti	TP	FP	FN	ACC (%)	SE (%)	PPV (%)	F1 (%)
1,2	trapmf	2	10	400	21	245	60,06	62,02	95,01	75,05
1,3	trimf	2	20	526	113	119	69,39	81,55	82,32	81,93
1,4	gaussmf	4	20	634	3	11	97,84	98,29	99,53	98,91
2,3	trimf	2	30	408	258	237	45,18	63,26	61,26	62,24
2,4	gaussmf	6	30	559	91	86	75,95	86,67	86,00	86,33
3,4	gbellmf	2	10	581	67	64	81,60	90,08	89,66	89,87
1,2,3	gaussmf	2	10	46	358	599	4,59	7,13	11,39	8,77
1,2,4	gaussmf	2	10	49	355	596	4,90	7,60	12,13	9,34
1,3,4	trapmf	2	10	631	9	14	96,48	97,83	98,59	98,21
2,3,4	gbellmf	2	10	595	59	50	84,52	92,25	90,98	91,61
1,2,3,4	trapmf	2	10	630	9	15	96,33	97,67	98,59	98,13

Tabulka 23: Ideální nastavení řádu filtru algoritmu RLS pro všechny možné kombinace elektrod u záznamu r05. Stanovené počty TP, FP a FN na základě detekce pozic R kmitů v extrahovaných fEKG signálech pomocí hybridní metody ICA-RLS-WT vzhledem k referenčním pozicím R kmitů a výpočet parametrů ACC, SE, PPV a F1.

Kombinace elektrod	Řád filtru	TP	FP	FN	ACC (%)	SE (%)	PPV (%)	F1 (%)
1,2	2	370	25	275	55,22	57,36	93,67	71,15
1,3	20	624	12	21	94,98	96,74	98,11	97,42
1,4	16	644	1	1	99,69	99,85	99,85	99,85
2,3	8	421	240	224	47,57	65,27	63,69	64,47
2,4	98	606	39	39	88,60	93,95	93,95	93,95
3,4	80	636	6	9	97,70	98,61	99,07	98,83
1,2,3	2	46	358	599	4,59	7,13	11,39	8,77
1,2,4	2	49	355	596	4,90	7,60	12,13	9,34
1,3,4	16	644	1	1	99,69	99,85	99,85	99,85
2,3,4	42	642	3	3	99,07	99,54	99,54	99,54
1,2,3,4	16	644	1	1	99,69	99,85	99,85	99,85

Tabulka 24: Ideální nastavení metody ANFIS pro všechny možné kombinace elektrod u záznamu r06. Stanovené počty TP, FP a FN na základě detekce pozic R kmitů v extrahovaných fEKG signálech pomocí hybridní metody ICA-ANFIS-WT vzhledem k referenčním pozicím R kmitů a výpočet parametrů ACC, SE, PPV a F1.

Kombinace elektrod	Tvar funkcí příslušnosti	Počet epoch	Počet funkcí příslušnosti	TP	FP	FN	ACC (%)	SE (%)	PPV (%)	F1 (%)
1,2	trimf	2	20	44	312	630	4,46	6,53	12,36	8,54
1,3	trapmf	2	10	147	360	527	14,22	21,81	28,99	24,89
1,4	gaussmf	2	10	57	384	617	5,39	8,46	12,93	10,22
2,3	trimf	4	10	256	415	418	23,51	37,98	38,15	38,07
2,4	trapmf	4	10	58	380	616	5,50	8,61	13,24	10,43
3,4	gbellmf	2	30	334	212	340	37,70	49,55	61,17	54,75
1,2,3	trapmf	4	10	46	311	628	4,67	6,83	12,89	8,92
1,2,4	trimf	2	10	219	262	455	23,40	32,49	45,53	37,92
1,3,4	trapmf	4	20	63	373	611	6,02	9,35	14,45	11,35
2,3,4	trimf	2	10	56	386	618	5,28	8,31	12,67	10,04
1,2,3,4	trimf	2	10	55	386	619	5,19	8,16	12,47	9,87

Tabulka 25: Ideální nastavení řádu filtru algoritmu RLS pro všechny možné kombinace elektrod u záznamu r06. Stanovené počty TP, FP a FN na základě detekce pozic R kmitů v extrahovaných fEKG signálech pomocí hybridní metody ICA-RLS-WT vzhledem k referenčním pozicím R kmitů a výpočet parametrů ACC, SE, PPV a F1.

Kombinace elektrod	Řád filtru	TP	FP	FN	ACC (%)	SE (%)	PPV (%)	F1 (%)
1,2	16	301	148	373	36,62	44,66	67,04	53,61
1,3	2	144	206	530	16,36	21,37	41,14	28,13
1,4	100	561	47	113	77,81	83,23	92,27	87,52
2,3	12	75	162	599	8,97	11,13	31,65	16,47
2,4	54	577	51	97	79,59	85,61	91,88	88,63
3,4	12	239	224	435	26,62	35,46	51,62	42,04
1,2,3	16	273	176	401	32,12	40,50	60,80	48,62
1,2,4	8	182	152	492	22,03	27,00	54,49	36,11
1,3,4	66	475	99	199	61,45	70,48	82,75	76,12
2,3,4	84	569	56	105	77,95	84,42	91,04	87,61
1,2,3,4	98	596	39	78	83,59	88,43	93,86	91,06

Tabulka 26: Ideální nastavení metody ANFIS pro všechny možné kombinace elektrod u záznamu r07. Stanovené počty TP, FP a FN na základě detekce pozic R kmitů v extrahovaných fEKG signálech pomocí hybridní metody ICA-ANFIS-WT vzhledem k referenčním pozicím R kmitů a výpočet parametrů ACC, SE, PPV a F1.

Kombinace elektrod	Tvar funkcí příslušnosti	Počet epoch	Počet funkcí příslušnosti	TP	FP	FN	ACC (%)	SE (%)	PPV (%)	F1 (%)
1,2	trapmf	4	10	229	320	398	24,18	36,52	41,71	38,95
1,3	trapmf	6	30	382	220	245	45,10	60,93	63,46	62,16
1,4	trapmf	8	10	280	203	347	33,74	44,66	57,97	50,45
2,3	trimf	2	20	330	315	297	35,03	52,63	51,16	51,89
2,4	trimf	2	10	261	315	366	27,71	41,63	45,31	43,39
3,4	trapmf	6	20	289	258	338	32,66	46,09	52,83	49,23
1,2,3	trimf	2	10	319	315	308	33,86	50,88	50,32	50,60
1,2,4	trimf	2	20	309	308	318	33,05	49,28	50,08	49,68
1,3,4	trimf	2	10	282	305	345	30,26	44,98	48,04	46,46
2,3,4	gbellmf	10	20	344	289	283	37,56	54,86	54,34	54,60
1,2,3,4	trimf	2	10	303	306	324	32,48	48,33	49,75	49,03

Tabulka 27: Ideální nastavení řádu filtru algoritmu RLS pro všechny možné kombinace elektrod u záznamu r07. Stanovené počty TP, FP a FN na základě detekce pozic R kmitů v extrahovaných fEKG signálech pomocí hybridní metody ICA-RLS-WT vzhledem k referenčním pozicím R kmitů a výpočet parametrů ACC, SE, PPV a F1.

Kombinace elektrod	Řád filtru	TP	FP	FN	ACC (%)	SE (%)	PPV (%)	F1 (%)
1,2	28	335	249	292	38,24	53,43	57,36	55,33
1,3	44	531	80	96	75,11	84,69	86,91	85,78
1,4	46	567	61	60	82,41	90,43	90,29	90,36
2,3	60	507	130	120	66,98	80,86	79,59	80,22
2,4	80	462	156	165	59,00	73,68	74,76	74,22
3,4	48	367	118	260	49,26	58,53	75,67	66,01
1,2,3	54	494	134	133	64,92	78,79	78,66	78,73
1,2,4	56	372	212	255	44,34	59,33	63,70	61,44
1,3,4	46	538	60	89	78,31	85,81	89,97	87,84
2,3,4	86	416	181	211	51,49	66,35	69,68	67,97
1,2,3,4	76	378	185	249	46,55	60,29	67,14	63,53

Tabulka 28: Ideální nastavení metody ANFIS pro všechny možné kombinace elektrod u záznamu r08. Stanovené počty TP, FP a FN na základě detekce pozic R kmitů v extrahovaných fEKG signálech pomocí hybridní metody ICA-ANFIS-WT vzhledem k referenčním pozicím R kmitů a výpočet parametrů ACC, SE, PPV a F1.

Kombinace elektrod	Tvar funkcí příslušnosti	Počet epoch	Počet funkcí příslušnosti	TP	FP	FN	ACC (%)	SE (%)	PPV (%)	F1 (%)
1,2	trapmf	2	10	636	16	15	95,35	97,70	97,55	97,62
1,3	trimf	6	20	467	59	184	65,78	71,74	88,78	79,35
1,4	gaussmf	2	10	650	1	1	99,69	99,85	99,85	99,85
2,3	gbellmf	8	10	635	7	16	96,51	97,54	98,91	98,22
2,4	trapmf	10	30	475	159	176	58,64	72,97	74,92	73,93
3,4	trimf	2	20	621	2	30	95,10	95,39	99,68	97,49
1,2,3	gaussmf	2	10	646	4	5	98,63	99,23	99,39	99,31
1,2,4	gaussmf	4	10	650	1	1	99,69	99,85	99,85	99,85
1,3,4	trapmf	2	10	650	1	1	99,69	99,85	99,85	99,85
2,3,4	trapmf	8	10	641	4	10	97,86	98,46	99,38	98,92
1,2,3,4	trapmf	10	20	111	207	540	12,94	17,05	34,91	22,91

Tabulka 29: Ideální nastavení řádu filtru algoritmu RLS pro všechny možné kombinace elektrod u záznamu r08. Stanovené počty TP, FP a FN na základě detekce pozic R kmitů v extrahovaných fEKG signálech pomocí hybridní metody ICA-RLS-WT vzhledem k referenčním pozicím R kmitů a výpočet parametrů ACC, SE, PPV a F1.

Kombinace elektrod	Řád filtru	TP	FP	FN	ACC (%)	SE (%)	PPV (%)	F1 (%)
1,2	20	639	16	12	95,80	98,16	97,56	97,86
1,3	12	630	12	21	95,02	96,77	98,13	97,45
1,4	30	650	1	1	99,69	99,85	99,85	99,85
2,3	58	640	10	11	96,82	98,31	98,46	98,39
2,4	4	337	284	314	36,04	51,77	54,27	52,99
3,4	10	637	7	14	96,81	97,85	98,91	98,38
1,2,3	46	649	3	2	99,24	99,69	99,54	99,62
1,2,4	30	650	1	1	99,69	99,85	99,85	99,85
1,3,4	2	650	1	1	99,69	99,85	99,85	99,85
2,3,4	14	644	6	7	98,02	98,93	99,08	99,00
1,2,3,4	14	126	159	525	15,56	19,36	44,21	26,92

Tabulka 30: Ideální nastavení metody ANFIS pro všechny možné kombinace elektrod u záznamu r09. Stanovené počty TP, FP a FN na základě detekce pozic R kmitů v extrahovaných fEKG signálech pomocí hybridní metody ICA-ANFIS-WT vzhledem k referenčním pozicím R kmitů a výpočet parametrů ACC, SE, PPV a F1.

Kombinace elektrod	Tvar funkcí příslušnosti	Počet epoch	Počet funkcí příslušnosti	TP	FP	FN	ACC (%)	SE (%)	PPV (%)	F1 (%)
1,2	gaussmf	8	30	394	32	263	57,18	59,97	92,49	72,76
1,3	trimf	6	10	452	109	205	59,01	68,80	80,57	74,22
1,4	trapmf	2	20	624	13	33	93,13	94,98	97,96	96,45
2,3	gbellmf	10	30	107	442	550	9,74	16,29	19,49	17,75
2,4	trimf	4	20	549	80	108	74,49	83,56	87,28	85,38
3,4	trimf	2	10	555	67	102	76,66	84,48	89,23	86,79
1,2,3	gbellmf	8	30	485	58	172	67,83	73,82	89,32	80,83
1,2,4	trapmf	4	30	614	13	43	91,64	93,46	97,93	95,64
1,3,4	gaussmf	10	10	616	23	41	90,59	93,76	96,40	95,06
2,3,4	trimf	4	30	582	35	75	84,10	88,58	94,33	91,37
1,2,3,4	trapmf	6	10	613	26	44	89,75	93,30	95,93	94,60

Tabulka 31: Ideální nastavení řádu filtru algoritmu RLS pro všechny možné kombinace elektrod u záznamu r09. Stanovené počty TP, FP a FN na základě detekce pozic R kmitů v extrahovaných fEKG signálech pomocí hybridní metody ICA-RLS-WT vzhledem k referenčním pozicím R kmitů a výpočet parametrů ACC, SE, PPV a F1.

Kombinace elektrod	Řád filtru	TP	FP	FN	ACC (%)	SE (%)	PPV (%)	F1 (%)
1,2	76	365	150	292	45,23	55,56	70,87	62,29
1,3	58	515	24	142	75,62	78,39	95,55	86,12
1,4	100	628	6	29	94,72	95,59	99,05	97,29
2,3	10	121	526	536	10,23	18,42	18,70	18,56
2,4	50	567	36	90	81,82	86,30	94,03	90,00
3,4	94	614	14	43	91,51	93,46	97,77	95,56
1,2,3	16	506	24	151	74,30	77,02	95,47	85,26
1,2,4	16	626	1	31	95,14	95,28	99,84	97,51
1,3,4	86	626	6	31	94,42	95,28	99,05	97,13
2,3,4	56	615	8	42	92,48	93,61	98,72	96,09
1,2,3,4	96	625	6	32	94,27	95,13	99,05	97,05

Tabulka 32: Ideální nastavení metody ANFIS pro všechny možné kombinace elektrod u záznamu r10. Stanovené počty TP, FP a FN na základě detekce pozic R kmitů v extrahovaných fEKG signálech pomocí hybridní metody ICA-ANFIS-WT vzhledem k referenčním pozicím R kmitů a výpočet parametrů ACC, SE, PPV a F1.

Kombinace elektrod	Tvar funkcí příslušnosti	Počet epoch	Počet funkcí příslušnosti	TP	FP	FN	ACC (%)	SE (%)	PPV (%)	F1 (%)
1,2	gbellmf	2	30	176	379	461	17,32	27,63	31,71	29,53
1,3	trimf	2	10	325	173	312	40,12	51,02	65,26	57,27
1,4	trimf	2	30	391	257	246	43,74	61,38	60,34	60,86
2,3	gbellmf	4	10	272	205	365	32,30	42,70	57,02	48,83
2,4	trimf	2	10	255	368	382	25,37	40,03	40,93	40,48
3,4	trimf	4	10	393	163	244	49,13	61,70	70,68	65,88
1,2,3	gbellmf	8	20	193	364	444	19,28	30,30	34,65	32,33
1,2,4	trimf	2	20	291	363	346	29,10	45,68	44,50	45,08
1,3,4	gaussmf	2	30	280	359	357	28,11	43,96	43,82	43,89
2,3,4	trapmf	6	20	133	396	504	12,88	20,88	25,14	22,81
1,2,3,4	trapmf	2	30	394	278	243	43,06	61,85	58,63	60,20

Tabulka 33: Ideální nastavení řádu filtru algoritmu RLS pro všechny možné kombinace elektrod u záznamu r10. Stanovené počty TP, FP a FN na základě detekce pozic R kmitů v extrahovaných fEKG signálech pomocí hybridní metody ICA-RLS-WT vzhledem k referenčním pozicím R kmitů a výpočet parametrů ACC, SE, PPV a F1.

Kombinace elektrod	Řád filtru	TP	FP	FN	ACC (%)	SE (%)	PPV (%)	F1 (%)
1,2	100	498	74	139	70,04	78,18	87,06	82,38
1,3	42	290	133	347	37,66	45,53	68,56	54,72
1,4	52	622	33	15	92,84	97,65	94,96	96,29
2,3	6	290	225	347	33,64	45,53	56,31	50,35
2,4	52	599	42	38	88,22	94,04	93,45	93,74
3,4	2	399	138	238	51,48	62,64	74,30	67,97
1,2,3	36	537	57	100	77,38	84,30	90,40	87,25
1,2,4	54	624	36	13	92,72	97,96	94,55	96,22
1,3,4	92	621	38	16	92,00	97,49	94,23	95,83
2,3,4	34	608	62	29	86,98	95,45	90,75	93,04
1,2,3,4	52	626	33	11	93,43	98,27	94,99	96,61

Tabulka 34: Ideální nastavení metody ANFIS pro všechny možné kombinace elektrod u záznamu r11. Stanovené počty TP, FP a FN na základě detekce pozic R kmitů v extrahovaných fEKG signálech pomocí hybridní metody ICA-ANFIS-WT vzhledem k referenčním pozicím R kmitů a výpočet parametrů ACC, SE, PPV a F1.

Kombinace elektrod	Tvar funkcí příslušnosti	Počet epoch	Počet funkcí příslušnosti	TP	FP	FN	ACC (%)	SE (%)	PPV (%)	F1 (%)
1,2	trimf	10	30	105	404	600	9,47	14,89	20,63	17,30
1,3	gaussmf	10	30	103	392	602	9,39	14,61	20,81	17,17
1,4	gaussmf	10	30	291	293	414	29,16	41,28	49,83	45,15
2,3	gbellmf	2	20	73	249	632	7,65	10,36	22,67	14,22
2,4	trapmf	2	30	66	419	639	5,87	9,36	13,61	11,09
3,4	trimf	2	30	117	433	588	10,28	16,60	21,27	18,65
1,2,3	gaussmf	10	30	94	433	611	8,26	13,33	17,84	15,26
1,2,4	gaussmf	8	30	84	308	621	8,29	11,92	21,43	15,31
1,3,4	trimf	2	10	171	329	534	16,54	24,26	34,20	28,38
2,3,4	trimf	2	10	196	255	509	20,42	27,80	43,46	33,91
1,2,3,4	gbellmf	2	20	79	387	626	7,23	11,21	16,95	13,49

Tabulka 35: Ideální nastavení řádu filtru algoritmu RLS pro všechny možné kombinace elektrod u záznamu r11. Stanovené počty TP, FP a FN na základě detekce pozic R kmitů v extrahovaných fEKG signálech pomocí hybridní metody ICA-RLS-WT vzhledem k referenčním pozicím R kmitů a výpočet parametrů ACC, SE, PPV a F1.


Kombinace elektrod	Řád filtru	TP	FP	FN	ACC (%)	SE (%)	PPV (%)	F1 (%)
1,2	26	210	353	495	19,85	29,79	37,30	33,12
1,3	100	133	345	572	12,67	18,87	27,82	22,49
1,4	12	166	312	539	16,32	23,55	34,73	28,06
2,3	2	70	271	635	7,17	9,93	20,53	13,38
2,4	10	97	412	608	8,68	13,76	19,06	15,98
3,4	6	110	396	595	9,99	15,60	21,74	18,17
1,2,3	26	210	348	495	19,94	29,79	37,63	33,25
1,2,4	8	86	291	619	8,64	12,20	22,81	15,90
1,3,4	42	82	295	623	8,20	11,63	21,75	15,16
2,3,4	24	168	287	537	16,94	23,83	36,92	28,97
1,2,3,4	80	322	267	383	33,13	45,67	54,67	49,77

Tabulka 36: Ideální nastavení metody ANFIS pro všechny možné kombinace elektrod u záznamu r12. Stanovené počty TP, FP a FN na základě detekce pozic R kmitů v extrahovaných fEKG signálech pomocí hybridní metody ICA-ANFIS-WT vzhledem k referenčním pozicím R kmitů a výpočet parametrů ACC, SE, PPV a F1.


Kombinace elektrod	Tvar funkcí příslušnosti	Počet epoch	Počet funkcí příslušnosti	TP	FP	FN	ACC (%)	SE (%)	PPV (%)	F1 (%)
1,2	trapmf	2	10	48	336	637	4,70	7,01	12,50	8,98
1,3	trimf	2	30	162	137	523	19,71	23,65	54,18	32,93
1,4	trapmf	2	30	55	375	630	5,19	8,03	12,79	9,87
2,3	gbellmf	2	10	211	163	474	24,88	30,80	56,42	39,85
2,4	trapmf	2	10	55	376	630	5,18	8,03	12,76	9,86
3,4	gbellmf	2	10	112	164	573	13,19	16,35	40,58	23,31
1,2,3	gaussmf	10	30	45	263	640	4,75	6,57	14,61	9,06
1,2,4	trimf	4	20	74	133	611	9,05	10,80	35,75	16,59
1,3,4	gaussmf	6	10	55	375	630	5,19	8,03	12,79	9,87
2,3,4	gaussmf	2	10	55	376	630	5,18	8,03	12,76	9,86
1,2,3,4	gaussmf	2	10	55	375	630	5,19	8,03	12,79	9,87

Tabulka 37: Ideální nastavení řádu filtru algoritmu RLS pro všechny možné kombinace elektrod u záznamu r12. Stanovené počty TP, FP a FN na základě detekce pozic R kmitů v extrahovaných fEKG signálech pomocí hybridní metody ICA-RLS-WT vzhledem k referenčním pozicím R kmitů a výpočet parametrů ACC, SE, PPV a F1.

Kombinace elektrod	Řád filtru	TP	FP	FN	ACC (%)	SE (%)	PPV (%)	F1 (%)
1,2	100	239	100	446	30,45	34,89	70,50	46,68
1,3	4	164	199	521	18,55	23,94	45,18	31,30
1,4	100	583	51	102	79,21	85,11	91,96	88,40
2,3	10	113	245	572	12,15	16,50	31,56	21,67
2,4	100	566	60	119	75,97	82,63	90,42	86,35
3,4	14	106	156	579	12,60	15,47	40,46	22,39
1,2,3	100	190	108	495	23,96	27,74	63,76	38,66
1,2,4	98	128	107	557	16,16	18,69	54,47	27,83
1,3,4	100	576	52	109	78,16	84,09	91,72	87,74
2,3,4	100	571	58	114	76,85	83,36	90,78	86,91
1,2,3,4	100	590	42	95	81,16	86,13	93,35	89,59




(a) Srovnání referenční a odhadnuté křivky fHR pomocí hybridní metody ICA-ANFIS-WT.




(b) Srovnání referenční a odhadnuté křivky fHR pomocí hybridní metody ICA-RLS-WT.

Obrázek 51: Srovnání odhadnutých a referenčních křivek fHR ze záznamu r02 pomocí Bland-Altmanova grafu.




(a) Srovnání referenční a odhadnuté křivky fHR pomocí hybridní metody ICA-ANFIS-WT.




(b) Srovnání referenční a odhadnuté křivky fHR pomocí hybridní metody ICA-RLS-WT.

Obrázek 52: Srovnání odhadnutých a referenčních křivek fHR ze záznamu r03 pomocí Bland-Altmanova grafu.




(a) Srovnání referenční a odhadnuté křivky fHR pomocí hybridní metody ICA-ANFIS-WT.




(b) Srovnání referenční a odhadnuté křivky fHR pomocí hybridní metody ICA-RLS-WT.

Obrázek 53: Srovnání odhadnutých a referenčních křivek fHR ze záznamu r05 pomocí Bland-Altmanova grafu.




(a) Srovnání referenční a odhadnuté křivky fHR pomocí hybridní metody ICA-ANFIS-WT.




(b) Srovnání referenční a odhadnuté křivky fHR pomocí hybridní metody ICA-RLS-WT.

Obrázek 54: Srovnání odhadnutých a referenčních křivek fHR ze záznamu r06 pomocí Bland-Altmanova grafu.




(a) Srovnání referenční a odhadnuté křivky fHR pomocí hybridní metody ICA-ANFIS-WT.




(b) Srovnání referenční a odhadnuté křivky fHR pomocí hybridní metody ICA-RLS-WT.

Obrázek 55: Srovnání odhadnutých a referenčních křivek fHR ze záznamu r07 pomocí Bland-Altmanova grafu.




(a) Srovnání referenční a odhadnuté křivky fHR pomocí hybridní metody ICA-ANFIS-WT.




(b) Srovnání referenční a odhadnuté křivky fHR pomocí hybridní metody ICA-RLS-WT.

Obrázek 56: Srovnání odhadnutých a referenčních křivek fHR ze záznamu r09 pomocí Bland-Altmanova grafu.




(a) Srovnání referenční a odhadnuté křivky fHR pomocí hybridní metody ICA-ANFIS-WT.




(b) Srovnání referenční a odhadnuté křivky fHR pomocí hybridní metody ICA-RLS-WT.

Obrázek 57: Srovnání odhadnutých a referenčních křivek fHR ze záznamu r10 pomocí Bland-Altmanova grafu.



(a) Srovnání referenční a odhadnuté křivky fHR pomocí hybridní metody ICA-ANFIS-WT.



(b) Srovnání referenční a odhadnuté křivky fHR pomocí hybridní metody ICA-RLS-WT.

Obrázek 58: Srovnání odhadnutých a referenčních křivek fHR ze záznamu r12 pomocí Bland-Altmanova grafu.

B Experimenty na reálných datech z databáze EKG physionet challenge 2013

Tato příloha obsahuje výsledky obdržené během testování hybridních metod na databázi EKG physionet challenge 2013. Výsledky hodnocení na základě určení přesnosti detekce R kmitů obsahovaly velké množství tabulek, proto bylo rozhodnuto přesunout zde všechny tabulky, ze kterých vznikly shrnující tabulky. Shrnující tabulky zobrazovaly ideální kombinaci elektrod a nastavení adaptivních metod pro jednotlivé záznamy. Tabulky 38 až 87 zobrazují jaké bylo ideální nastavení adaptivních metod pro jednotlivé kombinace elektrod. Každá tabulka obsahuje 11 řádků pro všechny možné kombinace elektrod a každá z těchto tabulek je vytvořena zvlášť pro jednotlivé záznamy a hybridní metody. Zvýrazněný řádek v tabulkách značí, kterou kombinací elektrod bylo dosaženo nejlepšího výsledku na základě parametru ACC. V případě, kdy bylo dosaženo pro 2 a více kombinací stejného výsledku, byl brán zřetel na rychlost výpočtu a popřípadě počet použitých elektrod. U metody ANFIS hraje největší roli počet funkcí příslušnosti a poté počet epoch. U RLS algoritmu se vybral v případě stejného výsledku ten, který byl vytvořen s nižším řádem filtru. Dále tato příloha obsahuje Bland-Altmany grafy pro zbylých 21 záznamů z databáze EKG physionet challenge 2013, které nebyly ukázány v experimentech, viz obrázky 59 až 79.

Tabulka 38: Ideální nastavení metody ANFIS pro všechny možné kombinace elektrod u záznamu a01. Stanovené počty TP, FP a FN na základě detekce pozic R kmitů v extrahovaných fEKG signálech pomocí hybridní metody ICA-ANFIS-WT vzhledem k referenčním pozicím R kmitů a výpočet parametrů ACC, SE, PPV a F1.

Kombinace elektrod	Tvar funkcí příslušnosti	Počet epoch	Počet funkcí příslušnosti	TP	FP	FN	ACC (%)	SE (%)	PPV (%)	F1 (%)
1,2	gausmf	2	10	23	57	122	11,39	15,86	28,75	20,44
1,3	gausmf	10	30	38	55	107	19,00	26,21	40,86	31,93
1,4	trimf	10	30	96	39	49	52,17	66,21	71,11	68,57
2,3	gausmf	10	10	30	54	115	15,08	20,69	35,71	26,20
2,4	gausmf	2	10	60	65	85	28,57	41,38	48,00	44,44
3,4	gbellmf	6	20	75	59	70	36,77	51,72	55,97	53,76
1,2,3	trapmf	8	20	25	57	120	12,38	17,24	30,49	22,03
1,2,4	gausmf	6	10	15	62	130	7,25	10,35	19,48	13,51
1,3,4	gausmf	2	10	131	3	14	88,51	90,35	97,76	93,91
2,3,4	trapmf	4	30	34	61	111	16,51	23,45	35,79	28,33
1,2,3,4	trimf	2	10	128	8	17	83,66	88,28	94,12	91,10

Tabulka 39: Ideální nastavení řádu filtru algoritmu RLS pro všechny možné kombinace elektrod u záznamu a01. Stanovené počty TP, FP a FN na základě detekce pozic R kmitů v extrahovaných fEKG signálech pomocí hybridní metody ICA-RLS-WT vzhledem k referenčním pozicím R kmitů a výpočet parametrů ACC, SE, PPV a F1.

Kombinace elektrod	Řád filtru	TP	FP	FN	ACC (%)	SE (%)	PPV (%)	F1 (%)
1,2	100	22	58	123	10,84	15,17	27,50	19,56
1,3	4	20	60	125	9,76	13,79	25,00	17,78
1,4	44	44	67	101	20,76	30,35	39,64	34,38
2,3	52	28	62	117	13,53	19,31	31,11	23,83
2,4	100	128	10	17	82,58	88,28	92,75	90,46
3,4	100	48	56	97	23,88	33,10	46,15	38,55
1,2,3	14	73	59	72	35,78	50,35	55,30	52,71
1,2,4	96	83	58	62	40,89	57,24	58,87	58,04
1,3,4	10	126	7	19	82,90	86,90	94,74	90,65
2,3,4	44	28	59	117	13,73	19,31	32,18	24,14
1,2,3,4	2	127	9	18	82,47	87,59	93,38	90,39

Tabulka 40: Ideální nastavení metody ANFIS pro všechny možné kombinace elektrod u záznamu a02. Stanovené počty TP, FP a FN na základě detekce pozic R kmitů v extrahovaných fEKG signálech pomocí hybridní metody ICA-ANFIS-WT vzhledem k referenčním pozicím R kmitů a výpočet parametrů ACC, SE, PPV a F1.

Kombinace elektrod	Tvar funkcí příslušnosti	Počet epoch	Počet funkcí příslušnosti	TP	FP	FN	ACC (%)	SE (%)	PPV (%)	F1 (%)
1,2	gaussmf	4	10	29	96	131	11,33	18,13	23,20	20,35
1,3	trimf	8	20	33	94	127	12,99	20,63	25,98	23,00
1,4	trapmf	4	20	32	93	128	12,65	20,00	25,60	22,46
2,3	trimf	2	30	25	75	135	10,64	15,63	25,00	19,23
2,4	trimf	2	10	27	80	133	11,25	16,88	25,23	20,23
3,4	trimf	2	10	25	92	135	9,92	15,63	21,37	18,05
1,2,3	gbellmf	8	10	31	92	129	12,30	19,38	25,20	21,91
1,2,4	trimf	2	10	30	90	130	12,00	18,75	25,00	21,43
1,3,4	gaussmf	8	30	24	41	136	11,94	15,00	36,92	21,33
2,3,4	gbellmf	8	30	31	88	129	12,50	19,38	26,05	22,22
1,2,3,4	trapmf	2	10	31	85	129	12,65	19,38	26,72	22,46

Tabulka 41: Ideální nastavení řádu filtru algoritmu RLS pro všechny možné kombinace elektrod u záznamu a02. Stanovené počty TP, FP a FN na základě detekce pozic R kmitů v extrahovaných fEKG signálech pomocí hybridní metody ICA-RLS-WT vzhledem k referenčním pozicím R kmitů a výpočet parametrů ACC, SE, PPV a F1.

Kombinace elektrod	Řád filtru	TP	FP	FN	ACC (%)	SE (%)	PPV (%)	F1 (%)
1,2	84	28	96	132	10,94	17,50	22,58	19,72
1,3	6	30	95	130	11,77	18,75	24,00	21,05
1,4	4	30	95	130	11,77	18,75	24,00	21,05
2,3	2	26	79	134	10,88	16,25	24,76	19,62
2,4	2	28	86	132	11,38	17,50	24,56	20,44
3,4	74	26	91	134	10,36	16,25	22,22	18,77
1,2,3	2	30	95	130	11,77	18,75	24,00	21,05
1,2,4	2	31	90	129	12,40	19,38	25,62	22,06
1,3,4	10	29	88	131	11,69	18,13	24,79	20,94
2,3,4	2	31	92	129	12,30	19,38	25,20	21,91
1,2,3,4	4	31	93	129	12,25	19,38	25,00	21,83

Tabulka 42: Ideální nastavení metody ANFIS pro všechny možné kombinace elektrod u záznamu a03. Stanovené počty TP, FP a FN na základě detekce pozic R kmitů v extrahovaných fEKG signálech pomocí hybridní metody ICA-ANFIS-WT vzhledem k referenčním pozicím R kmitů a výpočet parametrů ACC, SE, PPV a F1.

Kombinace elektrod	Tvar funkcí příslušnosti	Počet epoch	Počet funkcí příslušnosti	TP	FP	FN	ACC (%)	SE (%)	PPV (%)	F1 (%)
1,2	gbellmf	2	20	24	72	104	12,00	18,75	25,00	21,43
1,3	gaussmf	2	10	51	25	77	33,33	39,84	67,11	50,00
1,4	trapmf	2	10	26	80	102	12,50	20,31	24,53	22,22
2,3	trapmf	8	20	60	47	68	34,29	46,88	56,08	51,06
2,4	trimf	8	10	30	80	98	14,42	23,44	27,27	25,21
3,4	gaussmf	2	10	74	30	54	46,84	57,81	71,15	63,79
1,2,3	trimf	2	30	60	65	68	31,09	46,88	48,00	47,43
1,2,4	trimf	8	10	43	87	85	20,00	33,59	33,08	33,33
1,3,4	trimf	2	10	59	74	69	29,21	46,09	44,36	45,21
2,3,4	gaussmf	6	20	53	79	75	25,60	41,41	40,15	40,77
1,2,3,4	trapmf	4	10	56	75	72	27,59	43,75	42,75	43,24

Tabulka 43: Ideální nastavení řádu filtru algoritmu RLS pro všechny možné kombinace elektrod u záznamu a03. Stanovené počty TP, FP a FN na základě detekce pozic R kmitů v extrahovaných fEKG signálech pomocí hybridní metody ICA-RLS-WT vzhledem k referenčním pozicím R kmitů a výpočet parametrů ACC, SE, PPV a F1.

Kombinace elektrod	Řád filtru	TP	FP	FN	ACC (%)	SE (%)	PPV (%)	F1 (%)
1,2	90	78	7	50	57,78	60,94	91,77	73,24
1,3	4	50	27	78	32,26	39,06	64,94	48,78
1,4	100	126	2	2	96,92	98,44	98,44	98,44
2,3	4	59	55	69	32,24	46,09	51,75	48,76
2,4	28	123	5	5	92,48	96,09	96,09	96,09
3,4	12	87	21	41	58,39	67,97	80,56	73,73
1,2,3	96	114	12	14	81,43	89,06	90,48	89,76
1,2,4	2	38	96	90	16,96	29,69	28,36	29,01
1,3,4	100	123	4	5	93,18	96,09	96,85	96,47
2,3,4	12	122	8	6	89,71	95,31	93,85	94,57
1,2,3,4	100	122	4	6	92,42	95,31	96,83	96,06

Tabulka 44: Ideální nastavení metody ANFIS pro všechny možné kombinace elektrod u záznamu a04. Stanovené počty TP, FP a FN na základě detekce pozic R kmitů v extrahovaných fEKG signálech pomocí hybridní metody ICA-ANFIS-WT vzhledem k referenčním pozicím R kmitů a výpočet parametrů ACC, SE, PPV a F1.

Kombinace elektrod	Tvar funkcí příslušnosti	Počet epoch	Počet funkcí příslušnosti	TP	FP	FN	ACC (%)	SE (%)	PPV (%)	F1 (%)
1,2	gaussmf	2	10	129	0	0	100,00	100,00	100,00	100,00
1,3	trapmf	8	10	127	4	2	95,49	98,45	96,95	97,69
1,4	gaussmf	2	10	129	0	0	100,00	100,00	100,00	100,00
2,3	trimf	2	30	116	3	13	87,88	89,92	97,48	93,55
2,4	gaussmf	2	10	129	0	0	100,00	100,00	100,00	100,00
3,4	gaussmf	2	10	127	4	2	95,49	98,45	96,95	97,69
1,2,3	trapmf	2	20	127	1	2	97,69	98,45	99,22	98,83
1,2,4	trimf	4	10	126	0	3	97,67	97,67	100,00	98,82
1,3,4	gaussmf	2	10	129	0	0	100,00	100,00	100,00	100,00
2,3,4	gaussmf	2	10	128	0	1	99,23	99,23	100,00	99,61
1,2,3,4	gaussmf	2	10	129	0	0	100,00	100,00	100,00	100,00

Tabulka 45: Ideální nastavení řádu filtru algoritmu RLS pro všechny možné kombinace elektrod u záznamu a04. Stanovené počty TP, FP a FN na základě detekce pozic R kmitů v extrahovaných fEKG signálech pomocí hybridní metody ICA-RLS-WT vzhledem k referenčním pozicím R kmitů a výpočet parametrů ACC, SE, PPV a F1.

Kombinace elektrod	Řád filtru	TP	FP	FN	ACC (%)	SE (%)	PPV (%)	F1 (%)
1,2	64	129	0	0	100,00	100,00	100,00	100,00
1,3	100	127	4	2	95,49	98,45	96,95	97,69
1,4	28	129	0	0	100,00	100,00	100,00	100,00
2,3	4	126	1	3	96,92	97,67	99,21	98,44
2,4	100	129	0	0	100,00	100,00	100,00	100,00
3,4	98	129	0	0	100,00	100,00	100,00	100,00
1,2,3	100	128	0	1	99,23	99,23	100,00	99,61
1,2,4	62	129	0	0	100,00	100,00	100,00	100,00
1,3,4	100	129	0	0	100,00	100,00	100,00	100,00
2,3,4	100	127	0	2	98,45	98,45	100,00	99,22
1,2,3,4	100	129	0	0	100,00	100,00	100,00	100,00

Tabulka 46: Ideální nastavení metody ANFIS pro všechny možné kombinace elektrod u záznamu a05. Stanovené počty TP, FP a FN na základě detekce pozic R kmitů v extrahovaných fEKG signálech pomocí hybridní metody ICA-ANFIS-WT vzhledem k referenčním pozicím R kmitů a výpočet parametrů ACC, SE, PPV a F1.

Kombinace elektrod	Tvar funkcí příslušnosti	Počet epoch	Počet funkcí příslušnosti	TP	FP	FN	ACC (%)	SE (%)	PPV (%)	F1 (%)
1,2	gaussmf	2	10	128	1	1	98,46	99,23	99,23	99,23
1,3	trapmf	2	20	126	0	3	97,67	97,67	100,00	98,82
1,4	gaussmf	2	10	129	0	0	100,00	100,00	100,00	100,00
2,3	trimf	2	10	63	34	66	38,65	48,84	64,95	55,75
2,4	gaussmf	2	10	129	0	0	100,00	100,00	100,00	100,00
3,4	gaussmf	2	10	127	0	2	98,45	98,45	100,00	99,22
1,2,3	trimf	2	20	113	21	16	75,33	87,60	84,33	85,93
1,2,4	gbellmf	4	10	129	0	0	100,00	100,00	100,00	100,00
1,3,4	trapmf	2	20	48	61	81	25,26	37,21	44,04	40,34
2,3,4	trimf	8	30	126	2	3	96,18	97,67	98,44	98,05
1,2,3,4	gaussmf	2	10	129	0	0	100,00	100,00	100,00	100,00

Tabulka 47: Ideální nastavení řádu filtru algoritmu RLS pro všechny možné kombinace elektrod u záznamu a05. Stanovené počty TP, FP a FN na základě detekce pozic R kmitů v extrahovaných fEKG signálech pomocí hybridní metody ICA-RLS-WT vzhledem k referenčním pozicím R kmitů a výpočet parametrů ACC, SE, PPV a F1.

Kombinace elektrod	Řád filtru	TP	FP	FN	ACC (%)	SE (%)	PPV (%)	F1 (%)
1,2	6	126	1	3	96,92	97,67	99,21	98,44
1,3	32	126	0	3	97,67	97,67	100,00	98,82
1,4	100	129	0	0	100,00	100,00	100,00	100,00
2,3	2	60	46	69	34,29	46,51	56,60	51,06
2,4	100	129	0	0	100,00	100,00	100,00	100,00
3,4	100	129	0	0	100,00	100,00	100,00	100,00
1,2,3	6	127	1	2	97,69	98,45	99,22	98,83
1,2,4	58	129	0	0	100,00	100,00	100,00	100,00
1,3,4	4	41	55	88	22,28	31,78	42,71	36,44
2,3,4	92	128	2	1	97,71	99,23	98,46	98,84
1,2,3,4	88	129	0	0	100,00	100,00	100,00	100,00

Tabulka 48: Ideální nastavení metody ANFIS pro všechny možné kombinace elektrod u záznamu a06. Stanovené počty TP, FP a FN na základě detekce pozic R kmitů v extrahovaných fEKG signálech pomocí hybridní metody ICA-ANFIS-WT vzhledem k referenčním pozicím R kmitů a výpočet parametrů ACC, SE, PPV a F1.

Kombinace elektrod	Tvar funkcí příslušnosti	Počet epoch	Počet funkcí příslušnosti	TP	FP	FN	ACC (%)	SE (%)	PPV (%)	F1 (%)
1,2	gaussmf	2	10	33	67	127	14,54	20,63	33,00	25,39
1,3	trapmf	8	10	29	76	131	12,29	18,13	27,62	21,89
1,4	gaussmf	10	10	44	76	116	18,64	27,50	36,67	31,43
2,3	gbellmf	8	10	33	60	127	15,00	20,63	35,48	26,09
2,4	gbellmf	6	30	101	29	59	53,44	63,13	77,69	69,66
3,4	gaussmf	10	30	30	78	130	12,61	18,75	27,78	22,39
1,2,3	trapmf	10	30	46	77	114	19,41	28,75	37,40	32,51
1,2,4	trimf	6	20	40	60	120	18,18	25,00	40,00	30,77
1,3,4	gaussmf	2	20	23	77	137	9,71	14,38	23,00	17,69
2,3,4	trimf	10	20	23	72	137	9,91	14,38	24,21	18,04
1,2,3,4	trapmf	10	20	27	60	133	12,27	16,88	31,03	21,86

Tabulka 49: Ideální nastavení řádu filtru algoritmu RLS pro všechny možné kombinace elektrod u záznamu a06. Stanovené počty TP, FP a FN na základě detekce pozic R kmitů v extrahovaných fEKG signálech pomocí hybridní metody ICA-RLS-WT vzhledem k referenčním pozicím R kmitů a výpočet parametrů ACC, SE, PPV a F1.

Kombinace elektrod	Řád filtru	TP	FP	FN	ACC (%)	SE (%)	PPV (%)	F1 (%)
1,2	100	29	71	131	12,55	18,13	29,00	22,31
1,3	42	37	80	123	15,42	23,13	31,62	26,72
1,4	100	29	74	131	12,39	18,13	28,16	22,05
2,3	100	31	74	129	13,25	19,38	29,52	23,40
2,4	24	95	39	65	47,74	59,38	70,90	64,63
3,4	12	23	72	137	9,91	14,38	24,21	18,04
1,2,3	28	43	72	117	18,53	26,88	37,39	31,27
1,2,4	60	50	67	110	22,03	31,25	42,74	36,10
1,3,4	92	25	75	135	10,64	15,63	25,00	19,23
2,3,4	52	25	72	135	10,78	15,63	25,77	19,46
1,2,3,4	90	48	67	112	21,15	30,00	41,74	34,91

Tabulka 50: Ideální nastavení metody ANFIS pro všechny možné kombinace elektrod u záznamu a07. Stanovené počty TP, FP a FN na základě detekce pozic R kmitů v extrahovaných fEKG signálech pomocí hybridní metody ICA-ANFIS-WT vzhledem k referenčním pozicím R kmitů a výpočet parametrů ACC, SE, PPV a F1.

Kombinace elektrod	Tvar funkcí příslušnosti	Počet epoch	Počet funkcí příslušnosti	TP	FP	FN	ACC (%)	SE (%)	PPV (%)	F1 (%)
1,2	trapmf	8	10	21	70	109	10,50	16,15	23,08	19,01
1,3	trapmf	4	10	23	67	107	11,68	17,69	25,56	20,91
1,4	trimf	2	20	24	57	106	12,83	18,46	29,63	22,75
2,3	gbellmf	10	20	25	73	105	12,32	19,23	25,51	21,93
2,4	gaussmf	2	10	62	51	68	34,25	47,69	54,87	51,03
3,4	gaussmf	10	10	21	75	109	10,24	16,15	21,88	18,58
1,2,3	gaussmf	2	10	17	75	113	8,29	13,08	18,48	15,32
1,2,4	gaussmf	4	10	17	74	113	8,33	13,08	18,68	15,39
1,3,4	gbellmf	2	30	29	69	101	14,57	22,31	29,59	25,44
2,3,4	trapmf	8	20	18	72	112	8,91	13,85	20,00	16,36
1,2,3,4	trapmf	2	10	81	58	49	43,09	62,31	58,27	60,22

Tabulka 51: Ideální nastavení řádu filtru algoritmu RLS pro všechny možné kombinace elektrod u záznamu a07. Stanovené počty TP, FP a FN na základě detekce pozic R kmitů v extrahovaných fEKG signálech pomocí hybridní metody ICA-RLS-WT vzhledem k referenčním pozicím R kmitů a výpočet parametrů ACC, SE, PPV a F1.

Kombinace elektrod	Řád filtru	TP	FP	FN	ACC (%)	SE (%)	PPV (%)	F1 (%)
1,2	68	21	70	109	10,50	16,15	23,08	19,01
1,3	100	21	71	109	10,45	16,15	22,83	18,92
1,4	16	55	81	75	26,07	42,31	40,44	41,35
2,3	52	23	68	107	11,62	17,69	25,28	20,81
2,4	2	49	83	81	23,01	37,69	37,12	37,41
3,4	26	19	59	111	10,05	14,62	24,36	18,27
1,2,3	18	27	72	103	13,37	20,77	27,27	23,58
1,2,4	18	29	75	101	14,15	22,31	27,89	24,79
1,3,4	42	24	72	106	11,88	18,46	25,00	21,24
2,3,4	46	31	80	99	14,76	23,85	27,93	25,73
1,2,3,4	66	71	68	59	35,86	54,62	51,08	52,79

Tabulka 52: Ideální nastavení metody ANFIS pro všechny možné kombinace elektrod u záznamu a08. Stanovené počty TP, FP a FN na základě detekce pozic R kmitů v extrahovaných fEKG signálech pomocí hybridní metody ICA-ANFIS-WT vzhledem k referenčním pozicím R kmitů a výpočet parametrů ACC, SE, PPV a F1.

Kombinace elektrod	Tvar funkcí příslušnosti	Počet epoch	Počet funkcí příslušnosti	TP	FP	FN	ACC (%)	SE (%)	PPV (%)	F1 (%)
1,2	trimf	4	20	122	5	6	91,73	95,31	96,06	95,69
1,3	gbellmf	2	20	127	1	1	98,45	99,22	99,22	99,22
1,4	gaussmf	2	10	128	0	0	100,00	100,00	100,00	100,00
2,3	trapmf	2	20	44	39	84	26,35	34,38	53,01	41,71
2,4	trimf	2	30	58	36	70	35,37	45,31	61,70	52,25
3,4	gaussmf	4	30	128	1	0	99,23	100,00	99,23	99,61
1,2,3	gbellmf	2	10	126	2	2	96,92	98,44	98,44	98,44
1,2,4	gaussmf	2	10	128	0	0	100,00	100,00	100,00	100,00
1,3,4	gaussmf	2	10	127	1	1	98,45	99,22	99,22	99,22
2,3,4	trimf	8	30	127	3	1	96,95	99,22	97,69	98,45
1,2,3,4	gaussmf	2	10	128	0	0	100,00	100,00	100,00	100,00

Tabulka 53: Ideální nastavení řádu filtru algoritmu RLS pro všechny možné kombinace elektrod u záznamu a08. Stanovené počty TP, FP a FN na základě detekce pozic R kmitů v extrahovaných fEKG signálech pomocí hybridní metody ICA-RLS-WT vzhledem k referenčním pozicím R kmitů a výpočet parametrů ACC, SE, PPV a F1.

Kombinace elektrod	Řád filtru	TP	FP	FN	ACC (%)	SE (%)	PPV (%)	F1 (%)
1,2	4	121	6	7	90,30	94,53	95,28	94,90
1,3	28	127	1	1	98,45	99,22	99,22	99,22
1,4	100	128	0	0	100,00	100,00	100,00	100,00
2,3	2	61	71	67	30,65	47,66	46,21	46,92
2,4	2	58	64	70	30,21	45,31	47,54	46,40
3,4	86	128	0	0	100,00	100,00	100,00	100,00
1,2,3	16	126	2	2	96,92	98,44	98,44	98,44
1,2,4	100	128	0	0	100,00	100,00	100,00	100,00
1,3,4	98	127	1	1	98,45	99,22	99,22	99,22
2,3,4	2	127	3	1	96,95	99,22	97,69	98,45
1,2,3,4	96	128	0	0	100,00	100,00	100,00	100,00

Tabulka 54: Ideální nastavení metody ANFIS pro všechny možné kombinace elektrod u záznamu a09. Stanovené počty TP, FP a FN na základě detekce pozic R kmitů v extrahovaných fEKG signálech pomocí hybridní metody ICA-ANFIS-WT vzhledem k referenčním pozicím R kmitů a výpočet parametrů ACC, SE, PPV a F1.

Kombinace elektrod	Tvar funkcí příslušnosti	Počet epoch	Počet funkcí příslušnosti	TP	FP	FN	ACC (%)	SE (%)	PPV (%)	F1 (%)
1,2	trapmf	8	10	20	76	110	9,71	15,39	20,83	17,70
1,3	trapmf	4	20	26	70	104	13,00	20,00	27,08	23,01
1,4	gaussmf	2	10	22	73	108	10,84	16,92	23,16	19,56
2,3	trapmf	2	20	21	71	109	10,45	16,15	22,83	18,92
2,4	trapmf	4	10	21	73	109	10,35	16,15	22,34	18,75
3,4	trapmf	8	30	22	69	108	11,06	16,92	24,18	19,91
1,2,3	gbellmf	6	30	25	68	105	12,63	19,23	26,88	22,42
1,2,4	gaussmf	2	10	22	73	108	10,84	16,92	23,16	19,56
1,3,4	trapmf	6	20	27	68	103	13,64	20,77	28,42	24,00
2,3,4	trapmf	10	10	21	74	109	10,29	16,15	22,11	18,67
1,2,3,4	trimf	2	10	23	72	107	11,39	17,69	24,21	20,44

Tabulka 55: Ideální nastavení řádu filtru algoritmu RLS pro všechny možné kombinace elektrod u záznamu a09. Stanovené počty TP, FP a FN na základě detekce pozic R kmitů v extrahovaných fEKG signálech pomocí hybridní metody ICA-RLS-WT vzhledem k referenčním pozicím R kmitů a výpočet parametrů ACC, SE, PPV a F1.

Kombinace elektrod	Řád filtru	TP	FP	FN	ACC (%)	SE (%)	PPV (%)	F1 (%)
1,2	2	22	74	108	10,78	16,92	22,92	19,47
1,3	10	24	71	106	11,94	18,46	25,26	21,33
1,4	94	24	36	106	14,46	18,46	40,00	25,26
2,3	2	20	74	110	9,80	15,39	21,28	17,86
2,4	4	21	75	109	10,24	16,15	21,88	18,58
3,4	90	24	74	106	11,77	18,46	24,49	21,05
1,2,3	100	22	74	108	10,78	16,92	22,92	19,47
1,2,4	100	23	71	107	11,44	17,69	24,47	20,54
1,3,4	26	31	75	99	15,12	23,85	29,25	26,27
2,3,4	64	21	72	109	10,40	16,15	22,58	18,83
1,2,3,4	14	22	69	108	11,06	16,92	24,18	19,91

Tabulka 56: Ideální nastavení metody ANFIS pro všechny možné kombinace elektrod u záznamu a10. Stanovené počty TP, FP a FN na základě detekce pozic R kmitů v extrahovaných fEKG signálech pomocí hybridní metody ICA-ANFIS-WT vzhledem k referenčním pozicím R kmitů a výpočet parametrů ACC, SE, PPV a F1.

Kombinace elektrod	Tvar funkcí příslušnosti	Počet epoch	Počet funkcí příslušnosti	TP	FP	FN	ACC (%)	SE (%)	PPV (%)	F1 (%)
1,2	trapmf	2	10	35	69	140	14,34	20,00	33,65	25,09
1,3	trapmf	2	30	34	60	141	14,47	19,43	36,17	25,28
1,4	gaussmf	4	10	38	58	137	16,31	21,71	39,58	28,04
2,3	gbellmf	2	20	32	67	143	13,22	18,29	32,32	23,36
2,4	trimf	8	30	123	12	52	65,78	70,29	91,11	79,36
3,4	gaussmf	6	20	29	51	146	12,83	16,57	36,25	22,75
1,2,3	gaussmf	2	30	30	66	145	12,45	17,14	31,25	22,14
1,2,4	gaussmf	8	10	114	24	61	57,29	65,14	82,61	72,84
1,3,4	gbellmf	2	30	97	34	78	46,41	55,43	74,05	63,40
2,3,4	gaussmf	6	20	31	72	144	12,55	17,71	30,10	22,30
1,2,3,4	gaussmf	8	10	139	12	36	74,33	79,43	92,05	85,28

Tabulka 57: Ideální nastavení řádu filtru algoritmu RLS pro všechny možné kombinace elektrod u záznamu a10. Stanovené počty TP, FP a FN na základě detekce pozic R kmitů v extrahovaných fEKG signálech pomocí hybridní metody ICA-RLS-WT vzhledem k referenčním pozicím R kmitů a výpočet parametrů ACC, SE, PPV a F1.

Kombinace elektrod	Řád filtru	TP	FP	FN	ACC (%)	SE (%)	PPV (%)	F1 (%)
1,2	12	36	74	139	14,46	20,57	32,73	25,26
1,3	6	32	56	143	13,85	18,29	36,36	24,34
1,4	10	37	73	138	14,92	21,14	33,64	25,97
2,3	8	29	64	146	12,13	16,57	31,18	21,64
2,4	98	119	14	56	62,96	68,00	89,47	77,27
3,4	2	28	70	147	11,43	16,00	28,57	20,51
1,2,3	26	28	68	147	11,52	16,00	29,17	20,66
1,2,4	46	103	22	72	52,28	58,86	82,40	68,67
1,3,4	2	74	52	101	32,60	42,29	58,73	49,17
2,3,4	50	28	67	147	11,57	16,00	29,47	20,74
1,2,3,4	6	130	17	45	67,71	74,29	88,44	80,75

Tabulka 58: Ideální nastavení metody ANFIS pro všechny možné kombinace elektrod u záznamu a11. Stanovené počty TP, FP a FN na základě detekce pozic R kmitů v extrahovaných fEKG signálech pomocí hybridní metody ICA-ANFIS-WT vzhledem k referenčním pozicím R kmitů a výpočet parametrů ACC, SE, PPV a F1.

Kombinace elektrod	Tvar funkcí příslušnosti	Počet epoch	Počet funkcí příslušnosti	TP	FP	FN	ACC (%)	SE (%)	PPV (%)	F1 (%)
1,2	gaussmf	2	10	23	72	117	10,85	16,43	24,21	19,57
1,3	gaussmf	10	30	28	71	112	13,27	20,00	28,28	23,43
1,4	trapmf	6	10	29	65	111	14,15	20,71	30,85	24,79
2,3	gaussmf	2	10	25	70	115	11,91	17,86	26,32	21,28
2,4	gbellmf	8	10	26	68	114	12,50	18,57	27,66	22,22
3,4	gaussmf	6	30	23	60	117	11,50	16,43	27,71	20,63
1,2,3	gaussmf	2	10	25	70	115	11,91	17,86	26,32	21,28
1,2,4	gaussmf	8	10	27	68	113	12,98	19,29	28,42	22,98
1,3,4	trimf	10	30	31	72	109	14,62	22,14	30,10	25,51
2,3,4	gaussmf	2	10	27	70	113	12,86	19,29	27,84	22,79
1,2,3,4	gbellmf	8	10	27	68	113	12,98	19,29	28,42	22,98

Tabulka 59: Ideální nastavení řádu filtru algoritmu RLS pro všechny možné kombinace elektrod u záznamu a11. Stanovené počty TP, FP a FN na základě detekce pozic R kmitů v extrahovaných fEKG signálech pomocí hybridní metody ICA-RLS-WT vzhledem k referenčním pozicím R kmitů a výpočet parametrů ACC, SE, PPV a F1.

Kombinace elektrod	Řád filtru	TP	FP	FN	ACC (%)	SE (%)	PPV (%)	F1 (%)
1,2	2	26	69	114	12,44	18,57	27,37	22,13
1,3	20	32	55	108	16,41	22,86	36,78	28,19
1,4	24	29	23	111	17,79	20,71	55,77	30,21
2,3	6	25	70	115	11,91	17,86	26,32	21,28
2,4	8	24	68	116	11,54	17,14	26,09	20,69
3,4	6	22	73	118	10,33	15,71	23,16	18,72
1,2,3	100	27	60	113	13,50	19,29	31,03	23,79
1,2,4	16	26	69	114	12,44	18,57	27,37	22,13
1,3,4	42	45	68	95	21,64	32,14	39,82	35,57
2,3,4	4	25	68	115	12,02	17,86	26,88	21,46
1,2,3,4	26	26	69	114	12,44	18,57	27,37	22,13

Tabulka 60: Ideální nastavení metody ANFIS pro všechny možné kombinace elektrod u záznamu a12. Stanovené počty TP, FP a FN na základě detekce pozic R kmitů v extrahovaných fEKG signálech pomocí hybridní metody ICA-ANFIS-WT vzhledem k referenčním pozicím R kmitů a výpočet parametrů ACC, SE, PPV a F1.

Kombinace elektrod	Tvar funkcí příslušnosti	Počet epoch	Počet funkcí příslušnosti	TP	FP	FN	ACC (%)	SE (%)	PPV (%)	F1 (%)
1,2	trapmf	2	10	55	60	83	27,78	39,86	47,83	43,48
1,3	gbellmf	2	10	71	17	67	45,81	51,45	80,68	62,83
1,4	trimf	10	30	83	51	55	43,92	60,15	61,94	61,03
2,3	trimf	2	20	68	16	70	44,16	49,28	80,95	61,26
2,4	gbellmf	4	20	70	58	68	35,71	50,73	54,69	52,63
3,4	gaussmf	10	30	68	7	70	46,90	49,28	90,67	63,85
1,2,3	trapmf	2	10	66	64	72	32,67	47,83	50,77	49,25
1,2,4	gaussmf	8	10	24	63	114	11,94	17,39	27,59	21,33
1,3,4	gbellmf	2	10	57	69	81	27,54	41,30	45,24	43,18
2,3,4	gbellmf	4	20	41	71	97	19,62	29,71	36,61	32,80
1,2,3,4	gbellmf	2	20	56	68	82	27,18	40,58	45,16	42,75

Tabulka 61: Ideální nastavení řádu filtru algoritmu RLS pro všechny možné kombinace elektrod u záznamu a12. Stanovené počty TP, FP a FN na základě detekce pozic R kmitů v extrahovaných fEKG signálech pomocí hybridní metody ICA-RLS-WT vzhledem k referenčním pozicím R kmitů a výpočet parametrů ACC, SE, PPV a F1.

Kombinace elektrod	Řád filtru	TP	FP	FN	ACC (%)	SE (%)	PPV (%)	F1 (%)
1,2	4	51	41	87	28,49	36,96	55,44	44,35
1,3	2	78	14	60	51,32	56,52	84,78	67,83
1,4	98	102	27	36	61,82	73,91	79,07	76,40
2,3	4	78	30	60	46,43	56,52	72,22	63,42
2,4	2	98	27	40	59,39	71,01	78,40	74,53
3,4	14	76	17	62	49,03	55,07	81,72	65,80
1,2,3	56	103	9	35	70,07	74,64	91,96	82,40
1,2,4	2	28	60	110	14,14	20,29	31,82	24,78
1,3,4	14	130	2	8	92,86	94,20	98,49	96,30
2,3,4	78	127	4	11	89,44	92,03	96,95	94,42
1,2,3,4	14	130	2	8	92,86	94,20	98,49	96,30

Tabulka 62: Ideální nastavení metody ANFIS pro všechny možné kombinace elektrod u záznamu a13. Stanovené počty TP, FP a FN na základě detekce pozic R kmitů v extrahovaných fEKG signálech pomocí hybridní metody ICA-ANFIS-WT vzhledem k referenčním pozicím R kmitů a výpočet parametrů ACC, SE, PPV a F1.

Kombinace elektrod	Tvar funkcí příslušnosti	Počet epoch	Počet funkcí příslušnosti	TP	FP	FN	ACC (%)	SE (%)	PPV (%)	F1 (%)
1,2	trapmf	10	10	19	36	107	11,73	15,08	34,55	20,99
1,3	trimf	2	10	26	61	100	13,90	20,64	29,89	24,41
1,4	trimf	2	10	38	60	88	20,43	30,16	38,78	33,93
2,3	trimf	2	30	36	60	90	19,36	28,57	37,50	32,43
2,4	trapmf	10	10	27	55	99	14,92	21,43	32,93	25,96
3,4	trapmf	2	10	29	59	97	15,68	23,02	32,96	27,10
1,2,3	trapmf	4	10	48	57	78	26,23	38,10	45,71	41,56
1,2,4	trimf	2	30	98	29	28	63,23	77,78	77,17	77,47
1,3,4	gbellmf	10	30	25	57	101	13,66	19,84	30,49	24,04
2,3,4	trapmf	6	10	19	61	107	10,16	15,08	23,75	18,45
1,2,3,4	trimf	6	20	20	54	106	11,11	15,87	27,03	20,00

Tabulka 63: Ideální nastavení řádu filtru algoritmu RLS pro všechny možné kombinace elektrod u záznamu a13. Stanovené počty TP, FP a FN na základě detekce pozic R kmitů v extrahovaných fEKG signálech pomocí hybridní metody ICA-RLS-WT vzhledem k referenčním pozicím R kmitů a výpočet parametrů ACC, SE, PPV a F1.

Kombinace elektrod	Řád filtru	TP	FP	FN	ACC (%)	SE (%)	PPV (%)	F1 (%)
1,2	76	33	59	93	17,84	26,19	35,87	30,28
1,3	52	110	17	16	76,92	87,30	86,61	86,96
1,4	96	111	14	15	79,29	88,10	88,80	88,45
2,3	42	95	15	31	67,38	75,40	86,36	80,51
2,4	36	107	13	19	76,98	84,92	89,17	86,99
3,4	42	87	23	39	58,39	69,05	79,09	73,73
1,2,3	4	29	62	97	15,43	23,02	31,87	26,73
1,2,4	2	60	62	66	31,92	47,62	49,18	48,39
1,3,4	68	79	35	47	49,07	62,70	69,30	65,83
2,3,4	48	25	43	101	14,79	19,84	36,77	25,77
1,2,3,4	46	28	34	98	17,50	22,22	45,16	29,79

Tabulka 64: Ideální nastavení metody ANFIS pro všechny možné kombinace elektrod u záznamu a14. Stanovené počty TP, FP a FN na základě detekce pozic R kmitů v extrahovaných fEKG signálech pomocí hybridní metody ICA-ANFIS-WT vzhledem k referenčním pozicím R kmitů a výpočet parametrů ACC, SE, PPV a F1.

Kombinace elektrod	Tvar funkcí příslušnosti	Počet epoch	Počet funkcí příslušnosti	TP	FP	FN	ACC (%)	SE (%)	PPV (%)	F1 (%)
1,2	trimf	2	30	27	61	96	14,67	21,95	30,68	25,59
1,3	gaussmf	2	10	63	42	60	38,18	51,22	60,00	55,26
1,4	gaussmf	4	10	37	85	86	17,79	30,08	30,33	30,20
2,3	trapmf	2	30	63	37	60	39,38	51,22	63,00	56,50
2,4	gaussmf	2	10	39	86	84	18,66	31,71	31,20	31,45
3,4	trimf	6	20	60	35	63	37,98	48,78	63,16	55,05
1,2,3	trapmf	4	10	66	66	57	34,92	53,66	50,00	51,77
1,2,4	gbellmf	2	10	51	69	72	26,56	41,46	42,50	41,98
1,3,4	trapmf	2	10	58	75	65	29,29	47,15	43,61	45,31
2,3,4	trapmf	2	10	57	84	66	27,54	46,34	40,43	43,18
1,2,3,4	gaussmf	2	10	58	77	65	29,00	47,15	42,96	44,96

Tabulka 65: Ideální nastavení řádu filtru algoritmu RLS pro všechny možné kombinace elektrod u záznamu a14. Stanovené počty TP, FP a FN na základě detekce pozic R kmitů v extrahovaných fEKG signálech pomocí hybridní metody ICA-RLS-WT vzhledem k referenčním pozicím R kmitů a výpočet parametrů ACC, SE, PPV a F1.

Kombinace elektrod	Řád filtru	TP	FP	FN	ACC (%)	SE (%)	PPV (%)	F1 (%)
1,2	48	84	13	39	61,77	68,29	86,60	76,36
1,3	2	66	45	57	39,29	53,66	59,46	56,41
1,4	50	110	15	13	79,71	89,43	88,00	88,71
2,3	2	56	61	67	30,44	45,53	47,86	46,67
2,4	52	102	24	21	69,39	82,93	80,95	81,93
3,4	10	59	41	64	35,98	47,97	59,00	52,92
1,2,3	20	96	16	27	69,07	78,05	85,71	81,70
1,2,4	52	49	88	74	23,22	39,84	35,77	37,69
1,3,4	10	117	12	6	86,67	95,12	90,70	92,86
2,3,4	44	111	12	12	82,22	90,24	90,24	90,24
1,2,3,4	10	116	11	7	86,57	94,31	91,34	92,80

Tabulka 66: Ideální nastavení metody ANFIS pro všechny možné kombinace elektrod u záznamu a15. Stanovené počty TP, FP a FN na základě detekce pozic R kmitů v extrahovaných fEKG signálech pomocí hybridní metody ICA-ANFIS-WT vzhledem k referenčním pozicím R kmitů a výpočet parametrů ACC, SE, PPV a F1.

Kombinace elektrod	Tvar funkcí příslušnosti	Počet epoch	Počet funkcí příslušnosti	TP	FP	FN	ACC (%)	SE (%)	PPV (%)	F1 (%)
1,2	gaussmf	4	10	132	5	2	94,96	98,51	96,35	97,42
1,3	trimf	6	30	117	14	17	79,05	87,31	89,31	88,30
1,4	gaussmf	2	10	134	0	0	100,00	100,00	100,00	100,00
2,3	trimf	2	10	110	18	24	72,37	82,09	85,94	83,97
2,4	trimf	2	20	115	22	19	73,72	85,82	83,94	84,87
3,4	trimf	4	10	131	2	3	96,32	97,76	98,50	98,13
1,2,3	trimf	2	10	111	16	23	74,00	82,84	87,40	85,06
1,2,4	gaussmf	2	10	134	0	0	100,00	100,00	100,00	100,00
1,3,4	gaussmf	6	10	134	0	0	100,00	100,00	100,00	100,00
2,3,4	gbellmf	10	10	133	1	1	98,52	99,25	99,25	99,25
1,2,3,4	gbellmf	2	20	38	36	96	22,35	28,36	51,35	36,54

Tabulka 67: Ideální nastavení řádu filtru algoritmu RLS pro všechny možné kombinace elektrod u záznamu a15. Stanovené počty TP, FP a FN na základě detekce pozic R kmitů v extrahovaných fEKG signálech pomocí hybridní metody ICA-RLS-WT vzhledem k referenčním pozicím R kmitů a výpočet parametrů ACC, SE, PPV a F1.

Kombinace elektrod	Řád filtru	TP	FP	FN	ACC (%)	SE (%)	PPV (%)	F1 (%)
1,2	96	132	6	2	94,29	98,51	95,65	97,06
1,3	26	133	4	1	96,38	99,25	97,08	98,16
1,4	94	134	0	0	100,00	100,00	100,00	100,00
2,3	2	86	37	48	50,29	64,18	69,92	66,93
2,4	2	104	32	30	62,65	77,61	76,47	77,04
3,4	2	112	15	22	75,17	83,58	88,19	85,82
1,2,3	2	99	18	35	65,13	73,88	84,62	78,88
1,2,4	100	133	1	1	98,52	99,25	99,25	99,25
1,3,4	100	133	1	1	98,52	99,25	99,25	99,25
2,3,4	90	128	11	6	88,28	95,52	92,09	93,77
1,2,3,4	38	44	56	90	23,16	32,84	44,00	37,61

Tabulka 68: Ideální nastavení metody ANFIS pro všechny možné kombinace elektrod u záznamu a16. Stanovené počty TP, FP a FN na základě detekce pozic R kmitů v extrahovaných fEKG signálech pomocí hybridní metody ICA-ANFIS-WT vzhledem k referenčním pozicím R kmitů a výpočet parametrů ACC, SE, PPV a F1.

Kombinace elektrod	Tvar funkcí příslušnosti	Počet epoch	Počet funkcí příslušnosti	TP	FP	FN	ACC (%)	SE (%)	PPV (%)	F1 (%)
1,2	gaussmf	4	10	19	69	111	9,55	14,62	21,59	17,43
1,3	gaussmf	2	10	19	71	111	9,45	14,62	21,11	17,27
1,4	gaussmf	2	10	19	71	111	9,45	14,62	21,11	17,27
2,3	gaussmf	2	10	19	71	111	9,45	14,62	21,11	17,27
2,4	trimf	2	10	20	69	110	10,05	15,39	22,47	18,27
3,4	trimf	8	30	18	62	112	9,38	13,85	22,50	17,14
1,2,3	gaussmf	2	10	18	72	112	8,91	13,85	20,00	16,36
1,2,4	gbellmf	2	10	16	59	114	8,47	12,31	21,33	15,61
1,3,4	trapmf	10	30	28	63	102	14,51	21,54	30,77	25,34
2,3,4	gaussmf	2	10	20	69	110	10,05	15,39	22,47	18,27
1,2,3,4	gbellmf	2	10	16	61	114	8,38	12,31	20,78	15,46

Tabulka 69: Ideální nastavení řádu filtru algoritmu RLS pro všechny možné kombinace elektrod u záznamu a16. Stanovené počty TP, FP a FN na základě detekce pozic R kmitů v extrahovaných fEKG signálech pomocí hybridní metody ICA-RLS-WT vzhledem k referenčním pozicím R kmitů a výpočet parametrů ACC, SE, PPV a F1.

Kombinace elektrod	Řád filtru	TP	FP	FN	ACC (%)	SE (%)	PPV (%)	F1 (%)
1,2	8	20	70	110	10,00	15,39	22,22	18,18
1,3	42	21	40	109	12,35	16,15	34,43	21,99
1,4	40	21	22	109	13,82	16,15	48,84	24,28
2,3	100	19	66	111	9,69	14,62	22,35	17,67
2,4	2	20	70	110	10,00	15,39	22,22	18,18
3,4	18	18	67	112	9,14	13,85	21,18	16,74
1,2,3	6	18	72	112	8,91	13,85	20,00	16,36
1,2,4	12	19	71	111	9,45	14,62	21,11	17,27
1,3,4	2	22	69	108	11,06	16,92	24,18	19,91
2,3,4	60	19	68	111	9,60	14,62	21,84	17,51
1,2,3,4	12	18	71	112	8,96	13,85	20,23	16,44

Tabulka 70: Ideální nastavení metody ANFIS pro všechny možné kombinace elektrod u záznamu a17. Stanovené počty TP, FP a FN na základě detekce pozic R kmitů v extrahovaných fEKG signálech pomocí hybridní metody ICA-ANFIS-WT vzhledem k referenčním pozicím R kmitů a výpočet parametrů ACC, SE, PPV a F1.

Kombinace elektrod	Tvar funkcí příslušnosti	Počet epoch	Počet funkcí příslušnosti	TP	FP	FN	ACC (%)	SE (%)	PPV (%)	F1 (%)
1,2	gaussmf	2	20	120	2	12	89,55	90,91	98,36	94,49
1,3	trimf	4	20	127	2	5	94,78	96,21	98,45	97,32
1,4	gaussmf	2	10	131	1	1	98,50	99,24	99,24	99,24
2,3	trapmf	2	10	48	16	84	32,43	36,36	75,00	48,98
2,4	trapmf	2	30	109	30	23	67,28	82,58	78,42	80,44
3,4	trapmf	8	10	129	2	3	96,27	97,73	98,47	98,10
1,2,3	trapmf	4	30	127	6	5	92,03	96,21	95,49	95,85
1,2,4	trimf	4	30	132	0	0	100,00	100,00	100,00	100,00
1,3,4	gbellmf	10	10	54	69	78	26,87	40,91	43,90	42,35
2,3,4	trapmf	2	30	127	1	5	95,49	96,21	99,22	97,69
1,2,3,4	gbellmf	6	10	132	0	0	100,00	100,00	100,00	100,00

Tabulka 71: Ideální nastavení řádu filtru algoritmu RLS pro všechny možné kombinace elektrod u záznamu a17. Stanovené počty TP, FP a FN na základě detekce pozic R kmitů v extrahovaných fEKG signálech pomocí hybridní metody ICA-RLS-WT vzhledem k referenčním pozicím R kmitů a výpočet parametrů ACC, SE, PPV a F1.

Kombinace elektrod	Řád filtru	TP	FP	FN	ACC (%)	SE (%)	PPV (%)	F1 (%)
1,2	2	125	1	7	93,99	94,70	99,21	96,90
1,3	36	131	1	1	98,50	99,24	99,24	99,24
1,4	100	132	0	0	100,00	100,00	100,00	100,00
2,3	2	55	19	77	36,42	41,67	74,32	53,40
2,4	4	94	38	38	55,29	71,21	71,21	71,21
3,4	100	132	0	0	100,00	100,00	100,00	100,00
1,2,3	48	131	8	1	93,57	99,24	94,25	96,68
1,2,4	100	132	0	0	100,00	100,00	100,00	100,00
1,3,4	6	36	50	96	19,78	27,27	41,86	33,03
2,3,4	2	131	2	1	97,76	99,24	98,50	98,87
1,2,3,4	100	132	0	0	100,00	100,00	100,00	100,00

Tabulka 72: Ideální nastavení metody ANFIS pro všechny možné kombinace elektrod u záznamu a18. Stanovené počty TP, FP a FN na základě detekce pozic R kmitů v extrahovaných fEKG signálech pomocí hybridní metody ICA-ANFIS-WT vzhledem k referenčním pozicím R kmitů a výpočet parametrů ACC, SE, PPV a F1.

Kombinace elektrod	Tvar funkcí příslušnosti	Počet epoch	Počet funkcí příslušnosti	TP	FP	FN	ACC (%)	SE (%)	PPV (%)	F1 (%)
1,2	gaussmf	2	10	20	90	130	8,33	13,33	18,18	15,39
1,3	trimf	2	10	23	87	127	9,71	15,33	20,91	17,69
1,4	gaussmf	2	10	7	48	143	3,54	4,67	12,73	6,83
2,3	trapmf	2	10	19	72	131	8,56	12,67	20,88	15,77
2,4	trimf	6	20	17	83	133	7,30	11,33	17,00	13,60
3,4	trapmf	2	10	23	81	127	9,96	15,33	22,12	18,11
1,2,3	gaussmf	10	10	20	90	130	8,33	13,33	18,18	15,39
1,2,4	trapmf	10	10	20	90	130	8,33	13,33	18,18	15,39
1,3,4	trapmf	4	30	25	89	125	10,46	16,67	21,93	18,94
2,3,4	gaussmf	8	20	24	88	126	10,08	16,00	21,43	18,32
1,2,3,4	gaussmf	8	10	19	91	131	7,88	12,67	17,27	14,62

Tabulka 73: Ideální nastavení řádu filtru algoritmu RLS pro všechny možné kombinace elektrod u záznamu a18. Stanovené počty TP, FP a FN na základě detekce pozic R kmitů v extrahovaných fEKG signálech pomocí hybridní metody ICA-RLS-WT vzhledem k referenčním pozicím R kmitů a výpočet parametrů ACC, SE, PPV a F1.

Kombinace elektrod	Řád filtru	TP	FP	FN	ACC (%)	SE (%)	PPV (%)	F1 (%)
1,2	100	21	89	129	8,79	14,00	19,09	16,15
1,3	8	23	87	127	9,71	15,33	20,91	17,69
1,4	10	18	74	132	8,04	12,00	19,57	14,88
2,3	6	22	76	128	9,74	14,67	22,45	17,74
2,4	8	19	61	131	9,01	12,67	23,75	16,52
3,4	6	24	91	126	9,96	16,00	20,87	18,11
1,2,3	90	18	73	132	8,07	12,00	19,78	14,94
1,2,4	30	17	54	133	8,33	11,33	23,94	15,39
1,3,4	68	27	89	123	11,30	18,00	23,28	20,30
2,3,4	72	24	83	126	10,30	16,00	22,43	18,68
1,2,3,4	34	18	56	132	8,74	12,00	24,32	16,07

Tabulka 74: Ideální nastavení metody ANFIS pro všechny možné kombinace elektrod u záznamu a19. Stanovené počty TP, FP a FN na základě detekce pozic R kmitů v extrahovaných fEKG signálech pomocí hybridní metody ICA-ANFIS-WT vzhledem k referenčním pozicím R kmitů a výpočet parametrů ACC, SE, PPV a F1.

Kombinace elektrod	Tvar funkcí příslušnosti	Počet epoch	Počet funkcí příslušnosti	TP	FP	FN	ACC (%)	SE (%)	PPV (%)	F1 (%)
1,2	gaussmf	2	10	59	58	68	31,89	46,46	50,43	48,36
1,3	trimf	2	10	72	42	55	42,60	56,69	63,16	59,75
1,4	gbellmf	10	20	69	34	58	42,86	54,33	66,99	60,00
2,3	trimf	2	10	76	58	51	41,08	59,84	56,72	58,24
2,4	trapmf	4	10	73	49	54	41,48	57,48	59,84	58,64
3,4	trimf	2	10	55	55	72	30,22	43,31	50,00	46,41
1,2,3	trimf	2	10	70	57	57	38,04	55,12	55,12	55,12
1,2,4	trimf	2	30	100	26	27	65,36	78,74	79,37	79,05
1,3,4	gaussmf	2	30	69	43	58	40,59	54,33	61,61	57,74
2,3,4	trimf	2	30	99	27	28	64,29	77,95	78,57	78,26
1,2,3,4	trimf	10	30	22	32	105	13,84	17,32	40,74	24,31

Tabulka 75: Ideální nastavení řádu filtru algoritmu RLS pro všechny možné kombinace elektrod u záznamu a19. Stanovené počty TP, FP a FN na základě detekce pozic R kmitů v extrahovaných fEKG signálech pomocí hybridní metody ICA-RLS-WT vzhledem k referenčním pozicím R kmitů a výpočet parametrů ACC, SE, PPV a F1.

Kombinace elektrod	Řád filtru	TP	FP	FN	ACC (%)	SE (%)	PPV (%)	F1 (%)
1,2	16	71	57	56	38,59	55,91	55,47	55,69
1,3	84	111	12	16	79,86	87,40	90,24	88,80
1,4	36	113	9	14	83,09	88,98	92,62	90,76
2,3	74	122	8	5	90,37	96,06	93,85	94,94
2,4	60	109	14	18	77,31	85,83	88,62	87,20
3,4	42	115	4	12	87,79	90,55	96,64	93,50
1,2,3	2	59	55	68	32,42	46,46	51,75	48,96
1,2,4	2	79	57	48	42,94	62,21	58,09	60,08
1,3,4	2	67	32	60	42,14	52,76	67,68	59,29
2,3,4	2	79	56	48	43,17	62,21	58,52	60,31
1,2,3,4	4	32	32	95	20,13	25,20	50,00	33,51

Tabulka 76: Ideální nastavení metody ANFIS pro všechny možné kombinace elektrod u záznamu a20. Stanovené počty TP, FP a FN na základě detekce pozic R kmitů v extrahovaných fEKG signálech pomocí hybridní metody ICA-ANFIS-WT vzhledem k referenčním pozicím R kmitů a výpočet parametrů ACC, SE, PPV a F1.

Kombinace elektrod	Tvar funkcí příslušnosti	Počet epoch	Počet funkcí příslušnosti	TP	FP	FN	ACC (%)	SE (%)	PPV (%)	F1 (%)
1,2	gaussmf	2	20	27	66	104	13,71	20,61	29,03	24,11
1,3	trimf	2	30	43	64	88	22,05	32,82	40,19	36,13
1,4	trimf	2	10	56	60	75	29,32	42,75	48,28	45,34
2,3	trimf	2	10	51	64	80	26,15	38,93	44,35	41,46
2,4	trimf	2	10	47	62	84	24,35	35,88	43,12	39,17
3,4	trapmf	6	10	51	58	80	26,98	38,93	46,79	42,50
1,2,3	trimf	6	20	62	65	69	31,63	47,33	48,82	48,06
1,2,4	gaussmf	4	10	16	22	115	10,46	12,21	42,11	18,94
1,3,4	gaussmf	10	30	35	62	96	18,14	26,72	36,08	30,70
2,3,4	gaussmf	10	30	20	53	111	10,87	15,27	27,40	19,61
1,2,3,4	gbellmf	2	30	15	22	116	9,80	11,45	40,54	17,86

Tabulka 77: Ideální nastavení řádu filtru algoritmu RLS pro všechny možné kombinace elektrod u záznamu a20. Stanovené počty TP, FP a FN na základě detekce pozic R kmitů v extrahovaných fEKG signálech pomocí hybridní metody ICA-RLS-WT vzhledem k referenčním pozicím R kmitů a výpočet parametrů ACC, SE, PPV a F1.

Kombinace elektrod	Řád filtru	TP	FP	FN	ACC (%)	SE (%)	PPV (%)	F1 (%)
1,2	100	82	26	49	52,23	62,60	75,93	68,62
1,3	40	68	5	63	50,00	51,91	93,15	66,67
1,4	96	70	2	61	52,63	53,44	97,22	68,97
2,3	94	92	14	39	63,45	70,23	86,79	77,64
2,4	88	83	21	48	54,61	63,36	79,81	70,64
3,4	84	73	23	58	47,40	55,73	76,04	64,32
1,2,3	2	52	62	79	26,94	39,70	45,61	42,45
1,2,4	28	23	36	108	13,77	17,56	38,98	24,21
1,3,4	96	69	32	62	42,33	52,67	68,32	59,48
2,3,4	8	61	46	70	34,46	46,57	57,01	51,26
1,2,3,4	20	24	41	107	13,95	18,32	36,92	24,49

Tabulka 78: Ideální nastavení metody ANFIS pro všechny možné kombinace elektrod u záznamu a21. Stanovené počty TP, FP a FN na základě detekce pozic R kmitů v extrahovaných fEKG signálech pomocí hybridní metody ICA-ANFIS-WT vzhledem k referenčním pozicím R kmitů a výpočet parametrů ACC, SE, PPV a F1.

Kombinace elektrod	Tvar funkcí příslušnosti	Počet epoch	Počet funkcí příslušnosti	TP	FP	FN	ACC (%)	SE (%)	PPV (%)	F1 (%)
1,2	gaussmf	6	10	33	69	112	15,42	22,76	32,35	26,72
1,3	gbellmf	2	20	25	66	120	11,85	17,24	27,47	21,19
1,4	gbellmf	6	20	37	68	108	17,37	25,52	35,24	29,60
2,3	gbellmf	6	20	30	62	115	14,49	20,69	32,61	25,32
2,4	gbellmf	2	20	106	18	39	65,03	73,10	85,48	78,81
3,4	trimf	2	10	32	70	113	14,88	22,07	31,37	25,91
1,2,3	trapmf	10	30	36	69	109	16,82	24,83	34,29	28,80
1,2,4	trapmf	10	30	88	46	57	46,07	60,69	65,67	63,08
1,3,4	gaussmf	2	30	109	14	36	68,55	75,17	88,62	81,34
2,3,4	gaussmf	2	20	103	22	42	61,68	71,03	82,40	76,30
1,2,3,4	trapmf	2	20	77	65	68	36,67	53,10	54,23	53,66

Tabulka 79: Ideální nastavení řádu filtru algoritmu RLS pro všechny možné kombinace elektrod u záznamu a21. Stanovené počty TP, FP a FN na základě detekce pozic R kmitů v extrahovaných fEKG signálech pomocí hybridní metody ICA-RLS-WT vzhledem k referenčním pozicím R kmitů a výpočet parametrů ACC, SE, PPV a F1.

Kombinace elektrod	Řád filtru	TP	FP	FN	ACC (%)	SE (%)	PPV (%)	F1 (%)
1,2	100	26	64	119	12,44	17,93	28,89	22,13
1,3	100	23	68	122	10,80	15,86	25,28	19,49
1,4	18	28	63	117	13,46	19,31	30,77	23,73
2,3	20	27	73	118	12,39	18,62	27,00	22,04
2,4	26	104	21	41	62,65	71,72	83,20	77,04
3,4	6	24	64	121	11,48	16,55	27,27	20,60
1,2,3	8	28	75	117	12,73	19,31	27,18	22,58
1,2,4	24	79	48	66	40,93	54,48	62,21	58,09
1,3,4	60	108	21	37	65,06	74,48	83,72	78,83
2,3,4	4	108	20	37	65,46	74,48	84,38	79,12
1,2,3,4	98	70	46	75	36,65	48,28	60,35	53,64

Tabulka 80: Ideální nastavení metody ANFIS pro všechny možné kombinace elektrod u záznamu a22. Stanovené počty TP, FP a FN na základě detekce pozic R kmitů v extrahovaných fEKG signálech pomocí hybridní metody ICA-ANFIS-WT vzhledem k referenčním pozicím R kmitů a výpočet parametrů ACC, SE, PPV a F1.

Kombinace elektrod	Tvar funkcí příslušnosti	Počet epoch	Počet funkcí příslušnosti	TP	FP	FN	ACC (%)	SE (%)	PPV (%)	F1 (%)
1,2	gbellmf	2	30	56	59	70	30,27	44,44	48,70	46,47
1,3	trapmf	2	20	118	7	8	88,72	93,65	94,40	94,02
1,4	gaussmf	2	10	126	0	0	100,00	100,00	100,00	100,00
2,3	gaussmf	4	10	121	12	5	87,68	96,03	90,98	93,44
2,4	trapmf	4	20	21	59	105	11,35	16,67	26,25	20,39
3,4	trapmf	4	10	118	18	8	81,94	93,65	86,77	90,08
1,2,3	trapmf	2	10	112	15	14	79,43	88,89	88,19	88,54
1,2,4	gaussmf	6	10	126	1	0	99,21	100,00	99,21	99,61
1,3,4	gaussmf	2	10	126	0	0	100,00	100,00	100,00	100,00
2,3,4	gaussmf	2	10	21	61	105	11,23	16,67	25,61	20,19
1,2,3,4	gaussmf	2	10	126	0	0	100,00	100,00	100,00	100,00

Tabulka 81: Ideální nastavení řádu filtru algoritmu RLS pro všechny možné kombinace elektrod u záznamu a22. Stanovené počty TP, FP a FN na základě detekce pozic R kmitů v extrahovaných fEKG signálech pomocí hybridní metody ICA-RLS-WT vzhledem k referenčním pozicím R kmitů a výpočet parametrů ACC, SE, PPV a F1.

Kombinace elektrod	Řád filtru	TP	FP	FN	ACC (%)	SE (%)	PPV (%)	F1 (%)
1,2	100	22	58	104	11,96	17,46	27,50	21,36
1,3	44	120	1	6	94,49	95,24	99,17	97,17
1,4	32	126	0	0	100,00	100,00	100,00	100,00
2,3	14	119	4	7	91,54	94,44	96,75	95,58
2,4	12	66	51	60	37,29	52,38	56,41	54,32
3,4	60	126	1	0	99,21	100,00	99,21	99,61
1,2,3	10	119	9	7	88,15	94,44	92,97	93,70
1,2,4	50	126	0	0	100,00	100,00	100,00	100,00
1,3,4	12	126	0	0	100,00	100,00	100,00	100,00
2,3,4	8	52	58	74	28,26	41,27	47,27	44,07
1,2,3,4	12	126	0	0	100,00	100,00	100,00	100,00

Tabulka 82: Ideální nastavení metody ANFIS pro všechny možné kombinace elektrod u záznamu a23. Stanovené počty TP, FP a FN na základě detekce pozic R kmitů v extrahovaných fEKG signálech pomocí hybridní metody ICA-ANFIS-WT vzhledem k referenčním pozicím R kmitů a výpočet parametrů ACC, SE, PPV a F1.

Kombinace elektrod	Tvar funkcí příslušnosti	Počet epoch	Počet funkcí příslušnosti	TP	FP	FN	ACC (%)	SE (%)	PPV (%)	F1 (%)
1,2	gbellmf	6	20	40	91	86	18,43	31,75	30,53	31,13
1,3	trapmf	2	30	47	54	79	26,11	37,30	46,54	41,41
1,4	trimf	2	20	48	54	78	26,67	38,10	47,06	42,11
2,3	gaussmf	6	30	75	54	51	41,67	59,52	58,14	58,82
2,4	trapmf	6	10	35	48	91	20,12	27,78	42,17	33,49
3,4	trimf	2	10	44	57	82	24,04	34,92	43,56	38,77
1,2,3	trapmf	4	10	66	62	60	35,11	52,38	51,56	51,97
1,2,4	trimf	2	30	106	24	20	70,67	84,13	81,54	82,81
1,3,4	trimf	2	10	88	43	38	52,07	69,84	67,18	68,48
2,3,4	trimf	2	30	107	23	19	71,81	84,92	82,31	83,59
1,2,3,4	trimf	2	30	100	31	26	63,69	79,37	76,34	77,82

Tabulka 83: Ideální nastavení řádu filtru algoritmu RLS pro všechny možné kombinace elektrod u záznamu a23. Stanovené počty TP, FP a FN na základě detekce pozic R kmitů v extrahovaných fEKG signálech pomocí hybridní metody ICA-RLS-WT vzhledem k referenčním pozicím R kmitů a výpočet parametrů ACC, SE, PPV a F1.

Kombinace elektrod	Řád filtru	TP	FP	FN	ACC (%)	SE (%)	PPV (%)	F1 (%)
1,2	98	33	48	93	18,97	26,19	40,74	31,88
1,3	36	104	16	22	73,24	82,54	86,67	84,55
1,4	92	112	21	14	76,19	88,89	84,21	86,49
2,3	96	40	56	86	21,98	31,75	41,67	36,04
2,4	58	95	36	31	58,64	75,40	72,52	73,93
3,4	78	89	31	37	56,69	70,64	74,17	72,36
1,2,3	2	62	58	64	33,70	49,21	51,67	50,41
1,2,4	2	76	60	50	40,86	60,32	55,88	58,02
1,3,4	2	40	58	86	21,74	31,75	40,82	35,71
2,3,4	2	77	61	49	41,18	61,11	55,80	58,33
1,2,3,4	2	77	60	49	41,40	61,11	56,20	58,56

Tabulka 84: Ideální nastavení metody ANFIS pro všechny možné kombinace elektrod u záznamu a24. Stanovené počty TP, FP a FN na základě detekce pozic R kmitů v extrahovaných fEKG signálech pomocí hybridní metody ICA-ANFIS-WT vzhledem k referenčním pozicím R kmitů a výpočet parametrů ACC, SE, PPV a F1.

Kombinace elektrod	Tvar funkcí příslušnosti	Počet epoch	Počet funkcí příslušnosti	TP	FP	FN	ACC (%)	SE (%)	PPV (%)	F1 (%)
1,2	trapmf	8	20	18	66	105	9,52	14,63	21,43	17,39
1,3	gaussmf	4	20	62	55	61	34,83	50,41	52,99	51,67
1,4	trimf	4	30	76	48	47	44,44	61,79	61,29	61,54
2,3	trimf	4	20	36	59	87	19,78	29,27	37,90	33,03
2,4	gbellmf	6	10	64	57	59	35,56	52,03	52,89	52,46
3,4	trapmf	2	30	70	54	53	39,55	56,91	56,45	56,68
1,2,3	trimf	2	10	65	55	58	36,52	52,85	54,17	53,50
1,2,4	trimf	2	10	93	28	30	61,59	75,61	76,86	76,23
1,3,4	gaussmf	2	10	47	56	76	26,26	38,21	45,63	41,59
2,3,4	trimf	2	30	95	28	28	62,91	77,24	77,24	77,24
1,2,3,4	gbellmf	8	30	49	47	74	28,82	39,84	51,04	44,75

Tabulka 85: Ideální nastavení řádu filtru algoritmu RLS pro všechny možné kombinace elektrod u záznamu a24. Stanovené počty TP, FP a FN na základě detekce pozic R kmitů v extrahovaných fEKG signálech pomocí hybridní metody ICA-RLS-WT vzhledem k referenčním pozicím R kmitů a výpočet parametrů ACC, SE, PPV a F1.


Kombinace elektrod	Řád filtru	TP	FP	FN	ACC (%)	SE (%)	PPV (%)	F1 (%)
1,2	86	17	39	106	10,49	13,82	30,36	18,99
1,3	50	117	3	6	92,86	95,12	97,50	96,30
1,4	48	114	5	9	89,06	92,68	95,80	94,22
2,3	82	106	21	17	73,61	86,18	83,47	84,80
2,4	80	101	25	22	68,24	82,11	80,16	81,12
3,4	66	91	12	32	67,41	73,98	88,35	80,53
1,2,3	6	48	63	75	25,81	39,02	43,24	41,03
1,2,4	2	70	61	53	38,04	56,91	53,44	55,12
1,3,4	22	35	47	88	20,59	28,46	42,68	34,15
2,3,4	2	72	59	51	39,56	58,54	54,96	56,69
1,2,3,4	72	97	20	26	67,83	78,86	82,91	80,83

Tabulka 86: Ideální nastavení metody ANFIS pro všechny možné kombinace elektrod u záznamu a25. Stanovené počty TP, FP a FN na základě detekce pozic R kmitů v extrahovaných fEKG signálech pomocí hybridní metody ICA-ANFIS-WT vzhledem k referenčním pozicím R kmitů a výpočet parametrů ACC, SE, PPV a F1.


Kombinace elektrod	Tvar funkcí příslušnosti	Počet epoch	Počet funkcí příslušnosti	TP	FP	FN	ACC (%)	SE (%)	PPV (%)	F1 (%)
1,2	trimf	2	10	41	62	84	21,93	32,80	39,81	35,97
1,3	trimf	2	10	33	61	92	17,74	26,40	35,11	30,14
1,4	trimf	2	10	44	55	81	24,44	35,20	44,44	39,29
2,3	trimf	2	10	47	61	78	25,27	37,60	43,52	40,34
2,4	trimf	2	10	48	59	77	26,09	38,40	44,86	41,38
3,4	trapmf	6	20	33	42	92	19,76	26,40	44,00	33,00
1,2,3	gbellmf	6	20	41	59	84	22,28	32,80	41,00	36,44
1,2,4	trimf	2	10	98	29	27	63,64	78,40	77,17	77,78
1,3,4	trimf	6	30	59	36	66	36,65	47,20	62,11	53,64
2,3,4	trimf	2	20	101	29	24	65,58	80,80	77,69	79,22
1,2,3,4	trimf	2	20	98	28	27	64,05	78,40	77,78	78,09

Tabulka 87: Ideální nastavení řádu filtru algoritmu RLS pro všechny možné kombinace elektrod u záznamu a25. Stanovené počty TP, FP a FN na základě detekce pozic R kmitů v extrahovaných fEKG signálech pomocí hybridní metody ICA-RLS-WT vzhledem k referenčním pozicím R kmitů a výpočet parametrů ACC, SE, PPV a F1.

Kombinace elektrod	Řád filtru	TP	FP	FN	ACC (%)	SE (%)	PPV (%)	F1 (%)
1,2	52	81	33	44	51,27	64,80	71,05	67,78
1,3	70	98	17	27	69,01	78,40	85,22	81,67
1,4	86	90	18	35	62,94	72,00	83,33	77,25
2,3	94	117	10	8	86,67	93,60	92,13	92,86
2,4	86	111	15	14	79,29	88,80	88,10	88,45
3,4	34	62	15	63	44,29	49,60	80,52	61,39
1,2,3	4	34	56	91	18,79	27,20	37,78	31,63
1,2,4	2	69	63	56	36,70	55,20	52,27	53,70
1,3,4	2	24	52	101	13,56	19,20	31,58	23,88
2,3,4	2	70	62	55	37,43	56,00	53,03	54,48
1,2,3,4	2	69	62	56	36,90	55,20	52,67	53,91




(a) Srovnání referenční a odhadnuté křivky fHR pomocí hybridní metody ICA-ANFIS-WT.




(b) Srovnání referenční a odhadnuté křivky fHR pomocí hybridní metody ICA-RLS-WT.

Obrázek 59: Srovnání odhadnutých a referenčních křivek fHR ze záznamu a01 pomocí Bland-Altmanova grafu.




(a) Srovnání referenční a odhadnuté křivky fHR pomocí hybridní metody ICA-ANFIS-WT.

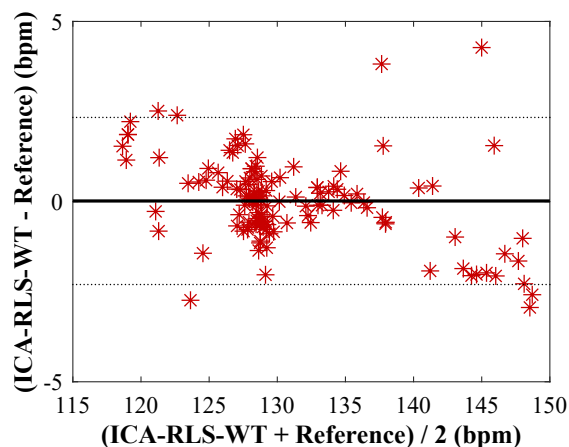


(b) Srovnání referenční a odhadnuté křivky fHR pomocí hybridní metody ICA-RLS-WT.

Obrázek 60: Srovnání odhadnutých a referenčních křivek fHR ze záznamu a03 pomocí Bland-Altmanova grafu.




(a) Srovnání referenční a odhadnuté křivky fHR pomocí hybridní metody ICA-ANFIS-WT.




(b) Srovnání referenční a odhadnuté křivky fHR pomocí hybridní metody ICA-RLS-WT.

Obrázek 61: Srovnání odhadnutých a referenčních křivek fHR ze záznamu a04 pomocí Bland-Altmanova grafu.




(a) Srovnání referenční a odhadnuté křivky fHR pomocí hybridní metody ICA-ANFIS-WT.




(b) Srovnání referenční a odhadnuté křivky fHR pomocí hybridní metody ICA-RLS-WT.

Obrázek 62: Srovnání odhadnutých a referenčních křivek fHR ze záznamu a06 pomocí Bland-Altmanova grafu.




(a) Srovnání referenční a odhadnuté křivky fHR pomocí hybridní metody ICA-ANFIS-WT.




(b) Srovnání referenční a odhadnuté křivky fHR pomocí hybridní metody ICA-RLS-WT.

Obrázek 63: Srovnání odhadnutých a referenčních křivek fHR ze záznamu a07 pomocí Bland-Altmanova grafu.




(a) Srovnání referenční a odhadnuté křivky fHR pomocí hybridní metody ICA-ANFIS-WT.




(b) Srovnání referenční a odhadnuté křivky fHR pomocí hybridní metody ICA-RLS-WT.

Obrázek 64: Srovnání odhadnutých a referenčních křivek fHR ze záznamu a09 pomocí Bland-Altmanova grafu.




(a) Srovnání referenční a odhadnuté křivky fHR pomocí hybridní metody ICA-ANFIS-WT.




(b) Srovnání referenční a odhadnuté křivky fHR pomocí hybridní metody ICA-RLS-WT.

Obrázek 65: Srovnání odhadnutých a referenčních křivek fHR ze záznamu a10 pomocí Bland-Altmanova grafu.




(a) Srovnání referenční a odhadnuté křivky fHR pomocí hybridní metody ICA-ANFIS-WT.




(b) Srovnání referenční a odhadnuté křivky fHR pomocí hybridní metody ICA-RLS-WT.

Obrázek 66: Srovnání odhadnutých a referenčních křivek fHR ze záznamu a11 pomocí Bland-Altmanova grafu.




(a) Srovnání referenční a odhadnuté křivky fHR pomocí hybridní metody ICA-ANFIS-WT.




(b) Srovnání referenční a odhadnuté křivky fHR pomocí hybridní metody ICA-RLS-WT.

Obrázek 67: Srovnání odhadnutých a referenčních křivek fHR ze záznamu a12 pomocí Bland-Altmanova grafu.




(a) Srovnání referenční a odhadnuté křivky fHR pomocí hybridní metody ICA-ANFIS-WT.




(b) Srovnání referenční a odhadnuté křivky fHR pomocí hybridní metody ICA-RLS-WT.

Obrázek 68: Srovnání odhadnutých a referenčních křivek fHR ze záznamu a13 pomocí Bland-Altmanova grafu.




(a) Srovnání referenční a odhadnuté křivky fHR pomocí hybridní metody ICA-ANFIS-WT.




(b) Srovnání referenční a odhadnuté křivky fHR pomocí hybridní metody ICA-RLS-WT.

Obrázek 69: Srovnání odhadnutých a referenčních křivek fHR ze záznamu a14 pomocí Bland-Altmanova grafu.




(a) Srovnání referenční a odhadnuté křivky fHR pomocí hybridní metody ICA-ANFIS-WT.




(b) Srovnání referenční a odhadnuté křivky fHR pomocí hybridní metody ICA-RLS-WT.

Obrázek 70: Srovnání odhadnutých a referenčních křivek fHR ze záznamu a15 pomocí Bland-Altmanova grafu.




(a) Srovnání referenční a odhadnuté křivky fHR pomocí hybridní metody ICA-ANFIS-WT.




(b) Srovnání referenční a odhadnuté křivky fHR pomocí hybridní metody ICA-RLS-WT.

Obrázek 71: Srovnání odhadnutých a referenčních křivek fHR ze záznamu a16 pomocí Bland-Altmanova grafu.




(a) Srovnání referenční a odhadnuté křivky fHR pomocí hybridní metody ICA-ANFIS-WT.




(b) Srovnání referenční a odhadnuté křivky fHR pomocí hybridní metody ICA-RLS-WT.

Obrázek 72: Srovnání odhadnutých a referenčních křivek fHR ze záznamu a17 pomocí Bland-Altmanova grafu.




(a) Srovnání referenční a odhadnuté křivky fHR pomocí hybridní metody ICA-ANFIS-WT.




(b) Srovnání referenční a odhadnuté křivky fHR pomocí hybridní metody ICA-RLS-WT.

Obrázek 73: Srovnání odhadnutých a referenčních křivek fHR ze záznamu a19 pomocí Bland-Altmanova grafu.




(a) Srovnání referenční a odhadnuté křivky fHR pomocí hybridní metody ICA-ANFIS-WT.




(b) Srovnání referenční a odhadnuté křivky fHR pomocí hybridní metody ICA-RLS-WT.

Obrázek 74: Srovnání odhadnutých a referenčních křivek fHR ze záznamu a20 pomocí Bland-Altmanova grafu.




(a) Srovnání referenční a odhadnuté křivky fHR pomocí hybridní metody ICA-ANFIS-WT.




(b) Srovnání referenční a odhadnuté křivky fHR pomocí hybridní metody ICA-RLS-WT.

Obrázek 75: Srovnání odhadnutých a referenčních křivek fHR ze záznamu a21 pomocí Bland-Altmanova grafu.

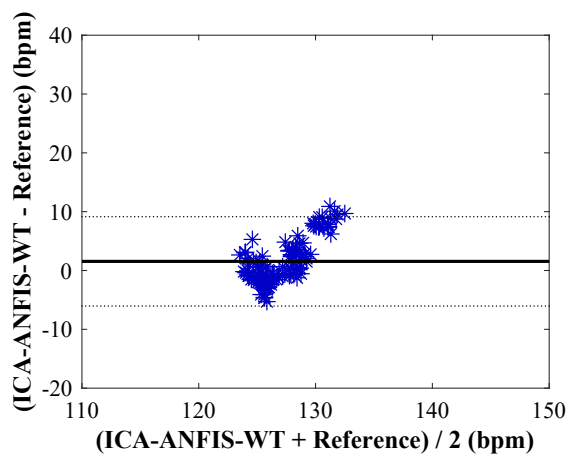


(a) Srovnání referenční a odhadnuté křivky fHR pomocí hybridní metody ICA-ANFIS-WT.




(b) Srovnání referenční a odhadnuté křivky fHR pomocí hybridní metody ICA-RLS-WT.

Obrázek 76: Srovnání odhadnutých a referenčních křivek fHR ze záznamu a22 pomocí Bland-Altmanova grafu.




(a) Srovnání referenční a odhadnuté křivky fHR pomocí hybridní metody ICA-ANFIS-WT.




(b) Srovnání referenční a odhadnuté křivky fHR pomocí hybridní metody ICA-RLS-WT.

Obrázek 77: Srovnání odhadnutých a referenčních křivek fHR ze záznamu a23 pomocí Bland-Altmanova grafu.




(a) Srovnání referenční a odhadnuté křivky fHR pomocí hybridní metody ICA-ANFIS-WT.




(b) Srovnání referenční a odhadnuté křivky fHR pomocí hybridní metody ICA-RLS-WT.

Obrázek 78: Srovnání odhadnutých a referenčních křivek fHR ze záznamu a24 pomocí Bland-Altmanova grafu.



(a) Srovnání referenční a odhadnuté křivky fHR pomocí hybridní metody ICA-ANFIS-WT.



(b) Srovnání referenční a odhadnuté křivky fHR pomocí hybridní metody ICA-RLS-WT.

Obrázek 79: Srovnání odhadnutých a referenčních křivek fHR ze záznamu a25 pomocí Bland-Altmanova grafu.

C Softwarová aplikace

Součástí této práce je vytvoření softwarové aplikace. V kapitole 6.1 byly popsány jednotlivé části této aplikace. Popis je v této kapitole doplněn o bloková schémata včetně průběhů signálů pro lepší představu o změně signálů při průchodu jednotlivými bloky. Tato softwarová aplikace byla licencována, proto není možné zveřejnit její kód jako součást příloh. Je možné dohledat tuto softwarovou aplikaci pod evidenčním číslem 006/03-05-2019_SW.