VŠB TECHNICKÁ | FAKULTA |||| UNIVERZITA | ELEKTROTECHNIKY OSTRAVA | A INFORMATIKY

# Umělé neuronové sítě jako přístup k extrakci plodového elektrokardiogramu a detekci R-kmitů

Artificial Neural Networks as Approach for Fetal Electrocardiogram Extraction and R-peak Detection

**Bc. Silvie Kovalová** 

Diplomová práce Vedoucí práce: Ing. René Jaroš, Ph.D. Ostrava, 2022 VŠB – Technická univerzita Ostrava Fakulta elektrotechniky a informatiky Katedra kybernetiky a biomedicínského inženýrství

# Zadání diplomové práce

#### **Bc. Silvie Kovalová**

Studijní program:

N0988A060001 Biomedicínské inženýrství

Téma:

Student:

Umělé neuronové sítě jako přístup k extrakci plodového elektrokardiogramu a detekci R-kmitů Artificial Neural Networks as Approach for Fetal Electrocardiogram Extraction and R-peak Detection

Jazyk vypracování:

čeština

Zásady pro vypracování:

Diplomová práce se zaměřuje na prostudování problematiky extrakce fetálního elektrokardiogramu (fEKG) pomocí metod umělých neuronových sítí (ANN). Mezi velmi často využívané metody ANN patří metody strojového učení, proto bude na ně v této práci zaměřena velká pozornost. Student provede rešerši současného stavu problematiky extrahování fEKG signálu pomocí ANN metod. Ve své práci na základě provedené literární rešerše vybere různé ANN metody k extrakci fEKG signálu a také k následné detekci R-kmitů. Dále bude náplní studenta vytvořit SW aplikaci, která bude schopna zpracovat, analyzovat a vyhodnotit extrahovaný fEKG signál. Pro realizaci bude využito vývojové prostředí MATLAB nebo LabVIEW.

Body zadání práce:

1. Prostudování problematiky zpracování neinvazivního fEKG signálu.

2. Rešerši současného stavu problematiky extrahování fEKG signálu a detekce R-kmitů pomocí ANN metod.

3. Výběr ANN metod (využití metod strojového učení) na základě provedené literární rešerše.

3. Navržení a realizace SW aplikace pro zobrazení, úpravu a analýzu extrahovaných fEKG signálů ve vývojovém prostředí MATLAB nebo LabVIEW.

4. Ověření funkcionality SW aplikace pomocí vhodné metodiky na reálných datech.

5. Analýza výsledků a provedení diskuse.

#### Seznam doporučené odborné literatury:

[1] Jagannath, D. J., Dolly, D. R. J., & Peter, J. D. (2020). Deep learning strategies for foetal electrocardiogram signal synthesis. Pattern Recognition Letters, 136, 286-292.

[2] Zhong, W., Liao, L., Guo, X., & Wang, G. (2018). A deep learning approach for fetal QRS complex detection. Physiological measurement, 39(4), 045004.

[3] Zhong, W., Liao, L., Guo, X., & Wang, G. (2019). Fetal electrocardiography extraction with residual convolutional encoder–decoder networks. Australasian physical & engineering sciences in medicine, 42(4), 1081-1089.

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

Vedoucí diplomové práce: Ing. René Jaroš, Ph.D.

Konzultant diplomové práce: Ing. Kateřina Barnová

 Datum zadání:
 01.09.2021

 Datum odevzdání:
 30.04.2022

prof. Ing. Jiří Koziorek, Ph.D. vedoucí katedry

prof. Ing. Jan Platoš, Ph.D. děkan fakulty

#### Abstrakt

Tato diplomová práce se zabývá extrakcí fetálního plodového elektrokardiogramu (fEKG) pomocí metod využívající umělé neuronové sítě (ANN). Po prostudování problematiky zpracování neinvazivního fEKG (NI-fEKG) signálu byla provedena rešerše současných metod využívající ANN pro extrakci fEKG signálu z abdominálního signálu (aEKG). Na základě provedené rešerše byly vybrány metody využívající lineární adaptivní neuron (ADALINE), adaptivní neuro-fuzzy inferenční systém (ANFIS) a rekurentní sítě (RNN) tzv. Echo state sítě. Tyto metody byly také využity v kombinaci s dopřednou vícevrstvou ANN (ANN-ADALINE, ANN-ANFIS, ANN-ESN). Testování vybraných metod bylo provedeno na reálných datech z databáze Labour dataset a Pregnancy dataset. Pro vyhodnocení extrakce a stanovení plodové srdeční frekvence (fHR) byly detekovány R-kmity pomocí dvou detektorů. První detektor byl založen na spojité vlnkové transformaci (CWT), druhý detektor byl založen na dopředné vícevrstvé ANN. Pro zhodnocení byla stanovena celková pravděpodobnost správné detekce (ACC), senzitivita (SE), pozitivní prediktivní hodnota (PPV) a jako harmonický průměr SE a PPV byl stanoven parametr F1. Funkčnost metod byla ověřena vůči referenčním anotacím. Ve srovnání s metodami ADALINE, ANFIS, ANN-ADALINE, ANN-ANFIS a ANN-ESN, dosáhla metoda ESN nejlepších výsledků. Pro data z databáze Labour dataset dosahovala metoda hodnoty ACC 78,65 %, pro data z databáze Pregnancy dataset byla hodnota ACC přes 80 %. Pro zpracování, analýzu a vyhodnocení bylo vytvořeno grafické uživatelské rozhraní (GUI) v programu MATLAB.

#### Klíčová slova

Neinvazivní plodová elektrokardiografie (NI-fEKG); Extrakce plodového elektrokardiogramu; Umělé neuronové sítě (ANN); Lineární adaptivní neuron (ADALINE); Adaptivní neuro-fuzzy inferenční systém (ANFIS); Dopředná vícevrstvá neuronová síť; Rekurentní neuronová síť (RNN); Echo state sítě (ESN); Detekce R-kmitů; Plodová srdeční frekvence (fHR).

#### Abstract

This thesis deals with the extraction of fetal electrocardiogram (fECG) through methods that use Artificial Neural Networks (ANN). After careful examination of non-invasive fECG (NI-fECG) signal processing, a search of current methods using ANN for extraction of fECG signal was performed. Based on the search, methods using a Linear Adaptive Neuron (ADALINE), an Adaptive Neuro-fuzzy Inference System (ANFIS) and a Recurrent Network (RNN), the so-called Echo State Network (ESN), were selected. These methods were also used in combination with Multilayer Feedforward ANN (ANN-ADALINE, ANN-ANFIS, ANN-ESN). Testing of the chosen methods was performed on real data from the Labour dataset and Pregnancy dataset databases. R-peaks were detected using two detectors to evaluate extraction and fetal heart rate (fHR). The first detector was based on continuous wavelet transform (CWT), the second detector was based on Multilayer Feedforward ANN. For evaluation the overall probability of correct detection (ACC), sensitivity (SE), positive predictive value (PPV) and the harmonic mean of SE and PPV (F1) were determined. The functionality of chosen methods was verified by comparison to reference anotations. In comparison to methods ADALINE, ANFIS, ANN-ADALINE, ANN-ANFIS a ANN-ESN, the ESN method achieved the best results. For data from the Labor dataset, the ACC value reached 78.65 %, for data from the Pregnancy dataset, the ACC value was over 80 %. A graphical user interface (GUI) was created for processing, analysis and evaluation in MATLAB.

#### Keywords

Non-invasive fetal electrocardiography (NI-fEKG); Fetal electrocardiogram extraction; Artificial Neural Networks (ANN); Linear Adaptive Neuron (ADALINE); Adaptive Neuro-fuzzy Inference System (ANFIS); Multilayer Feedforward Neural Networks; Recurrent Neural Networks (RNN); Echo State Network (ESN); R-peak Detection; Fetal Heart Rate (fHR).

#### Poděkování

Na tomto místě bych ráda poděkovala mému vedoucímu panu Ing. Renému Jarošovi, Ph.D za jeho pomoc, veškeré poskytnuté rady, materiály a hlavně čas, který věnoval pro vytvoření této práce. Dále bych ráda poděkovala mé konzultantce paní Ing. Kateřině Barnové za její cenné rady při zpracování zadané problematiky.

# OBSAH

Se	Seznam použitých zkratek			
Se	eznam o	obrázků	12	
Se	eznam t	tabulek	14	
Ú	Úvod15			
1	1 Vývoj kardiovaskulárního systému			
	1.1 Vývoj srdce			
1.2 Fetální krevní oběh			17	
2	Mor	nitorování srdce plodu	18	
	2.1	Hypoxémie, hypoxie a asfyxie	18	
	2.2	Současné metody monitorování srdce plodu	18	
	2.2.2	.1 Fetální fonokardiografie	19	
	2.2.2	.2 Fetální echokardiografie	20	
	2.2.3	.3 Fetální magnetokardiografie	20	
	2.2.4	.4 Kardiotokografie	21	
	2.2.	.5 Fetální elektrokardiografie	24	
3	Neir	nvazivní fetální elektrokardiografie		
	3.1	Historie a současnost		
	3.2	Rozmístění elektrod	27	
	3.2.2	.1 Abdominální rozmístění elektrod	27	
	3.2.2	.2 Kombinované rozmístění elektrod	28	
	3.3	Vlastnosti NI-fEKG	29	
4	Prob	blematika extrakce fEKG se zaměřením na neuronové sítě	31	
	4.1	Model neuronu	32	
	4.2	Jednovrstvé neuronové sítě		
	4.2.2	.1 Adaptivní lineární neuron	35	
	4.2.2	.2 Functional link ANN	35	
	4.3	Vícevrstvé neuronové sítě	36	
	4.3.3	.1 Dopředné neuronové sítě se zpětným šířením chyby		
	4.3.2	.2 Rekurentní neuronové sítě		
	4.4	Adaptivní neuro-fuzzy inferenční systém	38	
	4.5	Konvoluční neuronové sítě	39	
	4.6	Metody strojového učení	41	

	4.6.	1	Podpůrné vektory	41
	4.6.	2	Metoda k-nejbližších sousedů	42
5	Рор	ois pou	užitých metod pro extrakci fEKG	43
	5.1	Ana	lýza nezávislých komponent	43
	5.2	Dop	ředná vícevrstvá ANN	45
	5.3	ADA	LINE	48
	5.4	ANF	IS	49
	5.5	ESN		52
	5.6	Dete	ekce R-kmitů	53
	5.7	Hod	notící parametry	54
6	Náv	vrh už	ivatelského rozhraní	56
	6.1	Zob	razení a filtrace aEKG	56
	6.2	Extr	akce fEKG aplikací ANN	59
	6.3	Vyh	odnocení a vykreslení fHR	62
7	Exp	erime	ent a vyhodnocení	64
	7.1	Pou	žité databáze	64
	7.2	Vyh	odnocení pro Labour dataset	65
	7.2.	1	Zhodnocení kvality extrakce a detekce R-kmitů	65
	7.2.	2	Stanovení tepové frekvence z extrahovaných signálů	69
	7.2.	3	Vizuální zhodnocení extrahovaných signálů	72
	7.3	Vyh	odnocení pro Pregnancy dataset	74
	7.3.	1	Zhodnocení kvality extrakce a detekce R-kmitů	74
	7.3.	2	Stanovení tepové frekvence z extrahovaných signálů	77
	7.3.	3	Vizuální zhodnocení extrahovaných signálů	80
8	Disl	kuze d	dosažených výsledků	82
Za	ávěr			87
Li	teratur	a		89
Se	Seznam příloh			

# SEZNAM POUŽITÝCH ZKRATEK

1D	Jednorozměrný, jednodimenzionální
2D	Dvourozměrný, dvoudimenzionální
ACC	Celková pravděpodobnost správné detekce
ADALINE	Adaptivní lineární neuron (Adaptive Linear Neuron)
aEKG	Abdominální elektrokardiografie
ANC	Adaptivní potlačovač šumu (Adaptive Noise Cancellation)
ANFIS	Adaptivní neuro-fuzzy inferenční systém (Adaptive Neuro-Fuzzy Inference System)
ANN	Umělé neuronové sítě (Artificial Neural Networks)
AT	Technika průměrování (Averaging Technique)
AV	Atrioventrikulární
BN	Bayesovská síť (Bayesian Network, Belief Network)
BP	Algoritmus zpětného šíření chyby (Back-propagation)
bpm	Tepy za minutu (beats per minute)
BSS	Slepá separace zdrojů (Blind Source Separation)
CNN	Konvoluční neuronová síť (Convolutional Neural Network)
CNS	Centrální nervová soustava
CWT	Spojitá vlnková transformace (Continuous wavelet transform)
DE	Diferenciální evoluce (Differential Evolution)
EHG	Elektrohysterografie, elektrohysterogram
EKG	Elektrokardiografie, elektrokardiogram
EMD	Empirický režim rozkladu (Empirical Mode Decomposition)
EMG	Elektromyografie, elektromyogram
ESN	Echo State Network
F1	Harmonický průměr mezi senzitivitou a pozitivní prediktivní hodnotou
fecho	Fetální echokardiografie
fEKG	Fetální elektrokardiografie
fFKG	Fetální fonokardiografie
fHR	Fetální tepová frekvence (Fetal Heart Rate)
fHS	Fetální srdeční ozvy (Fetal Heart Sound)
FIGO	International Federation of Gynecology and Obstetrics
fQRS	Fetální QRS komplex
FIR	Filtr s konečnou impulzní odezvou (Finite Impulse Response)
FIS	Fuzzy inferenční systém (Fuzzy Inference System)
FLANN	Functional Link Artificial Neural Networks

fMKG	Fetální magnetokardiografie
FT	Filtrační technika (Filtering Technique)
HP	Horní propust
ICA	Analýza nezávislých komponent (Independent Component Analysis)
IIR	Filtr s nekonečnou impulzní odezvou (Infinite Impulse Response)
KF	Kalmanova filtrace (Kalman Filtering)
k-NN	Metoda k-nejbližších sousedů (k-Nearest Neighbor)
KTG	Kardiotokografie
LMS	Algoritmus se stochasticky gradientní adaptací (Least Mean Square)
LSTM	Long Short-Term Memory
mEKG	Mateřská elektrokardiografie
mf	Funkce příslušnosti (Membership Function)
mQRS	Mateřský QRS komplex
NB	Naive Bayes
NI-fEKG	Neinvazivní fetální elektrokardiografie
PCA	Analýza hlavních komponent (Principal Component Analysis)
PP	Pásmová propust
PPV	Pozitivní prediktivní hodnota (Positive Predictive Value)
PRD	Percent Root-Mean Square Difference
PSO	Optimalizace hejnem částic (Particle Swarm Optimization)
PZ	Pásmová zádrž
ReLU	Rectified Linear Unit
RLS	Algoritmus s rekurzivní optimální adaptací (Recursive Least Square)
RMSE	Relativní střední kvadratická chyba (Root Mean Square Error)
RNN	Rekurentní neuronová síť (Recurrent Neural Network)
S1	První srdeční ozva (Sound 1)
S2	Druhá srdeční ozva (Sound 2)
SA	Sinoatriální
SE	Senzitivita (Sensitivity)
SNR	Poměr signálu k šumu (Signal to Noise Ratio)
SQUID	Supravodivé kvantové interferenční zařízení (Superconducting Quantum Interference Device)
STAN	ST analýza
STFT	Krátkodobá Fourierova transformace (Short-Time Fourier Transform)
SVD	Rozklad singulárních hodnot (Singular Value Decomposition)
SVM	Metoda podpůrných vektorů (Support vector machines)

TDL	Tapped Delay Line
TS	Šablonové odčítání (Template Subtraction)
WT	Vlnková transformace (Wavelet Transform)
πርΑ	Analýza periodických komponent (Periodic Component Analysis)

# SEZNAM OBRÁZKŮ

Obr. 1: Vývoj srdeční kličky ze srdeční trubice [3]	16		
Obr. 2: Krevní oběh plodu [2]	17		
Obr. 3: Zařízení pro čtyřkanálovou fFKG [15]	19		
Dbr. 4: Ukázka vyšetření fECHO technikou [17] Dbr. 5: Ukázka vyšetření technikou fMKG [21]			
Obr. 7: Kardiotokogram. Nahoře je zobrazen průběh fHR, pod ním průběh děložních kontr	ntrakcí [28]. 22		
Obr. 8: Ukázka EKG signálů, shora: čtyřsvodové aEKG, fEKG ze skalpové elektrody (signá	l r08 labour		
dataset)	25		
Obr. 9: Komerčně dostupná zařízení pro záznam NI-fEKG. a) Monica AN24, Monica Novii Wi	reless Patch		
System, MERIDIAN 110 Fetal Monitoring System; b) PUREtrace, Nemo Fetal Monitoring S	System [36]. 26		
Obr. 10: Příklad abdominálního rozmístění s a) 5 elektrodami; b) 6 elektrodami; c) 10 e	elektrodami;		
d) 13 elektrodami; e) 32 elektrodami [35, 37]	28		
Obr. 11: Příklad kombinovaného rozmístění s a) 8 elektrodami; b) 14 elektrodami dl	e Vullingse;		
c) 14 elektrodami dle Andreottiho [35, 37]	29		
Obr. 12: Ukázka aEKG s rušivou složkou EMG a EHG [47]	30		
Obr. 13: Rozdělení adaptivních a neadaptivních metod pro extrakci fEKG [49]	32		
Obr. 14: Model umělého neuronu [51]	33		
Obr. 15: Přenosové funkce neuronu [51, 54]	34		
Obr. 16: Struktura vícevrstvé ANN s jednou skrytou vrstvou [91]	46		
Obr. 17: Struktura ADALINE [95]	48		
Obr. 18: Struktura ANFIS s dvěma vstupy a jedním výstupem [51]	49		
Obr. 19: Struktura ESN [83]	52		
Obr. 20: Blokové schéma navrženého systému pro extrakci fEKG	56		
Obr. 21: Panel pro nastavení parametrů filtrace v GUI	57		
Obr. 22: První blok GUI pro zobrazení a filtraci aEKG. Pro ukázku byl využit 3. svod z	áznamu r08		
z databáze Labour dataset	58		
Obr. 23: Vykreslení výsledných signálů po aplikaci metody ICA pro záznam r01 z datal	oáze Labour		
dataset	59		
Obr. 24: Druhý blok GUI pro extrakci fEKG. Pro ukázku byl využit záznam r08 z databáze Lab	our dataset.		
Obr. 25: Hodnotící parametry metody ESN pro extrakci fEKG ze záznamu r08 pomocí dete	ektoru ANN.		
Obr. 26: Hodnotící poromotry motody ESN pro ovtrakci fEKC zo záznamy r08 pomocí dot	02		
Obr. 27: Třetí blok GUI pro vyhodnocení a vykreslení fHR. Pro ukázku byl využit záznam rO	8 z databáze		
Labour dataset	63		
Obr. 28: Vykreslení signálů ze záznamu r01, databáze Labour dataset	64		
Obr. 29: Vykreslení signálů pro záznam r01 z databáze Pregnancy dataset	65		
Obr. 30: Zobrazení fHR v čase pro metody ADALINE, ANFIS a ESN; záznam r08 Labour data	set 71		

Obr. 31: Zobrazení fHR v čase pro metody ANN-ADALINE, ANN-ANFIS a ANN-ESN; záznam r08 Labour
dataset72
Obr. 32: Vykreslení průběhů extrahovaných fEKG signálů metodami ADALINE, ANFIS a ESN společně
s původním aEKG signálem a skalpovým fEKG; záznam r08 Labour dataset
Obr. 33: Vykreslení průběhů extrahovaných fEKG signálů metodami ANN-ADALINE, ANN-ANFIS a ANN-
ESN společně s původním aEKG signálem a skalpovým fEKG; záznam r08 Labour dataset
Obr. 34: Zobrazení fHR v čase pro metody ADALINE, ANFIS a ESN; záznam r05 Pregnancy dataset 79
Obr. 35: Zobrazení fHR v čase pro metody ANN-ADALINE, ANN-ANFIS a ANN-ESN; záznam rO5
Pregnancy dataset
Obr. 36: Vykreslení průběhů extrahovaných fEKG signálů metodami ADALINE, ANFIS a ESN společně
s původním aEKG signálem; záznam r05 Pregnancy dataset
Obr. 37: Vykreslení průběhů extrahovaných fEKG signálů metodami ANN-ADALINE, ANN-ANFIS a ANN-
ESN společně s původním aEKG signálem; záznam r05 Pregnancy dataset
Obr. 38: Vykreslené křivky fHR získané pomocí metody ADALINE, ANFIS a ESN s CWT detektorem;
záznam r02 Labour dataset
Obr. 39: Zobrazení průběhů extrahovaných fEKG signálů metodami ADALINE, ANFIS a ESN při chybové
detekci; záznam r02 Labour dataset
Obr. 40: Srovnání vhodných a nevhodných extrahovaných průběhů fEKG získaných metodou ADALINE
a ANN-ADALINE; záznam r05 (Pregnancy dataset) byl použit pro ukázku vhodné extrakce, záznam r02
(Pregnancy dataset) jako nevhodné extrakce

## SEZNAM TABULEK

Tab. 1: Klasifikační kritéria a interpretace hodnocení KTG [27]	23
Tab. 2: Hodnoty ACC pro jednotlivé extrakční metody s použitím ANN detektoru; Labour dataset 6	56
Tab. 3: Hodnoty ACC pro jednotlivé extrakční metody s použitím CWT detektoru	57
Tab. 4: Shrnutí nejvhodnějších metod dle ACC pro jednotlivé záznamy z databáze Labour dataset 6	58
Tab. 5: Nastavené parametry pro metodu ESN a hodnoticí parametry získané ANN detektorem 6	59
Tab. 6: Průměrné hodnoty fHR stanovené detektorem ANN pro jednotlivé metody; Labour dataset.	70
Tab. 7: Průměrné hodnoty fHR stanovené detektorem CWT pro jednotlivé metody	70
Tab. 8: Hodnoty ACC pro jednotlivé extrakční metody s použitím ANN detektoru; Pregnancy datase	et.
	75
Tab. 9: Hodnoty ACC pro jednotlivé extrakční metody s použitím CWT detektoru; Pregnancy datase	et.
	76
Tab. 10: Shrnutí nejvhodnějších metod dle ACC pro jednotlivé záznamy z databáze Pregnancy datase	et.
	76
Tab. 11: Nastavené parametry pro metodu ESN a hodnoticí parametry získané CWT detektorem, ko	de
M je počet neuronů v rezervoáru a $lpha$ představuje míru zapomínání	77
Tab. 12: Průměrné hodnoty fHR stanovené detektorem ANN pro jednotlivé metod	y;
Pregnancy dataset	78
Tab. 13: Průměrné hodnoty fHR stanovené detektorem CWT pro jednotlivé metod	y;
Pregnancy dataset	78
Tab. 14: Uvedené časy výpočtů pro jednotlivé metody	34

# ÚVOD

Fetální tepová frekvence je často využívaným indikátorem stavu plodu během těhotenství i během porodu. Včasnou a správnou diagnostikou patologických stavů lze předejít nevratnému poškození nebo i úmrtí plodu.

Nejčastěji využívanými technikami pro monitorování plodu jsou fetální echokardiografie (fECHO) a kardiotokografie (KTG). Tyto metody však nejsou vhodné pro dlouhodobé monitorování z důvodu expozice plodu ultrazvukovým zářením. Specificita metody KTG bývá často nízká, což vede ke zvýšenému počtu nadbytečně provedených lékařských zákroků. Vhodnou alternativou je využití NI-fEKG, kdy je pomocí elektrod umístěných na břiše těhotné ženy měřeno aEKG. Výhodou této metody je jednoduchá obsluha (není potřeba proškoleného personálu) a především její neinvazivnost, která umožňuje dlouhodobé monitorování. Získaný aEKG signál obsahuje kromě fetální složky také složku mateřskou a šum. Kvůli tomu, že fetální složka dosahuje nízkých amplitud, je potřeba kvalitní zpracování, během kterého jsou ze signálu odstraněny nežádoucí složky, jako je právě šum a signál matky. Extrakce fEKG signálu z aEKG signálu je předmětem této práce.

První část práce se zaměřuje na anatomii srdce plodu, především na srdeční vývoj a fetální krevní oběh. Dále jsou popsány monitorovací techniky plodu, které lze využít ke stanovení fHR. Z dostupných metod pro stanovení fHR se tato práce zaměřuje na ty, které využívají neinvazivního měření a zpracování fEKG. V literární rešerši je pozornost zaměřena na extrakční metody využívající ANN.

Na základě literární rešerše jsou vybrané metody pro extrakci fEKG aplikovány na reálná data. Pro otestování těchto metod je vytvořeno GUI v programu MATLAB, které také umožňuje zobrazení a analýzu zpracovaných signálů. U fEKG signálů, které byly extrahovány pomocí zvolených metod, byly detekovány R-kmity, ze kterých byla vypočítána hledaná hodnota fHR. Závěrečná část práce se věnuje diskusi nad dosaženými výsledky.

# 1 VÝVOJ KARDIOVASKULÁRNÍHO SYSTÉMU

Kardiovaskulární systém se vyvíjí již přibližně v polovině 3. týdne vývoje plodu. Extraembryonálně dochází k vytvoření prvních cév a krvinek. Ty vznikají tzv. angiogenezí z krevních ostrůvků, které se utvářejí z extraembryonálního mezodermu žloutkového váčku, zárodečného stvolu a choria. Krevní ostrůvky se následně rozlišují v oploštěné elementy, zvané angioblasty. Angioblasty dávají původ endotelu cév, primitivním krvinkám (hematogonie) a krevní plazmě. Také intraembryonálně vznikají krevní ostrůvky. Jejich diferenciací a propojením dochází k utváření hlavních cév embrya [1, 2].

## 1.1 Vývoj srdce

Ze začátku probíhají dvě endotelové trubice paralelně vedle sebe. Později trubice splynou a vytvoří jednu srdeční trubici (*cor tubulare*). Ve 23. dni těhotenství ohybem srdeční trubice začíná vývoj srdeční kličky. Dochází k rozšíření trubice na více místech. Vzniká primitivní síň, jakožto základ budoucích síní, která navazuje na *sinus venosus*. Mezi primitivní síní a primitivní komorou se nachází atrioventrikulární kanál. Z primitivní komory pokračuje *bulbus cordis*, z jehož distální části vzniká plicnice (*truncus pulmonalis*) a ascendentní aorta. Vývoj srdeční kličky ze srdeční trubice je zobrazen na Obr. 1 [2, 3].



Obr. 1: Vývoj srdeční kličky ze srdeční trubice [3].

Mezi 27.–37. dnem těhotenství dochází k vytvoření síňových přepážek. Nejdříve dochází k rozdělení na pravou a levou síň růstem přepážky zvané *primum septum* z horní stěny primitivní síně k atrioventrikulárnímu kanálu. Z atrioventrikulárního kanálu vyrůstají endotelové polštářky a rozdělují ho na pravý a levý otvor. Endokardové polštářky tvoří rozhraní mezi síní a komorami. Vpravo a více vepředu od *septum primum* vyrůstá následně druhá přepážka zvaná *septum secundum*. Druhá přepážka při růstu nedosáhne až k endokardovým polštářkům, proto mezi síněmi zůstává otvor nazývaný *foramen ovale* [1, 3].

Z oblasti srdečního hrotu vyrůstá směrem k endokardovým polštářkům komorové septum (*septum interventriculare*). Zakládá se ke konci 4. týdne, ale nedorůstá až k polštářkům, z tohoto důvodu je v septu otvor (*foramen interventriculare*). V 7. týdnu bulbárními valy, které se spirálně stáčejí a srůstávají dohromady, vzniká aortopulmonální septum. Dochází k rozdělení *foramen interventriculare* na dvě části, které odpovídají vchodům do velkých cév. Ve výsledku krev z levé komory vtéká do aorty a krev z pravé komory do *truncus pulmonalis* [1, 2].

Ve 4. týdnu začínají odvádět odkysličenou krev z přední oblasti srdce párové prekardinální žíly a z oblasti zadní postkardinální žíly. Tyto žíly ústí do *sinus venosus*, kde ústí taktéž umbilikální (pupečníkové) a vitelinní žíly. Z pravé prekardinální žíly je vyvinuta horní dutá žíla. V oblasti ledvin se z obou postkardinálních žil vyvíjejí nové subkardinální žíly a z pravé subkardinální žíly je vyvinuta dolní dutá žíla [1, 2].

## 1.2 Fetální krevní oběh

U fetálního oběhu, který je zobrazen na Obr. 2, nedochází k okysličení krve v plicích. Okysličená krev je vedena z placenty levou umbilikální žílou (*vena umbilicalis*) do jater. Následně společně s krví z jater je portální žílou vedena do ústí dolní duté žíly (*vena cava inferior*). Podstatné množství krve je dodáno do pravé síně, dále skrz *foramen ovale* do levé síně, levé komory a aorty (na Obr. 2 označeno jako L.S., L.K. a A). Z aorty krev proudí do hlavové oblasti, odkud je vedena odkysličená krev do horní duté žíly (*vena cava superior*) a z ní do pravé síně. Z pravé síně může krev téct také do pravé komory (P.K.). Z pravé komory je krev vedena do plicnice (P). Jelikož plíce ještě nefungují a plicní oběh je stlačený, proudí značná část krve z plicnice do descendentní aorty skrze Botallovu dučej (*ductus Botalli, ductus arteriosus*). Dále se krev vrací přes párové umbilikální artérie (*arteriae umbilicales*) do placenty [2].



Obr. 2: Krevní oběh plodu [2].

S prvním nádechem dítěte se dostává krev do plic přes plicní tepny. Z plic je krev vedena plicními žílami (*vena pulmonalis*) do levé síně. Zvýšením tlaku v levé síni dojde k přitlačení *septum primum* proti *septum secundum*, což má za následek uzavření *foramen ovale*. Uzavírá se také spojení mezi plicnicí a aortou (*ductus Botalli*), ze kterého se stává vazivový provazec. Výsledkem je oddělený žilní krevní oběh od tepenného oběhu [2].

# 2 MONITOROVÁNÍ SRDCE PLODU

Přísun kyslíku a živin k plodu je zajištěn prostřednictvím placenty, rovněž odvod oxidu uhličitého a odpadních látek z plodu ven. Jestliže dojde např. ke kompresi pupečníku, změně ve funkci placenty, zhoršení okysličení matky či abnormální děložní kontrakci může se následkem těchto příčin snížit přísun kyslíku k plodu a vzniká stav zvaný hypoxie. Hypoxémie a hypoxie předcházejí asfyxii (viz. Kap. 2.1), což je jedna z nejčastějších příčin úmrtí v perinatálním období [4]. Tento stav se projeví například snížením fHR, proto monitorování fHR bývá často používaným indikátorem stavu plodu během těhotenství i porodu. Správná a včasná diagnostika v těhotenství může tedy předejít nevratnému postižení nebo i úmrtí plodu [5, 6].

## 2.1 Hypoxémie, hypoxie a asfyxie

Stav, při kterém dochází k poklesu saturace kyslíku v tepenné krvi, se nazývá hypoxémie. Jedná se o počáteční stav, kdy ještě nejsou postiženy buněčné a orgánové funkce. Pokud však hypoxémie přetrvává, jsou spuštěny obranné mechanismy organismu. Nejprve se organismus snaží co nejefektivněji využívat kyslík, následně dochází k omezení pohybu, a nakonec omezí plod svůj růst. V tomto stavu může plod přežít v řádu dnů až týdnů bez podstatné újmy. Výsledkem dlouhotrvající hypoxémie je omezený růst a vývoj orgánových soustav. Problém také nastává během porodu, kdy má plod s dlouhodobou hypoxémií menší toleranci vůči akutní hypoxii, které je vystaven [7, 8].

K hypoxii dochází, jestliže se dále saturace krve kyslíkem snižuje a začíná se nedostatek kyslíku projevovat v periferních tkáních. Aktivovány jsou silnější obranné mechanismy, vyplavují se hormony nadledvin, centralizuje se oběh do mozku, srdce a nadledvin. Průtok krve do periferních tkání je omezen, dochází zde k rozvoji anaerobního metabolismu. V tomto stavu plod dokáže vytrvat několik hodin bez trvalých následků [7, 8].

Následným snižováním saturace krve kyslíkem až do extrémně nízkých hodnot, kdy anaerobní metabolismus probíhá nejen v periferních tkáních, ale také v důležitých orgánech jako je srdce a mozek, se plod dostává do akutního stavu zvaným asfyxie. Asfyxii je nutné vyřešit v rámci minut. Pokud nedojde k okamžitému zvýšení kyslíku v krvi, dochází k selhání srdce a centrální nervové soustavy (CNS) [7, 8].

## 2.2 Současné metody monitorování srdce plodu

Mezi nejčastěji využívané metody monitorování plodu v klinické praxi patří fECHO a KTG. Obě tyto metody ale využívají ultrazvukové snímače, čímž se nehodí pro dlouhodobé monitorování v důsledku expozice ultrazvukem. Navíc má KTG nízkou specificitu, což vedlo k zvýšenému počtu nadbytečně provedených lékařských zákroků [5]. Z tohoto důvodu byla zaměřena pozornost na další monitorovací metody jako fetální fonokardiografie (fFKG), fMKG a fEKG, které taktéž dokáží monitorovat fHR a mohly by tak nahradit dosavadní techniky [4, 11].

#### 2.2.1 Fetální fonokardiografie

Fetální FKG je nenákladná a neinvazivní metoda pro detekci srdečních ozev plodu (fHS). Za normálních podmínek lze fHS charakterizovat dvěma slyšitelnými ozvami pro každý srdeční cyklus. První srdeční ozva (S1) označuje počátek komorové systoly a je charakterizována mitrální a trikuspidální složkou, které jsou spojeny s uzavřením mitrální a trikuspidální chlopně. Druhá srdeční ozva (S2) označuje nástup diastoly. Skládá se taktéž ze dvou složek, a to z aortální a plicní složky odpovídající uzavření poloměsíčitých chlopní. Signál S1 obsahuje obvykle nízkou frekvenci s delší dobou trvání a vysokou intenzitou. Na rozdíl od S1, představuje S2 signál s vysokou frekvencí, kratší dobou trvání, což ztěžuje jeho detekci [10].

Srdeční činnost plodu však vytváří mnohem menší akustický signál než srdce dospělého. Navíc je tento signál zatížen elektrickým šumem a dalšími akustickými signály, jako jsou například srdeční ozvy matky, ozvy trávicího traktu, mateřské a plodové respirační pohyby. Také je závislý na místě snímání, gestačním stáří, poloze plodu a matky, což vede k nestacionaritě signálu. Proto zpracování signálu pro detekci fHS je značně problémové [10, 11].

V současné době je aplikace fFKG omezena na analýzu fHR, která by se mohla využívat jako sekundární diagnostický nástroj v období před porodem. Jelikož trpí nízkým poměrem signálu k šumu (SNR) nebyla by vhodná pro snímání během porodu [11]. Fetální FKG je moderní formou auskultace, která detekuje akustické signály z povrchu břicha matky. Detekce je umožněna pomocí mikrofonu s piezoelektrickým krystalem, který zachycené vibrace mění na elektrický výstup dle tlaku vyvolaného akustickou vlnou [12]. Zařízení s takovýmto mikrofonem pro detekci fHS se nazývá stetoskop. Signály jsou následně počítačově analyzovány a zpracovány [13, 14]. Ukázka čtyřkanálového zařízení pro fFKG se 4 oddělenými piezoelektrickými senzory je zobrazena na Obr. 3.



Obr. 3: Zařízení pro čtyřkanálovou fFKG [15].

Metodu fFKG lze aplikovat v mnoha případech již ve 20. týdnu gestačního stáří a je schopna odhalit například rozštěpy a srdeční šelesty, které mohou souviset s vrozenými srdečními chorobami nebo patologické stavy způsobující ireverzibilní neurologická poškození. Jelikož se jedná o jednoduchou a neinvazivní metodu, mohla by být využita v domácím prostředí pro monitorování plodu [13, 14].

#### 2.2.2 Fetální echokardiografie

Fetální ECHO je sonografické vyšetření, které se používá k identifikaci a charakterizaci srdečních anomálií plodu před porodem. Jedná se pravděpodobně o komerčně nejdostupnější prostředek pro monitorování srdeční činnosti. Vyšetření by mělo být provedeno pro získání nezbytných diagnostických informací s nejnižší možnou dávkou expozice ultrazvukem. V některých případech jsou nezbytná další vyšetření například pomocí barevné dopplerovské sonografie [12, 16].

Běžně se fECHO provádí mezi 18.–22. týdnem gestačního stáří [16]. Optimální pohled na srdce je získán, pokud je srdeční hrot plodu nasměrován k přední stěně matky. Pro poruchy průtoku nebo srdečního rytmu se využívá dopplerovská sonografie. Při dopplerovské sonografii se využívá ultrazvukového měniče, který pulsně vysílá ultrazvukové vlny většinou o frekvenci 2 MHz při intenzitě 10 mW/cm<sup>2</sup> [14]. Dlouhodobé vystavení těmto ultrazvukovým vlnám se nedoporučuje jak pro matku, tak ani pro plod, a z toho důvodu tato technika není vhodná pro dlouhodobé sledování fHR. Navíc je tato metoda náchylná na pohybové artefakty a při obsluze je zapotřebí proškoleného personálu [6, 14, 16]. Vyšetření fetálního srdce technikou fECHO je zobrazeno na Obr. 4.



Obr. 4: Ukázka vyšetření fECHO technikou [17].

#### 2.2.3 Fetální magnetokardiografie

Při fMKG se zaznamenává magnetické pole vytvořené aktivitou srdce plodu v břiše matky. Magnetické pole je generováno proudy, které procházejí v srdci plodu. Toto magnetické pole je extrémně slabé (10<sup>-12</sup> T) [18]. Záznam je umožněn dostatečně citlivým supravodivým kvantovým interferenčním zařízením (SQUID), které musí být chlazeno kapalným heliem. Helium je obsaženo v nádobě (kryostatu), která je umístěna pár cm nad břichem matky. Technika je tedy neinvazivní bez jakéhokoliv kontaktu s tělem matky. Při vyšetření (Obr. 5) musí být matka v klidu na lůžku [18–20].



Obr. 5: Ukázka vyšetření technikou fMKG [21].

Metodou fMKG lze monitorovat plod od 20. týdne těhotenství [18]. Využívá se ke zkoumání variability fHR, signálových intervalů PQRST a patologických stavů. Je užitečným nástrojem v diagnostice fetální tachyarytmie a při monitorování intrauterinní terapie [19]. Morfologická analýza je jednodušší u fMKG než u NI-fEKG, jelikož SNR bývá u fMKG vyšší. Oproti NI-fEKG, se fMKG nehodí na dlouhodobé monitorování. Přístroje pro záznam fMKG jsou složitější a dražší, také při obsluze je zapotřebí kvalifikovaného personálu [9, 12].

#### 2.2.4 Kardiotokografie

Kardiotokografie se využívá pro kontinuální registraci fHR a děložní aktivity. Monitorování fHR je uskutečněno ultrazvukovým snímačem, který využívá dopplerovského principu a je umístěn z vnějšku na břiše matky. Pro monitorování děložní činnosti se využívá tlakového snímače založeném na piezoelektrickém jevu, který je připevněný taktéž na břiše matky, pod děložním fundem. Pomocí tohoto snímače se však nedá zaznamenat intenzita kontrakcí, ale pouze jejich frekvence a délka [22–25]. Na Obr. 6 je zobrazeno umístění těchto dvou snímačů na břiše matky.



Obr. 6: KTG vyšetření [26].

Grafický záznam křivky fHR se nazývá kardiotachogram a grafický záznam křivky děložní činnosti je tokogram. Celkový záznam pořízený při KTG se nazývá kardiotokogram a je zobrazen na Obr. 7. Posun kardiotokogramu je v Evropě nastaven na 1 cm/min [22]. Při analýze záznamu se nejdříve vyhodnocují základní parametry jako je bazální frekvence, variabilita, akcelerace, decelerace a kontrakce [22, 27].



Obr. 7: Kardiotokogram. Nahoře je zobrazen průběh fHR, pod ním průběh děložních kontrakcí [28].

Bazální frekvence představuje průměrnou hodnotu srdeční frekvence posouzenou v desetiminutových intervalech. Normokardie je hodnota pohybující se od 110 do 160 tepů za minutu (bpm) [27]. Při zaznamenání hodnoty nad 160 bpm po dobu minimálně 10 minut se jedná o tachykardii. Bradykardie značí hodnoty pod 110 bpm po dobu větší než 10 minut [27, 29].

Variabilita představuje oscilaci fHR vyhodnocenou jako průměrnou šířku pásma amplitudy signálu v jednominutovém časovém úseku. Normální variabilita se nachází v rozmezí od 5 do 25 bpm. Hodnota pod 5 bpm trvající déle než 50 minut v základním úseku nebo trvající déle než 3 minuty během decelerace značí sníženou variabilitu (redukovanou variabilitu). Zvýšená variabilita (saltatorní typ) je nad horní hranicí 25 bpm po dobu 30 minut a více [27].

Jestliže dojde k rychlému vzestupu fHR nad hodnotu bazální frekvence alespoň o 15 bpm trvající v rozmezí od 15 sekund do 10 minut, jedná se o akceleraci. Pokles fHR o více než 15 bpm pod bazální frekvencí po dobu větší než 10 sekund je decelerace. Decelerace mohou být rané, variabilní (tvar písmene V), pozdní (tvar písmene U) a prolongované [27].

Postupný růst děložní aktivity, který následně symetricky klesá charakterizují kontrakce. Doba trvání kontrakcí je od 45 do 120 sekund [27].

	Fyziologický/normální	Suspektní	Patologický
Bazální frekvence	110–160 bpm		< 100 bpm
Variabilita	5–25 bpm	Pokud chybí alespoň	Redukovaná variabilita > 50 min., Zvýšená variabilita > 30 min.
Decelerace	Žádné opakované decelerace	<ul> <li>jedna charakteristika normality, bez patologických znaků</li> </ul>	Opakované pozdní nebo prolongované decelerace > 30 min. nebo 20 min. při snížené variabilitě, nebo jedna prolongovaná decelerace > 5 min.
Interpretace	Plod bez hypoxie/acidózy	Plod s nízkou pravděpodobností hypoxie/acidózy	Plod s vysokou pravděpodobností hypoxie/acidózy
Klinický management	Není potřeba žádné intervence pro zlepšení stavu oxygenace plodu	Opatření ke korekci odvratitelných příčin, pokud jsou identifikovány, pečlivé monitorování nebo použití dalších metod ke zhodnocení oxygenace plodu	Okamžité opatření ke korekci odvratitelných příčin, použití dalších metod ke zhodnocení oxygenace plodu nebo, pokud to není možné, rychlý porod

Tab. 1: Klasifikační kritéria a interpretace hodnocení KTG [27].

Po vyhodnocení kardiotokogramu dle FIGO (*International Federation of Gynecology and Obstetrics*) klasifikace (Tab. 1) a výše uvedených parametrů je záznam začleněn do jedné ze tří kategorií: záznam fyziologický/normální, suspektní a patologický. Vyhodnocení by se mělo opakovat alespoň jednou během 30 minut [22, 27].

Prostřednictvím KTG lze sledovat plod od 24. týdne těhotenství [24]. Hodnocení kardiotokogramu závisí na gestačním stáří, fázi porodu a jeho dosavadním průběhu, stavu plodu i matky a medikaci. Po zavedení KTG do klinické praxe byla získána metoda pro identifikaci hypoxie plodu během porodu, pomocí které bylo možno vyhnout se asfyxii plodu nebo dokonce intrapartálnímu úmrtí. KTG prokazuje vysokou senzitivitu, ale má nízkou specificitu, což vede ke zvýšené míře zbytečných lékařských zákroků [5]. Pro vyloučení falešné pozitivity se využívá dalších metod jako je například intrapartální fetální pulzní oxymetrie anebo analýza ST úseku fEKG. I po zavedení těchto dalších metod je KTG zlatým standardem ve včasném diagnostikování hypoxie plodu [5, 22, 24].

#### 2.2.5 Fetální elektrokardiografie

Fetální EKG je diagnostickou metodou, s jejíž pomocí lze snímat a zaznamenávat elektrickou aktivitu srdce plodu. Na rozdíl od mechanické činnosti, je elektrická činnost srdce plodu podobná činnosti srdce dospělého. Kontrakce a relaxace síní i komor je zajištěna převodním srdečním systémem, který je vyvinut v 16. týdnu těhotenství [30]. Skládá se ze speciálních automatických buněk, které nejenže vedou podráždění ve formě akčního potenciálu, ale také ho periodicky vytvářejí. Fyziologicky vzniká vzruch v sinoatriálním uzlu (SA), který se nachází v blízkosti horní duté žíly. SA uzel slouží jako pacemaker neboli udavatel rytmu, a tedy určuje fHR. Vzruch je dále přenesen stěnou pravé síně do atrioventrikulárního uzlu (AV), který se nachází ve spodní zadní části pravé síně. Z AV uzlu pokračuje vzruch do Hisova svazku vybíhající komorovým septem, kde se dále dělí na levé a pravé Tawarovo raménko. Tawarova rámenka se větví na Purkyňova vlákna, která rozvádějí podráždění ke všem buňkám myokardu komor. Rychlost vzruchu se během přenosu zmenšuje [3, 12, 31].

Vytvořením vzruchu v AV uzlu je zahájen srdeční cyklus, vzruch se následně šíří celým převodním systémem až k jednotlivým buňkám myokardu. Poté co se tyto buňky aktivují, dochází ke vzniku potenciálu, který lze zaznamenat na elektrokardiogramu (EKG). Na záznamu je jako první rozlišitelná vlna P, která je výsledkem depolarizace síní. Repolarizaci síní nelze na EKG rozlišit, jelikož je signál zastíněn signálem s vyšší amplitudou, který vzniká v důsledku depolarizace komor. Depolarizace komor je znázorněna na EKG jako komplex QRS. Další částí je vlna T, která odpovídá repolarizaci komor. V některých případech po vlně T následuje malá vlna U. Při normálním EKG, značí vlna U repolarizaci Purkyňových vláken. Z EKG lze také zjistit fHR, která se určuje z R-R intervalu [6, 12, 31].

Záznam lze získat invazivní a neinvazivní metodou. Invazivní metoda využívá skalpové elektrody, která se zavádí přes rozšířené děložní hrdlo po protržení plodových obalů, z toho důvodu je aplikace možná pouze během porodu. Elektroda má na konci malou kovovou spirálu, která se šroubovitým pohybem umístí těsně pod kůži na pokožce hlavy plodu (popř. na hýždi plodu) [7]. Protože takto umístěná elektroda je v přímém kontaktu s plodem, poskytuje velmi kvalitní záznam, který je zřetelnější než u neinvazivního způsobu snímání. Nevýhodou je možný přenos infekce do těla matky nebo plodu. Pokud dojde k nedostatečnému kontaktu elektrody s temenem hlavy, dochází k špatnému přenosu signálu a kolísání izolinie [6, 32, 33].

Neinvazivní metoda využívá několik elektrod umístěných na břiše matky, co nejblíže plodu, čímž je získáno aEKG. Rozmístění elektrod není dáno žádným standardizovaným schématem, jako u neinvazivního měření EKG dospělého. Jelikož se jedná o neinvazivní metodu není pro matku či plod zatěžující a lze ji použít jak během porodu, tak v době od 20. týdne těhotenství (kromě období, kdy se vytváří *vernix caseosa*, což bývá nejčastěji mezi 28.–32. týdnem) [9]. Další výhodou této metody je možnost dlouhodobého monitorování fEKG. Mezi hlavní omezení patří nízké SNR, které komplikuje následné vyhodnocení. Důvodem je nízká amplituda fEKG, na které je navíc superponováno mateřské EKG (mEKG) a šum (viz Kap. 3) [32–34]. Zobrazené EKG signály získané invazivní i neinvazivní metodou jsou zobrazeny na Obr. 8.



Obr. 8: Ukázka EKG signálů, shora: čtyřsvodové aEKG, fEKG ze skalpové elektrody (signál r08 labour dataset)

EKG je důležitá metoda pro detekci srdečních arytmií, ischemií a dalších srdečních vad. Hlavním cílem je stanovení fHR. V poslední době je velmi využívaná ST analýza (STAN) z křivky invazivního fEKG, která bývá doplňující metodou ke KTG. Pro analýzu se využívá ST interval, jelikož je nejvíce citlivý na hypoxické změny. Získává-li organismus energii pomocí anaerobního metabolismu (myokard reaguje na hypoxii), dochází k nárůstu vlny T. Nevyhodnocuje se absolutní výška vlny T, ale poměr výšek vlny T a QRS komplexu, který je popsán následující rovnicí (1):

$$STAN = \frac{T}{QRS},$$
(1)

kde *T* je výška vlny T a *QRS* je výška QRS komplexu. Jestliže se poměr zvýší nad 0,1, kdy je značný nárůst vlny T, reaguje plod na hypoxii. Pokud tento nárůst trvá do 10 minut, jedná se o epizodický nárůst. Při stabilním nárůstu trvají tyto změny déle než 10 minut. U stabilního nárůstu je významné zvýšení poměru i o více než 0,05. Dále se hodnotí bifázicita ST úseku, která probíhá ve 3 stupních. První označuje depresi ST úseku nad základní linii, což je možno brát jako fyziologickou změnu. Druhý stupeň značí depresi ST úseku pod bazální linií, a jestliže se nachází celý bifázický ST úsek pod bazální linií, jedná se o třetí stupeň. Druhý a třetí stupeň označují hypoxii plodu a pokud trvají více než 5 minut je nutná intervence. Analýza ST úseku je v současné době omezena pouze na použití během porodu, jelikož se využívá skalpové elektrody umístěné na hlavičce plodu. Pokud by však byla nalezena vhodná filtrační metoda, bylo by možné provádět STAN na NI-fEKG signálu a nahradit tak analyzátor ST úseku využívající skalpovou elektrodu [7, 8, 12, 32].

# **3** NEINVAZIVNÍ FETÁLNÍ ELEKTROKARDIOGRAFIE

V porovnání s výše uvedenými metodami monitorování plodu, je NI-fEKG metodou levnou, není zapotřebí žádného velkého zařízení jako u fMKG, ani kvalifikovaného personálu pro obsluhu. Umožňuje od 20. týdne těhotenství monitorovat fHR a také teoreticky umožňuje morfologickou analýzu, na rozdíl například od dopplerovského ultrazvuku. Morfologickou analýzou je možno odhalit patologické stavy srdce, ale problémem při vyhodnocování NI-fEKG je nízké SNR. Jedná se o metodu neinvazivní, jednoduchou, a proto je na ni v poslední době zaměřena velká pozornost i v ohledu možného využití pro domácí monitorování plodu [18, 35].

## 3.1 Historie a současnost

První zdokumentovaný záznam NI-fEKG provedený prostřednictvím elektrod umístěných na břiše matky realizoval M. Cremer v roce 1906. Pro provedení záznamu se využívaly galvanometrické přístroje, které byly omezeny velmi nízkou amplitudou signálu plodu. S vývojem techniky se stávala fEKG proveditelnější, ale velkým limitujícím faktorem, který přetrvává dodnes, bylo nízké SNR. Až s rozvojem výpočetní techniky a pokročilých metod zpracování signálů byl z aEKG potlačen signál z matky a šum, aby mohl být získán fEKG, který byl použit pro detekci R-kmitů a výpočet fHR [6, 12, 35].

V posledních 10 letech se objevují první komerčně dostupné přístroje pro záznam NI-fEKG a monitorování fHR. Konkrétně se jedná o zařízení Monica AN24 a Monica Novii Wireless Patch System (Monica Healthcare, UK), MERIDIAN M110 Fetal Monitoring System (MindChild Medical, USA), PUREtrace a Nemo Fetal Monitoring System (Nemo Healthcare, Nizozemsko). Na Obr. 9 jsou zobrazena jednotlivá zařízení, která se navzájem liší počtem elektrod, ale i umístěním na břiše matky [36].



Obr. 9: Komerčně dostupná zařízení pro záznam NI-fEKG. a) Monica AN24, Monica Novii Wireless Patch System, MERIDIAN 110 Fetal Monitoring System; b) PUREtrace, Nemo Fetal Monitoring System [36].

## 3.2 Rozmístění elektrod

Při záznamu NI-fEKG se využívá elektrod rozmístěných na břiše matky. Poloha ani počet elektrod není standardizována z důvodu nestálé polohy plodu v břiše, a tak automatické stanovení fHR je značným problémem. I přestože standardizace není zcela možná, bylo navrženo pár postupů pro konfiguraci elektrod ve snaze alespoň o částečnou standardizaci postupu. Využívá se dvou obecných rozmístění. Buď lze pořídit pouze záznam aEKG pomocí abdominálních elektrod nebo lze využít kombinovaného rozmístění abdominálních a hrudních elektrod, ze kterých lze získat navíc záznam mEKG [32, 35, 37].

#### 3.2.1 Abdominální rozmístění elektrod

Na Obr. 10a je zobrazeno rozmístění elektrod dle [38], kde byly využity 3 aktivní elektrody rozmístěné vlevo, vpravo a nad jizvou pupeční (*umbilicus*). Referenční elektroda byla umístěna nad stydkou sponou [38]. Podobného rozmístění 4 elektrod bylo využito i v práci [39], zde byla navíc 5. referenční elektroda umístěna na pravém boku [39]. Aktivní elektrody jsou na Obr. 10 označeny symbolem +, referenční elektrody -, zemnící elektrody jako GND.

Jezewski a kol. [40] využívali ve své práci 6 elektrod pro extrakci fEKG (Obr. 10b). Jedna aktivní elektroda byla umístěna nad pupeční jizvou a další 3 vedle něj v jedné rovině (dvě vpravo a jedna vlevo). Referenční elektroda se nacházela nad stydkou sponou a zemnící elektroda na levé noze [40].

Další možné rozmístění je například dle Marossero a kol. [41] s 10 elektrodami, což je zobrazeno na Obr. 10c. Čtyři elektrody jsou vertikálně umístěny ve středu břicha (dvě nad a dvě pod jizvou pupeční). Vpravo i vlevo od těchto 4 elektrod jsou umístěny taktéž vertikálně dvě dvojice elektrod. Referenční je umístěna ve středu a zemnící elektroda na pravé noze [41].

V práci [42] bylo použito 13 břišních elektrod rozmístěných do tvaru šesticípé hvězdy (Obr. 10d) [42].

Obr. 10e představuje rozmístění 32 elektrod na základě orientačních bodů jako je *umbilicus*, mečovitý výběžek, stydká spona, axilární linie a páteř [43].



Obr. 10: Příklad abdominálního rozmístění s a) 5 elektrodami; b) 6 elektrodami; c) 10 elektrodami; d) 13 elektrodami; e) 32 elektrodami [35, 37].

#### 3.2.2 Kombinované rozmístění elektrod

Kombinované rozmístění elektrod bylo využito například v práci [44]. Pro snímání NI-fEKG bylo aplikováno 5 abdominálních elektrod okolo pupeční jizvy a 3 hrudní elektrody na levé straně pod ňadrem (Obr. 11a) [44].

Dle Vullingse a kol. [45] bylo rozmístěno 14 elektrod, 12 na břicho a zbylé 2 elektrody na ramena matky, což je zobrazeno na Obr. 11b. Abdominální elektrody byly seřazeny horizontálně ve dvou řadách po 6, nad a pod středem břicha [45]. Také Andreotti a kol. [46] využívali 14 elektrod rozmístěných podle Obr. 11c. Pro snímání nakonec byly však použity jen tři bipolární svody. Na Obr. 11c jsou umístěny nejblíže k jizvě pupeční [46].

Značení elektrod na Obr. 11 je stejné jako v předchozím případě, kdy aktivní elektrody jsou označeny +, referenční elektrody -, zemnící elektrody jako GND.



Obr. 11: Příklad kombinovaného rozmístění s a) 8 elektrodami; b) 14 elektrodami dle Vullingse; c) 14 elektrodami dle Andreottiho [35, 37].

#### 3.3 Vlastnosti NI-fEKG

Při neinvazivním snímání aEKG je výstupem z každého svodu součet tří složek: fEKG, mEKG a šum. Proto je nutné, aby došlo nejdříve k eliminaci mEKG a šumu pro získání fEKG signálu. Fetální signál se nachází ve frekvenčním pásmu od 0,5 do 100 Hz. Amplituda QRS komplexu je velmi závislá na umístění elektrody, poloze plodu a na jeho gestačním stáří. Obvykle amplituda nepřesahuje hodnotu 60 μV. Mateřské EKG se nachází ve stejném frekvenčním pásmu jako fEKG. Jedná se o signál až 10x silnější. Amplituda QRS komplexů v mEKG se pohybuje v rozmezí 100–150 μV [37].

Šum může mít fyziologický původ nebo nefyziologický. Mezi fyziologický šum patří děložní aktivita neboli elektrohysterogram (EHG) a aktivita břišních svalů (elektromyogram, EMG). EHG má frekvenční rozsah 0–3 Hz, EMG se nachází v rozsahu od 0 Hz do 200 Hz [47]. Na Obr. 12 je zobrazen záznam aEKG s vyznačením EHG, EMG a QRS komplexů od matky i plodu. Křivka EKG může být také modulována dle dýchání s frekvencí od 0,15 do 0,3 Hz [48]. Nefyziologický šum pochází z přístroje, síťového rušení (50 Hz), které je možno odstranit pásmovou zádrží tzv. notch filtem, dále vzniká šum ze špatného stínění v kabelech nebo v důsledku špatného kontaktu mezi elektrodou a kůží [6, 37, 47].

Dalším omezením při záznamu fEKG je tvorba ochranné vrstvy zvané *vernix caseosa* v období od 28. týdne těhotenství. *Vernix caseosa* elektricky izoluje plod, takže nelze prakticky zaznamenat NIfEKG. Přibližně od 32. týdne těhotenství se začíná postupně rozpadat a od 37. týdne je zcela rozpuštěn v plodové vodě [47].



Obr. 12: Ukázka aEKG s rušivou složkou EMG a EHG [47].

# 4 PROBLEMATIKA EXTRAKCE FEKG SE ZAMĚŘENÍM NA NEURONOVÉ SÍTĚ

Součástí aEKG je velmi slabý signál fEKG, na který je superponován šum a mateřské signály, které se navíc nacházejí ve stejném frekvenčním pásmu jako fEKG, ale s mnohem vyšší amplitudou, proto filtrace prostřednictvím pásmových propustí a zádrží není v tomto případě vhodným řešením. Protože je potřeba složitějších technik filtrace spojené se zpracováním signálu, extrakce fEKG z aEKG je složitým tématem a vzniklo spoustu prací, které se zabývají různými metodami pro získání fEKG a následnou detekci R-kmitů, ze kterých lze určit fHR.

Metody používané pro extrakci fEKG lze rozdělit na dvě skupiny, a to na neadaptivní a adaptivní metody. Neadaptivní metody nepoužívají žádný adaptivní systém, který by se přizpůsoboval současným okolnostem. Pro extrakci fEKG využívají konstantní hodnoty koeficientů a ve srovnání s adaptivními metodami jsou časově invariantní. Jedná se však o velmi rychlé a přesné metody. Neadaptivními metodami se zpracovává signál aEKG získaný z abdominálního rozmístění elektrod. Tyto metody lze následně rozdělit dle využití jednokanálového nebo vícekanálového zdroje signálu. Nejvíce využívanými technikami, které se řadí pod neadaptivní metody využívající jednokanálového zdroje signálu, jsou například vlnková transformace (WT), technika průměrování (AT), filtrační techniky (FT) zahrnující filtry s konečnou impulsní odezvou (FIR), filtry s nekonečnou impulsní odezvou (IIR), techniky založené na Wienerově filtraci a fixní FT, dále šablonové odčítání (TS) a empirický režim rozkladu (EMD) [32, 49]. Vícekanálové neadaptivní metody jsou založeny obzvláště na slepé separaci zdrojů (BSS). Princip BSS je založen na rozkladu signálu na původní jednotlivé zdrojové složky, v tomto případě rozklad signálu aEKG na původní zdrojové složky jako jsou fEKG, mEKG a šum. Tyto metody předpokládají statistickou nezávislost jednotlivých zdrojů. Mezi základní zástupce metod založených na BSS patří analýza nezávislých komponent (ICA), analýza hlavních komponent (PCA), analýza periodických komponent ( $\pi$ CA) a rozklad singulárních hodnot (SVD) [32, 50].

Adaptivní metody jsou založeny na systému učení. Pro extrakci fEKG využívají většinou kombinovaného rozmístění elektrod, ze kterého je získán signál aEKG a samostatně také mEKG. Tyto metody lze rozdělit na lineární a nelineární. Mezi lineární adaptivní metody patří metody založené na Kalmanově filtraci (KF), algoritmu se stochasticky gradientní adaptací (LMS) a algoritmu s rekurzivní optimální adaptací (RLS). Neuronové sítě (ANN) se řadí do kategorie nelineárních adaptivních metod, avšak například metoda adaptivního lineárního neuronu (ADALINE) je metodou lineární. ANN se také vyskytují v kombinaci s fuzzy logikou jako adaptivní neuro-fuzzy inferenční systém (ANFIS) [32, 49]. Rozdělení neadaptivních a adaptivních metod je vyobrazeno na Obr. 13.



Obr. 13: Rozdělení adaptivních a neadaptivních metod pro extrakci fEKG [49].

Adaptivní metody, obzvlášť tedy metody umělé inteligence jako jsou ANN, mají velký potenciál pro řešení problematiky extrakce NI-FEKG. Některé typy ANN nepotřebují navíc hrudní svod, kterým je získáno mEKG jako referenční signál pro odhad mEKG složky z aEKG a její následnou subtrakci. V některých případech není nutné ani nějak zvlášť předzpracovat analyzované aEKG. Problémem však u ANN může být potřeba velkého souboru trénovacích dat, či časová i výpočetní náročnost, která může být omezují při využití v malých mobilních zařízeních sloužící například pro domácí pozorování. V poslední době však vznikají práce, které aplikují různé typy ANN, které se snaží tyto problémy řešit.

#### 4.1 Model neuronu

ANN představují matematický výpočetní model, který je inspirován biologickými soustavami, zejména tedy nervovým systémem v lidském těle. Základní stavební a funkční jednotkou nervové soustavy je neuron. Neuron je určen pro přenos signálu. Signál vstupuje prostřednictvím dendritů a vystupuje axonem, který se dále větví. Tyto jednotlivé větve jsou synapticky spojeny s dendrity jiných neuronů. Po propojení velkého počtu neuronů vzniká neuronová síť, která dokáže přijímat, zpracovávat, uchovávat a přenášet informace paralelně prostřednictvím celé neuronové sítě. Stejně tak je i složena ANN, která je tvořena z matematických modelů neuronu. Základním modelem neuronu je tzv. formální neuron, který se také nazývá McCulloch-Pittsův neuron podle svých autorů. Na Obr. 14 je zobrazen model umělého neuronu [51–53].



Obr. 14: Model umělého neuronu [51].

Formální neuron má libovolný počet vstupů  $x_j$ , které jsou upravovány pomocí vah  $w_j$ . Jestliže je hodnota vstupů, upravených váhami, větší než nastavený práh  $\theta$ , je neuron aktivní. Na upravené vstupy je také aplikována přenosová (aktivační) funkce f. Výstup neuronu y je dán následující rovnicí (2) [51]:

$$y = f\left(\sum_{j=1}^{N} x_j w_j + \theta\right).$$
(2)

Základní vlastností ANN je učení, při kterém je hledán takový vektor *w*, aby bylo dosaženo požadovaných výsledků. Učení ANN lze rozlišit na učení s učitelem nebo bez učitele. Učení s učitelem využívá testovací data, která jsou poskytnuta ANN a výstupní hodnoty jsou porovnávány s očekávánými výsledky. Na základě rozdílů jsou následně nastavovány váhy pro co nejnižší chybu výstupu. Učení bez učitele probíhá přímo na datech, kdy ANN výsledky klasifikuje, hledá statisticky významné rysy a vlastnosti. V tomto režimu dochází k samooganizování tréninkových vzorů [51, 53].

Nejčastěji využívané přenosové funkce jsou zobrazeny na Obr. 15, jedná se o sigmoidu, hyperbolický tangens, lineární a skokovou funkci, ReLU (*Rectified Linear Unit*) a Leaky ReLU. Existuje však mnoho dalších přenosových funkcí. Využití je dáno dle požadovaných vlastností sítě [51].



Obr. 15: Přenosové funkce neuronu [51, 54].

ANN se mohou skládat z různých typů zapojení. Zapojení závisí na daném problému a rychlosti řešení tohoto problému, s čímž souvisí výpočetní či paměťová náročnost. Nejjednodušší zapojení se skládají pouze ze dvou vrstev neuronů, takováto zapojení se řadí do jednovrstvých neuronových sítí. Složitější vícevrstvé neuronové sítě jsou složeny z tří a více vrstev neuronů [51, 55].

#### 4.2 Jednovrstvé neuronové sítě

Jednovrstvé neuronové sítě mají výstupní a vstupní vrstvu. Nejjednodušší jednovrstvou neuronovou sítí je tzv. perceptron. Perceptron se skládá z jednoho formálního neuronu, jehož aktivační funkce je skoková buď v binární nebo bifázické podobě. Jedná se o tzv. dopřednou síť (acyklickou), která zpracovává signál od vstupu k výstupu bez cyklické závislosti. Limitací perceptronu je jeho využití pouze na řešení problémů s lineárním charakterem [51, 55].

#### 4.2.1 Adaptivní lineární neuron

ADALINE navrhl poprvé Widrow a Hoff v roce 1960. ADALINE lze taktéž jako perceptron zařadit do jednovrstvých neuronových sítí. Hlavní rozdíl mezi ADALINE a perceptronem je v tom, že ADALINE má lineární aktivační funkci a zpětnovazebnou smyčku. Navíc je doplněn o vstup s požadovanou odpovědí systému. Učení ADALINE souvisí s nalezením vhodného vektoru vah *w*, kdy se výstup co nejvíce blíží požadované odpovědi [55]. Reaz a Wei (2004) [56] využili pravidlo LMS pro učení ADALINE, která byla navržena pro extrakci fEKG z aEKG matky. LMS algoritmus je také označován jako delta učící pravidlo [55]. Pomocí sítě byl vytvořen vstupní signál (zašuměné mEKG), který se co nejvíce podobal cílovému signálu (aEKG). Fetální EKG bylo získáno jako rozdíl mezi mEKG a aEKG. Následně bylo vytvořeno GUI v programu MATLAB pro detekci změn získaného fEKG dle zadaných parametrů sítě jako je hybnost, rychlost učení a hodnota počátečních vah. Filtrace fEKG byla nejvíce účinná při nízké hybnosti, vysoké rychlosti učení a malých počátečních váhách [56].

Obdobným postupem extrahovali fEKG z aEKG také Hasan a kol. (2009) [57]. V této práci byla použita kombinace ADALINE a zpožďovací linky TDL (*Tapped Delay Line*). Vstupní signál mEKG je přiveden na vstup TDL, prochází N - 1 zpožděními a výstupem je N-rozměrný vektor, který vstupuje do ADALINE. Výstup z ADALINE je odečten od cílového signálu aEKG. Pro snížení rozdílu mezi vstupním a cílovým signálem byly aktualizovány v každém kroku váhy. Rozdíl vstupního a cílového signálu byl považován za fEKG. Nejlepšího výstupu fEKG bylo taktéž dosaženo při nastavení vysoké rychlosti učení a nízké hodnoty hybnosti [57].

Jia a kol. (2010) [58] navrhli stejný algoritmus ADALINE, který využíval LMS pro učení jako v předchozí práci [56]. Algoritmus byl navržen v programu MATLAB a byl testován nejprve na simulovaných signálech vytvořených generátorem GENWAVE od UG DigiScope. Simulované aEKG bylo vytvořeno superpozicí 2 signálů EKG, jeden se srdeční frekvencí 80 bpm a druhý se 140 bpm, vzorkovací frekvence byla 250 Hz. Prvních 1000 bodů signálů aEKG a mEKG bylo použito k tréninku sítě. Odečtením mEKG od aEKG bylo získáno fEKG. Po tréninku došlo ke zlepšení v extrakci fEKG. Algoritmus byl také testován na klinických datech z databáze DaISy. Bylo využito 5 aEKG signálů a 3 mEKG signály s vzorkovací frekvencí 250 Hz. Postup byl stejný jak při testování na simulovaných signálech. Pomocí této metody bylo získáno jasnější fEKG i s použitím menšího množství dat [58].

#### 4.2.2 Functional link ANN

Mezi jednovrstvé neuronové sítě lze také zařadit *Functional link* ANN (FLANN). Taktéž se skládá pouze ze vstupních a výstupních vrstev, díky čemuž není tak výpočetně náročná oproti vícevrstvým ANN. Vstup ve FLANN je rozšířen pomocí matematických funkčních řad jako je například trigonometrická řada, Chebyshevova řada, Legendreova řada atd [59]. Ma a kol. (2014) [60] navrhli nelineární adaptivní potlačovač šumu (ANC), který byl složen z FIR filtrů a FLANN. Koeficienty FIR filtrů a FLANN byly aktualizovány pomocí algoritmu LMS. Navržený ANC byl vybaven několika referenčními kanály a jedním primárním kanálem. Jako referenční signál bylo využito mEKG a jako primární aEKG z reálného souboru dat z databáze DalSy. Signály v tomto souboru byly 10 s dlouhé, vzorkovací frekvence byla 250 Hz. K dispozici bylo 5 aEKG a 3 mEKG. Navržený systém pro extrakci fEKG byl schopen dosáhnout lepší extrakce než konvenční technika s FIR filtrem. Čím více referenčních signálu mEKG bylo do systému zahrnuto, tím lepší extrakce fEKG bylo dosaženo [60].

## 4.3 Vícevrstvé neuronové sítě

#### 4.3.1 Dopředné neuronové sítě se zpětným šířením chyby

Vícevrstvé neuronové sítě jsou rozšířeny o více perceptronů. Skládají se ze vstupní vrstvy, alespoň jedné skryté vrstvy a výstupní vrstvy. Každý neuron z nižší vrstvy je kompletně propojen s neurony z vyšších vrstev. Vícevrstvý perceptron využívá taktéž dopředného zpracování signálu a je schopen řešit i lineárně neseparovatelné problémy, a tak je mnohem častěji využíván i v praxi. Nejčastěji je pro učení této sítě využit algoritmus zpětného šíření tzv. back-propagation (BP), kdy se šíří chyba od výstupní vrstvy až ke vstupní vrstvě a postupně jsou zpětným šířením upravovány jednotlivé váhy neuronů. Učení u takovéto sítě probíhá s učitelem a aktivační funkcí pro algoritmus s BP bývá nejčastěji sigmoida nebo hyperbolický tangens [51, 53, 55].

ANN s algoritmem BP společně s bayesovskou inferencí byly použity pro extrakci fEKG Yinem a kol. (2010) v práci [61]. Data pro experiment pocházela jak ze simulovaných signálů, tak z reálných. Reálné signály EKG byly zaznamenány z 8 kanálů, prvních 5 z břišní oblasti a další 3 z hrudní. ANN byla využita pro aproximaci hrudního mEKG do aEKG a bayesovská inferenční metoda pro aproximaci signálu fEKG. Navržený algoritmus byl porovnán s algoritmem polynomiálních sítí navržený v práci [62]. Vizuálně byl pro extrakci fEKG lepší algoritmus ANN s bayesovskou inferencí, který dokázal úspěšně extrahovat fEKG z celé délky simulovaných signálů. U reálných signálů po aplikaci polynomiální sítě byla amplituda Rkmitů fEKG velmi snížena a některé R-kmity byly dokonce ztraceny [61].

Hasan a kol. (2011) [63] vyvinuli metodu, kde zkombinovali vícevrstvou ANN s BP algoritmem a korelací pro extrakci fEKG a detekci R-kmitů v signálu aEKG. ANN je adaptivní na nelineární a časově proměnlivý signál EKG. Trénováním dokáže síť odfiltrovat artefakty a šum při detekci mateřského QRS komplexu mEKG v aEKG. Dále byl použit korelační faktor pro škálování mEKG a jeho následné odečtení od aEKG, čímž bylo získáno fEKG. Metoda byla aplikována na sérii 55 vícekanálových neinvazivních abdominálních záznamů s vzorkovací frekvencí 1 kHz pořízených od jediného subjektu mezi 21. až 40. týdnem těhotenství. Algoritmus byl odzkoušen pomocí programu MATLAB. Extrakce fEKG byla dostatečně dobrá, i když se fEKG a mEKG překrývaly. R-kmity v fEKG byly detekovány s přesností 93,75 % [63].

#### 4.3.2 Rekurentní neuronové sítě

V rekurentních (cyklických) neuronových sítích (RNN) se šíří signál taktéž od vstupní vrstvy k výstupní vrstvě, ale navíc je zde zavedena i zpětná vazba, která umožňuje šíření informace od vyšší vrstvy k těm nižším. Tuto zpětnou vazbu zajišťují tzv. rekurentní neurony, díky kterým lze do sítě zakomponovat i časový kontext. Výstup sítě je dán jak aktuálním vstupem, tak i vstupy předcházejícími. RNN využívá pro adaptaci vah stejně jako dopředná síť metodu BP [52, 53]. Avšak často u trénování RNN pomocí BP algoritmu mohou vznikat problémy, protože může docházet k opakovanému násobení rekurentních vah stejnou hodnotou, což má za následek nekontrolovaný růst či klesání gradientů. Řešením tohoto problému je využití sítě *Echo state* (ESN) anebo *Long Short-Term Memory* (LSTM) [64].
#### Echo state network

ESN jsou složeny z rekurentní vrstvy, která se nachází na vstupu. Váhy jsou v tomto případě nastaveny náhodně a dále už nedochází k jejich trénování [64]. Aplikace ESN k extrakci fEKG z neinvazivního záznamu aEKG byla představena Beharem a kol. (2013) [65]. ESN byla testována na signálech ze dvou databází. První byla využita databáze PhysioNet, která obsahovala 55 multikanálových aEKG záznamů od jednoho subjektu. Z druhé soukromé databáze bylo použito 11 pětiminutových záznamů od 8 těhotných žen. Signály z obou databází byly vzorkovány frekvencí 1 kHz. Data byla však před extrakcí fEKG převzorkována s použitím antialiasing filtru na 250 Hz. Hyperparametry sítě byly nastaveny nejprve pomocí algoritmu vyhledávání v mřížce (*Grid search*), a to s výslednou přesností 85,6 %, následně také pomocí algoritmu náhodného prohledávání (*Random search*) s výslednou přesností 87,9 %. ESN byla účinnou metodou pro odstranění mEKG z aEKG, čímž bylo získáno fEKG jak s nastavenými parametry pomocí vyhledávání v mřížce, tak prostřednictvím náhodného prohledávání, které navíc dosahovalo menšího počtu iterací [65].

Lukoševičius a Marozas (2013) [66] využili ESN pro detekci fetálních QRS (fQRS) komplexů a odhad fHR. Metoda byla testována na záznamech z databáze PhysioNet, kdy každý záznam obsahoval signál ze 4 abdominálních svodů. Vzorkovací frekvence byla 1 kHz. Síť byla nejdříve školena pomocí tréninkového souboru o 75 záznamech, u nichž byla známa poloha fQRS komplexů. ESN umožňovala detekovat fQRS komplexy i přímo v signálech bez odstranění mEKG, i když odstranění mEKG pomáhalo zlepšit výkon metody [66].

Nakonec byla ESN porovnána s dalšími technikami jako je TS a adaptivní filtry založené na LMS a RMS algoritmu využívající se pro extrakci fEKG z aEKG. Srovnáním metod se zabývali Behar a kol. (2014) v práci [67]. Porovnání metod probíhalo na reálných záznamech ze dvou databází. První databáze PhysioNet obsahovala 55 vícekanálových záznamů aEKG pořízených od jediného subjektu mezi 21.–40. týdnem těhotenství. Každý záznam byl zaznamenán pomocí 3–4 břišních svodů s vzorkovací frekvencí 1 kHz. Druhá soukromá databáze obsahovala 11 pětiminutových záznamů od 8 těhotných žen. Každý záznam byl složen z 28 břišních svodů, jednoho hrudního EKG a fEKG zaznamenaného pomocí skalpové elektrody. Taktéž byla vzorkovací frekvence signálů 1 kHz. Testováním daných metod bylo zjištěno, že mEKG je lépe odstraněno adaptivními algoritmy jako je ESN, LMS a RLS. Nevýhodou těchto algoritmů je však závislost na kvalitě EKG pořízeného z hrudníku. TS na rozdíl od adaptivních algoritmů spoléhá na přesnou detekci mateřských QRS (mQRS) komplexů. Nejlepší výkon, i když jen mírně, vykazovala ESN oproti ostatním porovnávaným metodám [67].

#### Long Short-Term Memory Network

Zhou a kol. (2021) [68] navrhli novou metodu inspirovanou LSTM sítí, která se řadí do RNN. LSTM sítě se skládají z tzv. LSTM buněk, které pracují se svým stavem neboli pamětí. Rekurentní spoje jsou nastaveny na pevnou hodnotu 1. Díky těmto vlastnostem je schopna LSTM sít si zapamatovat delší posloupnost vstupů než základní RNN [64]. Architektura v práci [68] pro extrakci fEKG byla založená na dvou fázích představující pomalou a rychlou LSTM. Cílem první fáze bylo eliminovat mEKG z aEKG, což bylo provedeno právě prostřednictvím pomalé LSTM, která sloužila pro detekci složek mEKG a její odstranění v časové oblasti. V druhé fázi byl aplikován algoritmus rychlé LSTM pro zlepšení výpočetní účinnosti. Rychlá LSTM snížila výpočetní náročnost přibližně o 50 %, aniž by došlo ke snížení výkonu. Navržená metoda byla zkoumána jak na simulovaných datech generovaných simulátorem FECGSYN, tak na reálných datech z databáze DalSy. Bylo využito 5 aEKG signálů a 3 mEKG signály se vzorkovací frekvencí 250 Hz a dobou trvání každého signálu 10 s. Navrženou metodou bylo dosaženo zvýšení SNR při eliminaci mEKG o 3,09 dB a o dalších 1,81 dB v extrahovaném fEKG [68].

# 4.4 Adaptivní neuro-fuzzy inferenční systém

ANFIS byl navržen poprvé v roce 1993 J. Jangem. Jedná se v podstatě o hybridní systém, který spojuje neuronovou síť s fuzzy systémem. Fuzzy systém umožňuje zpracovávat a vyhodnocovat i nepřesná data, ale není schopen učení jako ANN, ty však nedokážou vyhodnotit nepřesná data jako fuzzy systém. Kombinací dopředné ANN s adaptivním fuzzy inferenčních systémem (FIS) typu Sugeno byl vytvořen ANFIS, který je schopen se učit a následně vyhodnocovat skryté či nelineární závislosti. Učení systému se provádí nejčastěji hybridním učícím algoritmem, který kombinuje BP a LMS metodu [51, 55].

Nasiri a kol. (2011) [69] aplikovali ANFIS, který byl trénovaný metodou optimalizace hejnem částic (PSO). Jedná se o přírodou inspirovaný algoritmus, chováním ryb či ptáků žijících v hejnech. Využívá tedy množinu částic, kdy každá částice se skládá z vektorů, které určují její pozici a rychlost. Každá částice se následně pohybuje v prohledávacím prostoru. Na začátku je její pozice vybrána náhodně, poté se s každou iterací rychlost i pozice aktualizuje, aby byla získána pozice s nejlepším řešením pro danou částici, ale také s nejlepším řešením z globálního hlediska [70]. Takto trénovaný ANFIS byl využit pro stanovení nelineární transformace mezi mEKG z hrudních svodů a abdominálních svodů. Extrakce fEKG byla provedena následným odečtením mEKG od signálu aEKG. Algoritmus byl testován na datech simulovaných i reálných z databáze PhysioNet. Pro vyhodnocení na simulovaných datech bylo využito nejen vizuální kritérium, ale také parametr PRD (Percent Root-Mean Square Difference), který udává míru rozdílu mezi původním a nově získaným signálem neboli míru zkreslení [71]. Čím více se parametr blíží nule, tím je větší podobnost mezi signály. V této práci byla navržená metoda ANFIS s algoritmem PSO porovnávána s WT a ANFIS bez PSO. Ve výsledku byla hodnota PRD nejnižší u metody ANFIS s algoritmem PSO s hodnotou 0,4734. Na signály z databáze PhysioNet byla aplikovaná metoda ANFIS s PSO, ANFIS bez PSO, SVD, WT a ICA. Dle parametru SNR vycházeli nejlépe metody ICA a ANFIS s PSO. ANFIS s PSO však potřeboval pro výslednou extrakci fEKG menší počet zaznamenaných signálů než ICA. Další výhodou navrženého algoritmu byla jeho schopnost extrahovat fEKG také v raném období těhotenství [69].

Martinek a kol. (2016) [72] se zabývali nastavením parametrů pro ANFIS jako je počet členských funkcí (*membership function* - mf), typ celé struktury (typ mf) a počet epoch, pro docílení, co nejvyšší kvality extrakce fEKG. Pro získání fEKG pomocí ANFIS je zapotřebí jednoho abdominálního svodu s aEKG a druhého hrudního svodu s mEKG. Během procesu učení jsou přizpůsobovány parametry, dokud není dosaženo požadovaného počtu epoch anebo dokud není systém dostatečně natrénován. Výstupem ANFIS je odhadnutý mEKG z aEKG. Chybou mezi odhadnutým a referenčním mEKG z hrudního svodu je získán fEKG. Nastavení parametrů bylo provedeno v programu MATLAB pomocí syntetických dat, jelikož byl u těchto dat znám SNR. Dalším parametrem pro hodnocení byla střední kvadratická chyba (RMSE). S rostoucím počtem mf a epoch se zlepšovala kvalita filtrace. SNR bylo ovlivněno také typem mf, nejlepších výsledků extrakce bylo provedeno pomocí Gaussovské a Zvonovité struktury. Z časového hlediska potřebného k výpočtu, bylo lepší využít 6 mf a 10 nebo 20 epoch, kdy nastavení parametrů bylo dostatečné pro optimální extrakci [72].

V další práci Panigrahy a Sahu (2017) [73] navrhli pětistupňový systém pro extrakci fEKG z jednosvodového aEKG. Nejprve byl odstraněn šum z aEKG. Následně byla využita rozšířena KF pro odhad mEKG z aEKG. Algoritmem využívající diferenciální evoluci (DE) byly vybrány optimalizované parametry mEKG, které byly použity pro KF. Jelikož se jedná o nelineární vztah, byl pro odhad mEKG v signálu aEKG využit ANFIS. Vstupem ANFIS byly výstupy KF a předem zpracované aEKG. Fetální EKG bylo dáno odečtením výstupu ANFIS od předem zpracovaného aEKG. Systém byl aplikován na data ze dvou databází. První databáze se skládala z 55 vícekanálových záznamů EKG, přičemž první dva signály v každém záznamu byly mEKG a zbývající aEKG. Vzorkovací frekvence byla 1 kHz. Senzitivita navrženého systému byla při použití dat z této databáze 94,21 %, přesnost byla 90,66 % a pozitivní prediktivní hodnota (PPV) 96,05 %. Druhá použitá databáze byla PhysioNet, která obsahovala 75 vícekanálových záznamů, kdy každý záznam se skládal ze 4 jednominutových aEKG. Vzorkovací frekvence byla taktéž 1 kHz. Sensitivita byla v tomto případě 91,47 %, přesnost 84,89 % a PPV 92,18 % [73].

## 4.5 Konvoluční neuronové sítě

CNN je dopředná ANN, která se skládá z konvolučních vrstev, sdružených vrstev (*pooling layers*) a plně propojené vrstvy (*full-connected layer*). Taktéž bývá převážně trénována prostřednictvím BP algoritmu. Na rozdíl od ANN však umožňuje CNN extrakci naučených příznaků rovnou z nezpracovaných dat pro maximalizování přesnosti klasifikace, což ale na druhou stranu obvykle vyžaduje vyšší výpočetní náročnost. Původní využití CNN bylo výhradně pro zpracování dvourozměrných (2D) dat, proto je také označována jako 2D CNN. Využití této CNN pro zpracování jednorozměrných (1D) signálů vyžaduje konverzi z 1D na 2D. Z toho plynou již výše zmíněné problémy s vysokou výpočetní náročností, a navíc 2D CNN vyžaduje velké množství trénovacích dat. Řešením je použití 1D CNN, která se začala objevovat v posledních letech. Výpočetní náročnost 1D CNN je výrazně nižší než ve srovnání s 2D CNN za ekvivalentních podmínek, také tyto sítě využívají méně skrytých vrstev a jsou tedy vhodné pro výpočty v reálném čase bez potřeby speciálního hardwaru. Jako přenosová funkce pro CNN byla obzvlášť kdysi využita sigmoida nebo hyperbolický tangens, dnes se již častěji využívá funkce ReLU [74].

Lo a Tsai (2018) [75] využívali 2D CNN pro detekci fEKG z vícekanálového aEKG signálu, které byly nejprve zpracovány krátkodobou Fourierovou transformací (STFT) pro získání časově-frekvenční reprezentace dat. Takto zpracovaná data byla přivedena na vstup CNN, která se skládala ze 2 konvolučních vrstev, 2 sdružených vrstev a 1 plně propojené vrstvy. Použité signály aEKG byly poskytnuty z databáze PhysioNet. Každý záznam obsahoval 4 aEKG a jeden referenční signál fEKG získaný skalpovou elektrodou z hlavičky plodu. Vzorkovací frekvence byla 1 kHz. Přesnější detekci fEKG vykazovala 2D CNN v porovnání s metodou k-NN, která je popsána níže v kap. 4.6.2 [75].

Fotiadou a Vullings (2020) [76] navrhli hlubokou CNN kodér-dekodér pro odstranění zbývajícího šumu v fEKG získaného z vícekanálového aEKG, poté co z něj bylo potlačeno mEKG. Navrhovaná CNN se skládala z kodéru představující 8 konvolučních vrstev a dekodéru složených z 8 symetricky transponovaných konvolučních vrstev. Konvoluční vrstvy sloužily pro extrakci znaků fEKG a eliminaci šumu. Transponované konvoluční vrstvy byly použity pro obnovu detailů v signálu. Síť byla trénována na simulovaných signálech fEKG a ověřena na reálných datech ze dvou databází. První soukromá databáze obsahovala 462 šestikanálových záznamů aEKG mezi 18. až 42. týdnem těhotenství. Pro vyhodnocení navržené sítě byly využity pouze 4 kanály. Vzorkovací frekvence signálů byla 500 Hz. Druhá použitá databáze byla PhysioNet se čtyřkanálovými záznamy aEKG mezi 38. až 41. týden těhotenství. Každý záznam obsahoval 4 aEKG a 1 referenční signál fEKG ze skalpové elektrody. Signály jsou vzorkovány s frekvencí 1 kHz. Navržená CNN byla schopna kombinovat vstupní kanály a poskytovat tak na výstupu signál fEKG se zlepšeným SNR. Průměrné zlepšení na simulovaných datech se vstupním SNR v rozmezí -20 až 20 dB činilo 9,50 dB. Využití vícekanálového signálu pro navrženou CNN vykazovalo vyšší zlepšení SNR výstupního signálu než při využití pouze jednokanálového vstupu [76].

V další práci od Fotiadou a kol. (2021) [77] byla využita CNN s rozšířeným počátkem v kombinaci s LSTM pro přímé určení fHR z NI-fEKG. Síť je schopna zachytit krátkodobé i dlouhodobé časové vzorce fHR. CNN se skládala ze 6 konvolučních vrstev, které sloužily pro extrakci znaků fEKG a tyto znaky byly přivedeny do sítě LSTM, která byla zodpovědná za odhad fHR. Pro zvýšení spolehlivosti metody byl použit samostatný klasifikátor založený na CNN, který odhaduje přesnost detekované fHR. Tento klasifikátor byl vyvinut z důvodu nepřesných odhadů fHR, které se vyskytovaly u některých případů v druhé době porodní. Data pro otestování navržené metody pocházela ze soukromé databáze, která obsahovala 28 záznamů aEKG zaznamenaných pomocí 4 elektrod během porodu se vzorkovací frekvencí 500 Hz a z databáze PhysioNet, která se skládala ze 75 záznamů aEKG se vzorkovací frekvencí 1 kHz. Shoda určené fHR dle navržené metody byla u souboru dat ze soukromé databáze 97,30 % a u signálů z databáze PhysioNet 99,60 % [77].

#### **Octave CNN**

*Octave* CNN (OctConv) poprvé použili Chen a kol. (2019) [78] pro snížení prostorové redundance u 2D CNN, čímž bylo sníženo i výpočetní a paměťové náročnosti. CNN s OctConv provede konvoluci a výslednou mapu charakteristických znaků rozloží na znaky s různou frekvenční informací. Vytvoří se tedy nové vysokofrekvenční a nízkofrekvenční příznakové mapy, které se rozdělují do různých skupin. Nízkofrekvenční informace lze následně snížit prostřednictvím sdílení informací mezi sousedními místy, čímž dojde i ke snížení redundance [78].

Systémem využívajícím OctConv se zabývali například Vo a kol. (2020) [79]. Konkrétně se jednalo o reziduální síť (ResNet), což je typ CNN, která umožňuje obejít určité vrstvy a tím je optimalizována rychlost učení. Navíc je vhodná pro sítě s velkou hloubkou, které se potýkají s postupným vytrácením signálu, kdy obnova signálu je u ResNet vyřešena právě pomocí vynechání určitých částí [80]. ResNet využívala 1D OctConv pro detekci fQRS komplexů z vícekanálového aEKG. Jako přenosová funkce byla použita ReLU. Navržená síť byla testována na záznamech z databáze PhysioNet. Celkem bylo využito 68 záznamů s čtyřsvodovým aEKG. Vzorkovací frekvence byla 1 kHz. K datům byl navíc přidán šum pro simulaci v reálných podmínkách. Navržená metoda byla srovnána s CNN z dřívějších prací. Přesnost CNN s OctConv byla 91,82 %, běžná CNN navržená v práci [81] měla přesnost 75,33 % a CNN navržená v práci [82] měla sice vyšší přesnost 92,77 % než metoda s OctConv, ale bylo u ni nutné nastavit parametry co nejoptimálněji pro konkrétní úlohu [79].

# 4.6 Metody strojového učení

Strojové učení spadá do oblasti umělé inteligence. Jedná se o algoritmy využívající metody učení pro řešení určitého problému, proto mezi metody strojového učení lze zařadit i ANN (viz Kap. 4.2 a 4.3). Pod ANN patří například metody hlubokého učení (*deep learning*), kdy jsou v podstatě využity neuronové sítě s větším počtem vrstev a učení sítě probíhá od vstupních po výstupní vrstvy neboli v tomto případě směrem k hlubším vrstvám. Mezi sítě využívající hlubokého učení lze zařadit například RNN, CNN a tzv. autoenkodéry. Autoenkodéry mívají vstupní a výstupní vrstvy o stejných rozměrech, skryté vrstvy o rozměrech menších. Většinou se uplatňují při kompresi dat a jejich následné obnově [76, 83].

Další metodou strojového učení mohou být Bayesovské sítě (BN), což jsou acyklicky orientované grafy, které určují pravděpodobnostní závislost mezi uzly prostřednictvím křivek. Uzly představují náhodnou veličinu. Pokud z uzlu vycházejí křivky do jiných uzlů, je uzel nazýván rodičem a přiřazuje pravděpodobnostní distribuci uzlu, který je s rodičem spojen. Jednodušším používaným klasifikátorem bývá tzv. *Naive Bayes* (NB), který má jeden nadřazený klasifikační uzel všem ostatním uzlům. Jedná se o velmi účinný klasifikátor, který nevyžaduje žádný postup učení [84, 85]. Také metodu podpůrných vektorů (SVM) popsanou v kap. 4.6.1 a metodu k-nejbližších sousedů (k-NN) popsanou v kap. 4.6.2 lze zařadit mezi klasifikátory patřící do metod strojového učení.

## 4.6.1 Podpůrné vektory

Metoda SVM slouží pro klasifikaci dat prostřednictvím nalezení optimální nadroviny, která data rozděluje do vhodných tříd. Vzdálenost nadroviny od jednotlivých tříd je co největší a určuje tzv. pásmo necitlivosti nebo také hraničí pásmo. SVM využívá jádrovou transformaci (*kernel transformation*), která umožňuje přenést data do vyšší dimenze. Vytváří se vícedimenzionální prostor, ve kterém původně lineárně neseparovatelná data, lze nyní již rozdělit lineárně [83, 86].

SVM mohou být taktéž využity pro extrakci fEKG jako ANN. Tímto tématem se zabývali Fu a kol. (2015) [87]. SVM byla využita pro co nejoptimálnější odhad mEKG z aEKG. Odečtením odhadnutého mEKG od aEKG bylo získáno fEKG. Pro trénování i testování samotné extrakce byla použita reálná data z databáze DalSy, která obsahovala 3 mEKG a 5 aEKG záznamů se vzorkovací frekvencí 250 Hz. Na tyto záznamy byla aplikována i ANN s algoritmem BP pro srovnání s navrženou metodou. Srovnání bylo provedeno jak vizuálně, tak pomocí SNR. Extrakce fEKG pomocí SVM vykazovala vyšší SNR (9,23 dB) a mnohem nižší čas pro získání výsledné extrakce (0,80 s) než u ANN (SNR 5,45 dB a čas 19,67 s) [87]. Dalším využitím metody SVM může být například detekce R-kmitů fQRS komplexů, čímž se zabývali Liao a kol. (2018) [88]. Pro extrakci fEKG z aEKG byla využita WT. Metoda SVM byla aplikována po extrakci fEKG, aby lokalizovala fQRS komplexy. Použité signály aEKG pocházely z databáze PhysioNet. Z celkových 75 záznamů bylo v této práci použito 69 záznamů se vzorkovací frekvencí 1 kHz. Klasifikace fQRS komplexů pomocí SVM byla porovnána s metodou k-NN a NB. Metoda SVM vykazovala vyšší senzitivitu (68,47 %), přesnost (84,53 %) i PPV (89,60 %) ve srovnání s k-NN a BN (senzitivita 30,26 % a 7,67 %; přesnost 70,98 % a 59,38 %; PPV 87,47 % a 40,35 %) [88].

### 4.6.2 Metoda k-nejbližších sousedů

Taktéž jako metoda SVM je i k-NN klasifikační metodou. Cílem je přiřazení nových dat na základě podobnosti, k již klasifikovaným datům. Nejčastěji jsou data klasifikována na základě euklidovské vzdálenosti. Nejedná se o parametrickou metodu, která by vyžadovala určování parametrů a nemusí se tedy trénovat. Potřebuje však uchovat klasifikovaná data, což může být omezením při klasifikaci velkého souboru dat [83, 89].

Metoda k-NN může být využita pro detekci R-kmitů v signálu fEKG. Tímto problémem se zabývali například Delgado a kol. (2015) [90], kteří nejdříve rozdělili signál aEKG na 250ms oddíly. Každý oddíl byl označen podle toho, zda se v něm nachází či nenachází fQRS komplex anebo mQRS komplex pomocí WT a PCA. Metody strojového učení jako je k-NN, SVM a BN byly aplikovány pro samotnou detekci fQRS komplexů. Navržená metoda byla aplikována na 75 záznamů čtyřsvodového aEKG se vzorkovací frekvencí 1 kHz z databáze PhysioNet. Ve výsledku poskytovaly nejlepší detekci fQRS komplexů metody k-NN a SVM, které dosáhly přesnosti 89,59 % resp. 89,19 %. Přestože k-NN dosáhla mírně lepších výsledků, metoda SVM je méně časově náročnější [90].

Zhong a kol. (2018) [81] také detekovali fQRS komplexy v signálu NI-fEKG bez odstranění mEKG, v tomto případě pomocí metod CNN, k-NN, NB a SVM. Všechny metody byly ověřeny na datech z databáze PhysioNet. Celkem bylo použito 68 záznamů, kdy každý záznam obsahoval signál aEKG ze 4 svodů. Vzorkovací frekvence byla 1 kHz. Experimenty byly prováděny pomocí programu MATLAB. Nejvyšší přesnost detekce, která byla 77,38 %, poskytovala metoda CNN. Metoda k-NN detekovala fQRS komplexy s přesností 68,76 %, NB s přesností 55,52 % a SVM s přesností 70,65 % [81].

# 5 POPIS POUŽITÝCH METOD PRO EXTRAKCI FEKG

Z uvedené rešerše je patrné, že pro problém extrakce fEKG z aEKG a následnou detekci R-kmitů vzniklo spoustu prací zabývajících se různými metodami založených na ANN. Pro tuto práci byla vybrána metoda ADALINE, jelikož je jednou z nejjednodušších a časově méně náročnějších metod. Jedná se však o jednovrstvou síť, proto byly také využity sítě vícevrstvé jak dopředné, tak rekurentní (konkrétně síť ESN). RNN dokáží pracovat díky zpětné vazbě i s časovým kontextem, proto se jeví lépe pro řešení složitějších úloh. V poslední době také bývají velmi využívány hybridní metody spojující více metod, ať už neadaptivních či adaptivních. Velmi využívanou hybridní metodou pro extrakci fEKG je ANFIS, který kombinuje dopřednou ANN s fuzzy systémem.

Důležitým krokem pro správnou extrakci fEKG a následnou detekci R-kmitů je předzpracování. Signály aEKG byly nejdříve vyfiltrovány FIR filtrem a notch filtrem. Jelikož adaptivní metody, mezi které patří ANN, využívají většinou kombinovaného zapojení elektrod, ze kterého je získán jak signál aEKG, tak i mEKG, byla v rámci předzpracování zvolena metoda ICA. Tato metoda extrahuje z aEKG signálů komponentu mEKG a komponentu tvořenou mEKG a fEKG. V prvním případě tyto komponenty slouží jako vstupy do využitých metod, kterými byla metoda ADALINE, ANFIS a ESN. Ve druhém případě jsou komponenty využity jako vstupy do dopředné ANN a výstup z dopředné ANN je využit jako vstup do zmíněných metod. Použité metody jsou popsány níže.

### 5.1 Analýza nezávislých komponent

Jedná se o metodu separace signálů, která hledá statisticky nezávislé komponenty v původním signálu. Pro využití metody by signál neměl mít Gaussovské rozložení hustoty pravděpodobnosti. Obecným příkladem aplikace ICA je tzv. Coctail-party problém, který je popsán situací na večírku, kdy dva lidé při rozhovoru musejí odseparovat hlasy ostatních lidí, aby se navzájem slyšeli. Tento problém se dá také aplikovat na zpracování NI-fEKG, kdy je pomocí abdominálních elektrod získáno aEKG. V tomto případě byly uvažovány dvě elektrody poskytující dva aEKG signály označené jako  $x_1(t)$  a  $x_2(t)$ , které jsou dány součtem mateřské a fetální komponenty  $s_1(t)$  a  $s_2(t)$ . Rovnice (3) a (4) představují výpočet těchto dvou abdominálních signálů.

$$x_1 = a_{11}s_1 + a_{12}s_2, (3)$$

$$x_2 = a_{21}s_1 + a_{22}s_2, (4)$$

kde parametry *a* nejsou známy. Řešení předpokládá statistickou nezávislost komponent  $s_1(t)$  a  $s_2(t)$ , což je v případě mateřské a fetální komponenty splněno [91, 92].

Jelikož při snímání EKG pomocí abdominálních elektrod nelze přímo změřit a získat jen mateřskou či fetální komponentu jsou tyto nezávislé komponenty skrytými proměnnými a jsou dány vektorem  $\vec{s}$ . Z měřených signálů, které jsou dány vektorem  $\vec{x}$ , je tedy nutné odhadnout jak vektor  $\vec{s}$ , tak směšovací matici **A**. Výpočet vektoru  $\vec{x}$  je dán rovnicí (5):

$$\vec{x} = \mathbf{A} \cdot \vec{s}. \tag{5}$$

Za předpokladu, že odhadnutá matice  $\mathbf{A}$  je čtvercová matice, lze nezávislé komponenty získat pomocí inverzní matice  $\mathbf{W}$ , jak je uvedeno v rovnici (6) [91, 92]:

$$\vec{s} = \mathbf{W} \cdot \vec{x}.$$
 (6)

Před samotnou aplikací metody je vhodné provést centrování a bělení signálu. Centrováním je získán vektor  $\vec{x}$  s nulovou střední hodnotou, což je dosaženo odečtením střední hodnoty  $\vec{x}$  od vektoru  $\vec{x}$ . Po této operaci bude mít taktéž vektor  $\vec{s}$  nulovou střední hodnotu. Následuje bělení signálu, kdy je získán nový vektor  $\vec{x}$  lineární transformací vektoru  $\vec{x}$ . Nově vzniklý vektor je vybělený, má nekorelované komponenty a jejich rozptyl je jednotkový. Kovariační matice je poté dána jako jednotková matice (7):

$$E\{\vec{\tilde{x}}\cdot\vec{\tilde{x}}^T\} = \mathbf{I}.$$
(7)

Pro bělení se velmi využívá metoda vlastní hodnoty rozkladu (EVD) pro kovariační matici, což představuje rovnice (8):

$$E\{\vec{\tilde{x}}\cdot\vec{\tilde{x}}^T\} = \mathbf{E}\mathbf{D}\mathbf{E}^T,\tag{8}$$

kde ortogonální matice vlastních vektorů je označena jako **E** a diagonální matice vlastních hodnot jako **D**. Bělením dochází k transformaci směšovací matice **A** na novou matici  $\widetilde{\mathbf{A}}$ , jak je vyjádřeno v rovnici (9):

$$\vec{\tilde{x}} = \mathbf{E}\mathbf{D}^{-\frac{1}{2}}\mathbf{E}^T\mathbf{A}\vec{s} = \widetilde{\mathbf{A}}\vec{s}.$$
(9)

Výhodou bělení je redukce parametrů, kterých pro matici  $\widetilde{\mathbf{A}}$  je n(n-1)/2, na rozdíl od matice  $\mathbf{A}$ , pro kterou je nutné odhadnout  $n^2$  parametrů [91, 92].

Pro samotný odhad nezávislých komponent v signálu je využíván výpočet špičatosti anebo je využita negativní entropie (negentropy). Je-li vypočtená hodnota špičatosti kladná, proměnné jsou označovány jako supergaussovské a jejich hustota rozdělení je špičatější než hustota normálního rozdělení. Proměnné, jejichž špičatost je záporná, jsou označovány jako subgaussovké a jejich hustota rozdělení je plošší než u normálního rozdělení. Výpočet špičatosti je uveden v následující rovnici (10):

$$kurt(y) = E(y^4) - 3E(y^2)^2.$$
 (10)

Výpočet entropie  $H(\vec{y})$  náhodného vektoru  $\vec{y}$  s hustotou pravděpodobnosti  $f(\vec{y})$  je dán rovnicí (11). Entropie udává míru náhodnosti daných proměnných. Jestliže proměnné pocházejí z dat, která lze jasně koncentrovat na jistých hodnotách, jejich hodnota entropie dosahuje nízkých hodnot. Proměnné z normálního (gaussovského) rozdělení mají entropii naopak vysokou. Pro získání nenormality, která je pro gaussovské proměnné nulová, se využívá negativní entropie. Negativní entropie, jejíž výpočet udává rovnice (12), dosahuje tedy vysokých hodnot pro proměnné nepocházející z normálního rozdělení.

$$H(\vec{y}) = -\int f(\vec{y}) \log(f(\vec{y})) \, dy. \tag{11}$$

$$J(\vec{y}) = H\left(\vec{y}_{gauss}\right) - H(\vec{y}),\tag{12}$$

kde  $\vec{y}_{gauss}$  představuje náhodný vektor Gaussovského rozdělení se stejnou kovariační maticí jako vektor  $\vec{y}$ . Pro odhad negativní entropie se využívá aproximace založené na výpočtu maximální negativní entropie dle vztahu (13):

$$J(\vec{y}) \approx \sum_{i=1}^{p} k_i [E\{G_i(y)\} - E\{G_i(v)\}]^2,$$
(13)

kde jako  $k_i$  je označena kladná konstanta, v je proměnná z Gaussovského rozdělení dat, má střední hodnotu nulovou a jednotkový rozptyl. Proměnná y má taktéž nulovou střední hodnotu i jednotkový rozptyl a  $G_i$  představuje nekvadratické funkce [91, 92].

V poslední době bývá nejčastěji využívanou metodou rychlá analýza nezávislých komponent neboli FastICA, která slouží pro hledání maxima v datech s negaussovským rozdělením  $\vec{w}^T \vec{x}$ . Maximum lze také aproximačně odvodit s využitím Newtonovy iterační metody. Derivací nekvadratické funkce *G* je získáno  $g_1$  (14) a  $g_2$  (15):

$$g_1(u) = \tan h(a_1 u), \tag{14}$$

$$g_2(u) = -uex \, p\left(-\frac{u^2}{2}\right),\tag{15}$$

kde  $a_1$  je konstanta volena v rozmezí od 1 do 2. Základní kroky algoritmu FastICA jsou popsány dále dle [91, 92].

**První krok**: stanovení náhodného vektoru počátečních vah  $\vec{w}$ .

Druhý krok: výpočet špičatosti dle rovnice (16), případně negativní entropie.

$$\vec{w}^{+} = E\{\vec{x}g(\vec{w}^{T}\vec{x})\} - E\{\vec{x}g'(\vec{w}^{T}\vec{x})\}\vec{w}.$$
(16)

Třetí krok: normování dle rovnice (17):

$$\vec{w} = \frac{\vec{w}^+}{\|\vec{w}^+\|}.$$
(17)

Čtvrtý krok: jestliže není splněno kritérium konvergence, kdy skalární součin staré a nové hodnoty  $\vec{w}$  je menší než stanovené kritérium konvergence, algoritmus se opakuje od druhého kroku. Algoritmus může být také ukončen, jestliže je dosaženo stanoveného počtu iterací.

#### 5.2 Dopředná vícevrstvá ANN

Dopředná vícevrstvá ANN vzniká spojením více neuronů, které jsou uspořádány do vrstev. Postup dat probíhá postupně od vstupní vrstvy přes skryté vrstvy, kdy data bývají zpracována nejdříve v první skryté vrstvě a výsledky z této vrstvy jsou předány do další skryté vrstvy pro další zpracování. Po skrytých vrstvách následuje výstupní vrstva, která má na výstupu výsledek řešení poskytnutý sítí. Každý neuron z nižší vrstvy je kompletně propojen s neurony z vyšších vrstev. Struktura vícevrstvé dopředné ANN s jednou skrytou vrstvou je zobrazena na Obr. 16.

Výstupy jednotlivých neuronů jsou dány rovnicí (2), která vyjadřuje výpočet výstupu perceptronu. Jako aktivační funkce se u dopředných vícevrstvých sítí využívá funkce spojitá, diferencovatelná amonotónně neklesající. Nejčastěji využívanou aktivační funkcí je sigmoida, jejíž výpočet je definován následujícím vztahem (18) anebo hyperbolický tangens definován vztahem (19):

$$f(\varphi) = \frac{1}{1 + e^{-S\varphi}},\tag{18}$$

$$f(\varphi) = \frac{1 - e^{-S\varphi}}{1 + e^{-S\varphi}}.$$
(19)

Strmost funkce je značena jako S a vnitřní potenciál neuronu jako  $\varphi$  [51, 91, 93, 94].



Obr. 16: Struktura vícevrstvé ANN s jednou skrytou vrstvou [91].

Základní schopností ANN je učení, kdy dochází k úpravě jednotlivých vah. Nejčastěji je dopředná síť učena pomocí učitele algoritmem BP, kdy jsou váhy upravovány postupně od výstupní vrstvy až k vrstvě vstupní. Jednotlivé kroky algoritmu BP pro vícevrstvou ANN jsou popsány následovně dle [53, 94].

**První krok:** nejdříve je nutná inicializace vah, kdy jsou váhy nastaveny náhodně na hodnoty v rozsahu <-1; 1>.

Druhý krok: jestliže není splněna podmínka pro ukončení učení sítě, opakuje se třetí až osmý krok.

**Třetí krok**: jestliže nebyly předloženy veškeré vzory z trénovací množiny, opakuje se čtvrtý až sedmý krok.

**Čtvrtý krok**: aktivace neuronů ve vstupní vrstvě, která slouží pouze pro předávání vstupních dat do první skryté vrstvy. Z trénovací množiny je vybrán vzor, který je umístěn na vstup sítě. Data jsou dále zpracována po vrstvách směrem od vstupní vrstvy k výstupní vrstvě a pro jednotlivé neurony jsou počítány vnitřní potenciály. Výpočet vnitřních potenciálů neuronů skryté vrstvy  $h_j$  je dán následujícími rovnicemi (20) a (21):

$$h_j(in) = w_{0j} + \sum_{i=1}^n x_i w_{ij}$$
, (20)

$$h_j = f[h_j(in)]. \tag{21}$$

Výpočet vnitřních potenciálů neuronů výstupní vrstvy  $y_k$  je dán rovnicemi (22) a (23):

$$y_k(in) = w_{0k} + \sum_{j=1}^p h_j w_{jk}$$
, (22)

$$y_k = f[y_k(in)]. \tag{23}$$

**Pátý krok**: každému neuronu ve výstupní vrstvě je určena očekávaná hodnota výstupu pro daný tréninkový vzor. Vztahem (24) je vypočteno  $\delta_k$ , což je částečná korekce vah, které jsou dány chybou spojení mezi neurony ze skryté vrstvy a neurony z výstupní vrstvy. Z vypočteného  $\delta_k$  lze určit korekci vah (25) i korekci prahů (26).

$$\delta_k = (d_k - y_k) f'[y_k(in)], \tag{24}$$

$$\Delta w_{jk} = \eta \delta_k h_j, \tag{25}$$

$$\Delta w_{0k} = \eta \delta_k , \qquad (26)$$

kde  $d_k$  je požadovaný výstup a  $\eta$  je koeficient učení. Také každému neuronu ve skryté vrstvě je určena hodnota  $\delta_j(in)$ , která je dána součtem jeho vstupů, tedy neuronů v následující vrstvě (v tomto případě jsou uvažovány neurony z výstupní vrstvy) (27). Vynásobením  $\delta_j(in)$  s derivovanou aktivační funkcí je získána částečná korekce vah  $\delta_j$ , která je dána chybou spojení mezi neurony předchozí vrstvy, v tomto případě se jedná o vrstvu vstupní, a skryté vrstvy (28). Dále lze vypočíst váhovou korekci (29) a korekci prahů (30).

$$\delta_j(in) = \sum_{k=1}^m \delta_k w_{jk},\tag{27}$$

$$\delta_j = \delta_j(in) f'[h_j(in)], \tag{28}$$

$$\Delta w_{ij} = \eta \delta_j x_i, \tag{29}$$

$$\Delta w_{0j} = \eta \delta_j. \tag{30}$$

**Šestý krok**: výpočet chyby sítě, kdy pomocí BP algoritmu je minimalizována chybová funkce na základě gradientního sestupu. Parciální chyba sítě  $E_l$  pro l. tréninkový vzor je definována pomocí následující rovnice (31):

$$E_l = \frac{1}{2} \sum_{k=1}^{m} (y_k - d_k)^2,$$
(31)

kde m představuje počet neuronů výstupní vrstvy. Celková chyba sítě je dána součtem parciálních chyb.

Sedmý krok: aktualizace vah a prahů pro každý neuron ve výstupní vrstvě (32) i skryté vrstvě (33).

$$w_{jk}(new) = w_{jk}(old) + \Delta w_{jk}, \qquad (32)$$

$$w_{ij}(new) = w_{ij}(old) + \Delta w_{ij}, \qquad (33)$$

kde  $w_{jk}(new)$  představuje aktualizované váhové hodnoty pro neurony ve výstupní vrstvě a  $w_{ij}(new)$  představuje aktualizované váhové hodnoty pro neurony ve skryté vrstvě.

**Osmý krok**: ukončení učení dopředné vícevrstvé ANN porovnáním celkové chyby sítě se zvolenou celkovou chybou. Učení může být také ukončeno po provedení stanoveného počtu epoch.

Pro každý vzor z tréninkové množiny nejdříve proběhne čtvrtý krok (tzv. *feedforward*), kdy jsou data zpracována od vstupní vrstvy po výstupní. Jelikož je síť učena s učitelem, jsou ji poskytnuty informace o požadovaném výstupu, ze kterých je možno zjistit chybu mezi výstupem sítě a požadovaným výstupem. Výpočtem parciální derivace chybové funkce, se chyba šíří zpět od výstupní vrstvy ke vstupní vrstvě, což představuje pátý a šestý krok (*backpropagation*). Zpětný výpočet probíhá po vrstvách sekvenčně a v rámci jedné vrstvy paralelně. Sedmý krok slouží pro následnou aktualizaci vah a prahů [53].

### 5.3 ADALINE

ADALINE je stejně jako perceptron jednovrstvou neuronovou sítí, kdy výstup neuronu je dán taktéž jako u perceptronu rovnicí (2). Na rozdíl od perceptronu má však lineární aktivační funkci a zpětnovazebnou smyčku. Podobně jako perceptron má jeden výstup a více vstupů, ale jeden vstup je navíc pro stanovení požadované odpovědi systému. Struktura ADALINE je zobrazena na Obr. 17. Učení ADALINE probíhá úpravou vah, které jsou nastavovány nejčastěji pomocí metody nejmenších čtverců (LMS algoritmu), někdy bývá označeno jako W-H pravidlo učení či delta učící pravidlo. Výstup sítě by měl co nejvíce odpovídat požadované odpovědi [55, 95].



Obr. 17: Struktura ADALINE [95].

Algoritmus shrnující učení ADALINE je popsán následně dle [51, 53].

**První krok**: je totožný s prvním krokem algoritmu popsaným pro vícevrstvou dopřednou ANN, kdy dochází nejdříve k inicializaci vah, hodnota vah je malá a náhodná.

Druhý krok: pokud není splněna podmínka pro ukončení, opakují se následující kroky tři až šest.

Třetí krok: aktivace vstupních neuronů podle vzorů z trénovací množiny.

Čtvrtý krok: výpočet hodnoty na výstupu sítě y, která je dána následujícím vztahem (34):

$$y = w_0 + \sum_i x_i w_i , \qquad (34)$$

kde  $w_0$  je práh,  $x_i$  udává vstupy a  $w_i$  váhy.

**Pátý krok**: výpočet odhadované chyby e(n) (35):

$$e(n) = d(n) - y(n),$$
 (35)

kde *d* je požadovaná odpověď.

Šestý krok: aktualizace vah  $w_i(new)$  a prahu  $w_0(new)$  podle následujících vztahů (36) a (37):

$$w_i(new) = w_i(old) + \mu e x_i , \qquad (36)$$

$$w_0(new) = w_0(old) + \mu e,$$
 (37)

kde  $\mu$  udává krok učení. Pokud je zvolen příliš malý krok, bude mít algoritmus vyšší časovou náročnost pro nalezení optimálního řešení. Pokud je  $\mu$  zvoleno příliš velké, adaptační algoritmus bude nestabilní, nebude konvergovat.

**Sedmý krok**: ukončení učení metody ADALINE, jestliže je nalezena hodnota menší než maximální chyba sítě. Algoritmus je nastaven, aby minimalizoval střední kvadratickou chybu.

#### 5.4 ANFIS

Jedná se o hybridní systém, který spojuje dopřednou neuronovou síť s fuzzy systémem typu Takagi-Sugeno. Výhodou tohoto hybridního systému je jeho schopnost učit se, což je dovednost získaná neuronovou sítí a zároveň je díky fuzzy systému schopen zpracovat a vyhodnocovat i nepřesná data. ANFIS se skládá z pěti propojených vrstev FIS, které jsou vnitřně realizovány neuronovou sítí. Základní architektura je vyobrazena na Obr. 18, kde vstupují do systému dva vstupy x, y a je dán jeden výstup z. Uvedený FIS je typu Takagi-Sugeno, jehož dvě znalostní pravidla  $R_1$  a  $R_2$  ve formě IF (jestliže)-THEN (pak) jsou dány vztahy (38) a (39):

$$R_1: IF (x \text{ is } A_1) \text{ and } (y \text{ is } B_1) THEN (z_1 = p_1 x + q_1 y + r_1),$$
 (38)

$$R_2$$
: IF (x is  $A_2$ ) and (y is  $B_2$ ) THEN ( $z_2 = p_2 x + q_2 y + r_2$ ). (39)



Obr. 18: Struktura ANFIS s dvěma vstupy a jedním výstupem [51].

V následující části jsou popsány dle [51, 55, 91] jednotlivé vrstvy, které tvoří strukturu ANFIS.

**První vrstva**: neboli vstupní vrstva se skládá z adaptivních uzlů, kdy každý uzel představuje jazykovou proměnnou. Na Obr. 18 mají adaptivní uzly podobu čtverců. Úkolem této vrstvy je provést fuzzifikaci vstupních proměnných, kde míra příslušnosti  $O_i^1$  vstupní proměnné x k příslušné jazykové hodnotě  $A_i$  je dána následujícím vztahem (40):

$$O_i^1 = \mu_{Ai}(x),$$
 (40)

kde  $\mu_{Ai}$  je funkce příslušnosti jazykové hodnoty  $A_i$  a x je vstup i. uzlu. Tato rovnice udává funkci pro každý i. uzel ve vrstvě. Učením jsou adaptovány parametry funkcí příslušnosti. Nejčastěji se pro extrakci fEKG využívají funkce příslušnosti Gaussovské nebo zvonové.

**Druhá vrstva**: bývá označena jako pravidlová vrstva a tvoří ji pouze neadaptivní uzly, ty jsou na Obr. 18 zobrazeny jako kružnice. Vstupem do těchto uzlů jsou signály z předchozí vrstvy a výstupem je vypočtená váha (síla) pravidla *w* podle následujícího vztahu (41):

$$w_i = \mu_{Ai}(x) \cdot \mu_{Bi}(y). \tag{41}$$

Pro výše uvedený příklad se dvěma vstupy, nabývá *i* hodnot 1 a 2. Pomocí neadaptivních uzlů jsou tedy násobeny signály z předchozí vrstvy, čímž je dána váha pravidel. Jednotlivé uzly odpovídají jednomu podmíněnému pravidlu.

**Třetí vrstva**: či normalizační vrstva se skládá taktéž jako vrstva druhá z neadaptivních uzlů. Výstupem uzlů v této vrstvě je výpočet normalizované váhy (síly) pravidla  $\overline{w}_i$ , která je získána z poměru vah jednotlivých pravidel vzhledem k součtu všech vah pravidel. Poměr je vyjádřen pomocí rovnice (42):

$$\overline{w}_i = \frac{w_i}{w_1 + w_2}.\tag{42}$$

Čtvrtá vrstva: je defuzzifikační a tvoří ji adaptivní uzly s lineární nebo konstantní přenosovou funkcí. Vstupem do adaptivního uzlu je korespondující výstup z normalizační vrstvy a také vstupní proměnné systému x a y. Výstupem je výpočet váhového konsekventu, který je dán následovně (43):

$$\overline{w}_i f_i = \overline{w}_i (p_i x + q_i y + r_i), \tag{43}$$

kde p, q a r udávají parametry konsekventu.

**Pátá vrstva**: neboli sumační vrstva je poslední vrstvou a výsledkem této vrstvy je celkový výstup ANFIS. Je dána pouze jediným neadaptivním uzlem, který provádí součet výstupů z předchozí vrstvy podle následující rovnice (44):

$$\sum_{i} \overline{w}_{i} f_{i} = \frac{\sum_{i} \overline{w}_{i} f_{i}}{\sum_{i} w_{i}}.$$
(44)

Pro učení využívá ANFIS nejčastěji tzv. hybridní algoritmus, který je kombinací LMS algoritmu a algoritmu BP. Algoritmus BP optimalizuje parametry antecedentu v první vrstvě, parametry konsekventu ve čtvrté vrstvě jsou optimalizovány pomocí LMS algoritmu. Hybridní algoritmus může být rozdělen na dopředný a zpětný chod. Podle nastaveného počtu epoch dochází k pravidelnému opakování obou chodů učícího algoritmu [55, 91].

Nejdříve se uplatňuje dopředný chod, kdy jsou na vstupy metody ANFIS přivedeny vzory z tréninkové množiny, které jsou zpracovány výše zmíněnými vrstvami systému. Ve čtvrté vrstvě se uplatňuje LMS algoritmus, kterým jsou dány jednotlivé parametry konsekventu. Jelikož se jedná o FIS typu Takagi-Sugeno, výstupní vektor lze zapsat lineární funkcí ve tvaru (45) [51, 55, 91]:

$$\vec{z}_i = p_i x + q_i + r_i. \tag{45}$$

Množina tréninkových vzorů o velikosti m, která je tvořena z m lineárních rovnic o parametrech konsekventu p, q a r, je dána rovnicí (46):

$$\begin{cases} \vec{z}(1) = \bar{w}_1(1)f_1(1) + \dots + \bar{w}_n(1)f_n(1) \\ \vec{z}(2) = \bar{w}_1(2)f_1(2) + \dots + \bar{w}_n(2)f_n(2) \\ \vdots \\ \vec{z}(m) = \bar{w}_1(m)f_1(m) + \dots + \bar{w}_n(m)f_n(m) \end{cases}$$
(46)

kde n určuje počet neadaptivních uzlů ve druhé (pravidlové) vrstvě. Lineární rovnice lze zapsat také zjednodušeně pomocí vztahu (47):

$$\mathbf{Z} = \mathbf{A} \cdot \vec{k}. \tag{47}$$

Výstupní matice **Z** je vyjádřena rovnicí (48), **A** je matice  $m \times n$  dána rovnicí (49) a  $\vec{k}$  je vektor  $1 \times n$  neznámých parametrů konsekventu zapsaný pomocí rovnice (50) [51, 55, 91].

$$\mathbf{Z} = \begin{bmatrix} \vec{z}(1) \\ \vec{z}(2) \\ \vdots \\ \vec{z}(m) \end{bmatrix},$$
(48)

$$\mathbf{A} = \begin{bmatrix} \overline{w}(1) & \overline{w}(1)x(1) & \overline{w}(1)y(1) & \cdots & \overline{w}_{n}(1) & \overline{w}_{n}(1)x(1) & \overline{w}_{n}(1)y(1) \\ \overline{w}(2) & \overline{w}(2)x(2) & \overline{w}(2)y(2) & \cdots & \overline{w}_{n}(2) & \overline{w}_{n}(2)x(2) & \overline{w}_{n}(2)y(2) \\ \vdots & \vdots & \vdots & \cdots & \vdots & \vdots & \vdots \\ \overline{w}(m) & \overline{w}(m)x(m) & \overline{w}(m)y(m) & \cdots & \overline{w}_{n}(m) & \overline{w}_{n}(m)x(m) & \overline{w}_{n}(m)y(m) \end{bmatrix},$$
(49)  
$$\vec{k} = \begin{bmatrix} p_{1} & q_{1} & r_{1} & p_{2} & q_{2} & r_{2} & \cdots & p_{n} & q_{n} & r_{n} \end{bmatrix}.$$
(50)

Pokud nastane situace, kdy je počet n parametrů konsekventu nižší, než počet m učících vzorů, jedná se o tzv. přeučení sítě a situace nemusí mít řešení. Proto se využívá nalezení odhadu k pomocí algoritmu LMS, čímž dochází k minimalizaci chyby aplikací pseudo-inverzní metody dle následující rovnice (51):

$$k^* = (\mathbf{A}^{\mathrm{T}} \mathbf{A})^{-1} \mathbf{A}^{\mathrm{T}} \mathbf{Z},\tag{51}$$

kde  $k^*$  je odhad parametrů konsekventu, který je dán pseudo-inverzí **A** jako ( $\mathbf{A}^T \mathbf{A}$ )<sup>-1</sup> $\mathbf{A}^T$ . Z celkového výstupu ANFIS a požadovaného výstupu je vypočtena chyba *e* (52) [51, 55, 91]:

$$e = \mathbf{Z} - \mathbf{Z}_{aktual}.$$
 (52)

Nyní se uplatňuje zpětný chod hybridního učícího algoritmu, který využívá algoritmus BP (viz Kap. 5.2). Chybový signál je šířen zpětně a derivací složené funkce jsou adaptovány parametry antecedentu. Příklad výpočtu změny parametru *a* s využitím zvonové funkce je uveden v pracích [51, 91].

### 5.5 ESN

ESN je typ rekurentní sítě, které jsou schopny modelovat nelineární dynamické systémy. Pomocí tzv. rekurentních neuronů, zajišťujících zpětnou vazbu, umožňují zpracování dat s časovou závislostí. Samotná ESN se skládá ze vstupní vrstvy, tzv. dynamického rezervoáru, díky kterému je do sítě zakomponována zpětná vazba, a výstupní vrstvy. Struktura je vyobrazena na Obr. 19. Dynamický rezervoár je složen ze stanoveného počtu náhodně propojených neuronů, jejichž váhy jsou taktéž stanoveny náhodně. Při učení se váhy neuronů v rezervoáru již nemění a aktualizovány jsou pouze váhy výstupních neuronů. ESN lze také chápat jako přístup pro trénování RNN, protože při využití klasického algoritmu BP, který využívají pro učení dopředné ANN, by mohlo docházet k opakovanému násobení vah rekurentních neuronů stejnou hodnotou. Název sítě (*Echo state*) je odvozen od reakce probíhající v rezervoáru, pomocí které je výstup dán jak posledním vstupem, tak i "ozvěnou" předchozích vstupů [67, 83].



Obr. 19: Struktura ESN [83].

Učení ESN může probíhat online nebo offline metodou. U offline metody učení dojde ke zpracování všech vstupních hodnot tréninkové množiny. Sítí je následně poskytnuta matice složená z výstupních hodnot a váhy jsou až poté upravovány pomocí pseudo-inverzní metody dle matice s požadovanými výstupy sítě. V porovnání s offline metodou, online metoda učení zpracovává jednotlivé vstupy postupně. Po průchodu vstupní hodnoty je dána výstupní hodnota, která se porovnává s požadovanou hodnotou výstupu, následně dochází k úpravě výstupních vah. Jelikož byl online algoritmus využit pro extrakci fEKG, jednotlivé kroky algoritmu budou popsány následně dle referencí [67, 83].

**První krok**: stanovení počtu neuronů v rezervoáru a vytvoření ESN. Neurony jsou propojeny v rezervoáru náhodně a jejich váhy jsou taktéž stanoveny náhodně.

**Druhý krok**: přivedení signálu na vstupy ESN. Signál je dále transformován v každém neuronu podle stanovené přenosové funkce. Jako přenosová funkce bývá využíván hyperbolický tangens, jehož výpočet udává rovnice (19). Signál je také transformován zpětnou vazbou v rezervoáru. Výpočet vnitřního stavu je dán následující rovnicí (53):

$$s(n+1) = s(n) + f(W_{in} \cdot x(n+1) + W \cdot s(n) + W_{back} \cdot y(n)),$$
(53)

kde x udává vstupní vektor, s je vektor vnitřních stavů, y je výstupní vektor, přenosová funkce je označena jako f a  $W_{in}$  značí vstupní váhy, W vnitřní a  $W_{back}$  představuje zpětnovazební váhy.

**Třetí krok**: udává výpočet výstupu ESN, který je dán vynásobením vnitřního stavu sítě s výstupními váhami  $W_{out}$  v čase n podle vztahu (54):

$$y(n+1) = s(n+1) \cdot W_{out}(n).$$
 (54)

**Čtvrtý krok**: prostřednictvím porovnání výstupu ESN s požadovaným výstupem je vypočtena chyba  $e_y$  a dochází k adaptaci výstupních vah  $W_{out}$  podle následujícího vztahu (55):

$$W_{out}(n+1) = W_{out}(n) + \eta \cdot s(n+1)^T \cdot e_y(n+1) + \gamma \cdot s(n)^T \cdot e_y(n).$$
(55)

 $\eta$  nabývá hodnot od 0 do 1 a představuje koeficient učení,  $\gamma$  nabývá taktéž hodnot od 0 do 1 a bývá označován jako momentový koeficient.

**Pátý krok**: ukončení algoritmu online učení, jestliže již na vstupu ESN není žádný signál, v opačném případě se algoritmus opakuje.

#### 5.6 Detekce R-kmitů

Po aplikaci výše zmíněných metod na aEKG signál je získán signál fEKG, ze kterého lze pomocí detekce R-kmitů určit fHR. Monitorování fHR je důležitým parametrem pro určení stavu plodu a případného distresu, který může vést k nevratnému poškození nebo i úmrtí plodu. V této práci byl využit detektor na bázi dopředné vícevrstvé ANN a detektor založený na CWT.

Pro detekci používají oba detektory adaptivní práh, který představili Pan a Tompkins v práci [96]. Algoritmus využívá dva prahy pro detekci všech QRS komplexů v signálu a pro jejich klasifikaci. Každý detekovaný kmit je označen buď jako kmit signálu nebo kmit šumu. Následně je z posledních hodnot takto označených kmitů vypočten nastavitelný práh (*threshold*). Kmit, označen jako data(n), je vypočten dle následujícího vztahu (56):

$$data(n-1) < data(n) > data(n+1).$$
(56)

Následně dochází k inicializaci prahů a R-R intervalů s využitím prvních 4 s záznamu. Inicializace zahrnuje 2 části. Nejprve jsou detekovány všechny kmity ve zmíněném 4s časovém úseku. První detekovaný kmit je definován jako první lokální maximum, kdy byla překročena hodnota prahu a je vypočten dle rovnice (57):

$$threshold = 0,6 \cdot \max(data_{4s}(N)), \tag{57}$$

kde *data*<sub>4s</sub> představují prvních 4 s původního signálu. Tento kmit je uložen do proměnné *SignalPeak*. Poslední kmit v tomto časovém úseku, jehož hodnota nebyla vyšší než práh, je uložen do proměnné *NoisePeak*. Další R-kmit je stanoven podle prahu (58) [97]:

$$threshold = 0,25 \cdot \max(SignalPeak - NoisePeak).$$
(58)

Po inicializaci nastává druhá část, kdy jsou zpracována i ostatní data podle následujících kroků:

První krok: všechny R-kmity jsou detekovány podle vztahu (56).

Druhý krok: stanovení prahu dle rovnice (58) a následně dle rovnice (59):

$$threshold2 = 0.5 \cdot threshold.$$
(59)

**Třetí krok**: aktualizace hodnoty proměnné *SignalPeak* (60) při každém zaznamenaném kmitu vyšším, než je práh (*threshold*). Stejně tak i dochází k aktualizaci proměnné *NoisePeak* (61), když je zaznamenán kmit nižší, než je stanovený práh.

$$SignalPeak = 0,125 \cdot Signal_{amplitude} + 0,875 \cdot SignalPeak,$$
(60)

$$NoisePeak = 0,125 \cdot Noise_{amplitude} + 0,875 \cdot NoisePeak,$$
(61)

kde *Signal<sub>amplitude</sub>* je hodnota amplitudy kmitu, který překročil práh a *Noise<sub>amplitude</sub>* značí hodnotu amplitudy kmitu, který se nacházel pod prahem [97].

První detektor využíval pro detekci fQRS komplexů již naučenou vícevrstvou dopřednou ANN, která byla učena algoritmem BP (viz Kap. 5.2). Síť se skládala ze vstupní vrstvy, jedné skryté vrstvy a výstupní vrstvy. Princip detekce u tohoto detektoru byl založen na predikci signálu bez R-kmitů, jakmile došlo v signálu ke QRS komplexu, zvýšila se chyba sítě. Po výpočtu chyby, byl stanoven adaptivní práh dle výše uvedených kroků [97].

Druhý detektor byl založený na CWT, při které dochází k dekompozici signálu pomocí konvoluce vlnky  $\psi_{\tau,s}(t)$  se signálem f(x) (62). Výpočet vlnky je dán rovnicí (63).

$$W_{s}f(\tau,s) = f(t) * \psi_{\tau,s}(t) = \frac{1}{\sqrt{s}} \int_{-\infty}^{+\infty} f(t)\psi\left(\frac{t-\tau}{s}\right) dt,$$
(62)

$$\psi_{\tau,s}(t) = \frac{1}{\sqrt{s}}\psi\left(\frac{t-\tau}{s}\right),\tag{63}$$

kde *s* je měřítko a určuje šířku (dilataci) vlnky,  $\tau$  označuje polohu (translaci) vlnky. Při malé hodnotě *s* je získáno více detailnějších složek odpovídající vysokofrekvenčním složkám v signálu, což bylo využito i pro detekci fQRS komplexů. Detektor využíval vlnku Morlet se šířkou 1, která má tvar sinusovky modulované Gaussovským oknem. Rozklad signálu byl stanoven na 5. Po provedení CWT a získání koeficientů byly hledány veškeré lokální minima a maxima dané stanoveným prahem, poté byl proveden výpočet adaptivního prahu a stanovení R-kmitů dle výše uvedených kroků [97, 98].

#### 5.7 Hodnotící parametry

Pro zhodnocení extrakčních metod byla využita detekce R-kmitů. Výsledky detekce byly srovnány s anotací obsahující referenční pozice fQRS komplexů, z čehož byly získány parametry stanovující skutečně pozitivní hodnoty (TP), falešně pozitivní hodnoty (FP) a falešně negativní hodnoty (FN).

Parametr TP určuje, kolik R-kmitů bylo skutečně stanoveno na místech, odpovídajících pozicím, kde se dle reference má R-kmit nacházet. Pro zlepšení přesnosti detekce využívaly R-detektory oboustranné 50ms intervaly stanovené od detekované hodnoty. Jako výsledný R-kmit byla brána maximální hodnota v těchto intervalech [97]. Parametr FP stanovuje počet detekovaných R-kmitů navíc mimo referenční hodnoty a parametr FN stanovuje počet chybějících R-kmitů, které nebyly dle reference detekovány. Z těchto uvedených parametrů lze získat senzitivitu (SE), jejíž výpočet je uveden v rovnici (64), pozitivní prediktivní hodnotu (PPV), viz rovnice (65), a jako harmonický průměr hodnot SE a PPV je dán parametr F1 (66). Výpočet celkového odhadu pravděpodobnosti správné detekce (ACC) je uveden v rovnici (67). Všechny tyto parametry jsou udávány v procentech [67, 91].

$$SE = \frac{TP}{TP + FN} \cdot 100, \tag{64}$$

$$PPV = \frac{TP}{TP + FP} \cdot 100, \tag{65}$$

$$F1 = 2 \cdot \frac{PPV \cdot SE}{PPV + SE} = \frac{2 \cdot TP}{2 \cdot TP + FN + FP'},$$
(66)

$$ACC = \frac{TP}{TP + FP + FN} \cdot 100.$$
(67)

# 6 NÁVRH UŽIVATELSKÉHO ROZHRANÍ

Pro samotnou aplikaci výše zmíněných metod na signály aEKG za účelem extrakce fEKG a následné detekce R-kmitů bylo vytvořeno grafické uživatelské rozhraní (GUI) v programu MATLAB. GUI se skládá ze tří bloků, kdy první blok zajišťuje načtení čtyřsvodového aEKG a jeho následnou filtraci. Druhý blok byl navržen pro samotnou extrakci fEKG pomocí metod ADALINE, ANFIS a ESN. Třetí blok vyobrazuje tepové křivky, jak referenční, tak extrahované pomocí jednotlivých metod a numericky porovnává pomocí hodnoticích parametrů dva aplikované detektory R-kmitů. Blokové schéma navrženého systému je zobrazeno na Obr. 20.



Obr. 20: Blokové schéma navrženého systému pro extrakci fEKG.

# 6.1 Zobrazení a filtrace aEKG

Prvním krokem je načtení všech čtyř svodů aEKG záznamu. Po volbě signálů je jeden zvolený svod zobrazen v prvním bloku navrženého GUI. Pro co nejlepší provedení extrakce je nutné před aplikací metod odstranit ze signálů nepodstatné složky. Pro potlačení síťového rušení 50 Hz byl použit filtr pásmová zádrž (PZ), pro který byla využita Butterworthova aproximace s řádem filtru 5. Dolní mezní frekvence filtru byla nastavena na hodnotu 49 Hz a horní mezní frekvence na hodnotu 51 Hz. Filtr byl aplikován pomocí funkce *butter()*.

Kromě síťového rušení je nutné odstranit další šumové složky, které vznikají např. kolísáním izolinie, dýcháním, aktivitou svalů atd. V tomto případě byl využit FIR filtr, který neobsahuje zpětnou vazbu, čímž bývá stabilní, ale má vysoký řád přenosové funkce. Při použití FIR filtru také dochází ke zpoždění filtrovaného signálu od původního signálu. Z tohoto důvodu bylo nejdříve zjištěno zpoždění pro konkrétně nastavený filtr a původní signál byl následně rozšířen o počet vzorků rovný tomuto zpoždění. Po filtraci byl filtrovaný signál zkrácen zpět na původní délku. Po načtení aEKG záznamů byla využita funkce *fir1()* pro implementaci FIR filtru jako pásmové propusti (PP). Řád FIR filtru byl nastaven na hodnotu 500, dolní mezní frekvence na hodnotu 5 Hz a horní mezní frekvence na 50 Hz. V navrženém GUI je umožněno měnit parametry obou filtrů, panel s nastavitelnými parametry filtrů je zobrazen na Obr. 21 a celkový první blok vytvořené aplikace je zobrazen na Obr. 22.

Filtrace	
Pásmová propust	
Řád FIR filtru	500
Dolní mezní frekvence	5
Horní mezní frekvence	50
Pásmová zádrž	
Řád Butterworth filtru	5
Dolní mezní frekvence	49
Horní mezní frekvence	51

Obr. 21: Panel pro nastavení parametrů filtrace v GUI.



Obr. 22: První blok GUI pro zobrazení a filtraci aEKG. Pro ukázku byl využit 3. svod záznamu r08 z databáze Labour dataset.

### 6.2 Extrakce fEKG aplikací ANN

Tato část byla navržena pro samotnou extrakci fEKG. Na načtené a filtrované signály je aplikována metoda ADALINE, ANFIS a ESN. Při prvním spuštění metody je nejdříve provedena ICA pro získání mateřské komponenty a mateřské komponenty společně s fetální. Fetální komponenta bývá mnohdy zvýrazněna oproti původním signálům a dosahuje podobných amplitud jako mateřská komponenta. Pro ICA metodu je nutné zvolit počet výsledných komponent, které mají být ve vstupním signálu nalezeny. Počet komponent byl nastaven na hodnotu 3, počet iterací na hodnotu 100 a kritérium konvergence na hodnotu 0,000001. Výsledkem byly získány 3 signály, které musely být nejdříve zarovnány dle vstupního aEKG signálu. Pro každý výsledný signál byl vypočten průměrný výkon, dle kterého byly signály rozlišeny. Jeden signál představoval odhadnutý šum, proto nebyl v dalším zpracování uvažován. Na Obr. 23 jsou zobrazeny výstupy získané metodou ICA.



Obr. 23: Vykreslení výsledných signálů po aplikaci metody ICA pro záznam r01 z databáze Labour dataset.

Zbylé 2 signály získané metodou ICA, kdy jeden představoval jen mateřskou komponentu mEKG a druhý nově získané aEKG obsahující jak mateřskou, tak fetální komponentu, byly využity jako vstupy do extrakčních metod. Pro metodu ADALINE je možné nastavit dimenzionalitu vstupu neboli počet synapsí a koeficient učení  $\mu$  od 0 do 1. Pro učení ADALINE byl implementován algoritmus LMS. Další využitou metodou byl ANFIS, u které lze sledovat vliv na extrakci fEKG změnou počtu funkcí příslušnosti, tvaru funkcí příslušnosti a počtem epoch. Hybridní učící algoritmus byl využit pro učení sítě pomocí funkce *anfis()*. U ESN je možné měnit parametr udávající počet neuronů v rezervoáru a míru zapomínání  $\alpha$ , která může nabývat hodnot od 0 do 1. Se zvyšující se hodnotou  $\alpha$  si neurony zachovávají méně informací o svých předchozích stavech. Algoritmem RLS jsou upravovány výstupní váhy u ESN.

Extrahované signály dané jednotlivými metodami jsou zobrazeny pod sebou pro vizuální zhodnocení. Po extrakci je možno detekovat R-kmity a získat parametr ACC pro rychlé zhodnocení kvality detekce pro konkrétní nastavení parametrů u jednotlivých metod. Před aplikací daných metod lze využít zpracování signálu dopřednou vícevrstvou ANN, která se skládá z 1 vstupní vrstvy, 3 skrytých vrstev a jedné výstupní vrstvy. Vstupem do dopředné vícevrstvé ANN je získaný signál aEKG metodou ICA a výstupem je upravený signál aEKG, který je využit jako vstup do metod ADALINE, ANFIS nebo ESN. K extrahovaným signálům fEKG je možné zobrazit referenční fEKG signál získaný přímo skalpovou elektrodou umístěnou na hlavičce plodu pro vizuální zhodnocení extrakce. Blok pro aplikaci metod a následné zobrazení extrahovaného fEKG signálu je zobrazen na Obr. 24.



Obr. 24: Druhý blok GUI pro extrakci fEKG. Pro ukázku byl využit záznam r08 z databáze Labour dataset.

## 6.3 Vyhodnocení a vykreslení fHR

Poslední blok navrženého GUI se zabývá zhodnocením detekce R-kmitů u extrahovaných signálů pomocí referenčních anotací R-kmitů plodu. V práci byly pro detekci využity dva detektory. První byl založen na dopředné vícevrstvé ANN, která se skládala ze vstupní vrstvy, 2 skrytých vrstev a výstupní vrstvy, druhý detektor byl založen na CWT s využitím vlnky Morlet se šířkou 1 a stupněm rozkladu 5. Z detekovaných R-kmitů byly určeny parametry TP, FP a FN, ze kterých bylo následně vypočteno ACC, F1, SE a PPV. Tyto parametry se v GUI zobrazují jak pro detektor využívající ANN, tak pro detektor CWT. Společně s určením hodnotících parametrů byla stanovena průměrná fHR a vykreslena tepová křivka jak z referenčních anotací, tak z detekovaných R-kmitů získaných aplikací obou detektorů. Pro zobrazení trendu tepové křivky byl využit mediánový filtr s nastaveným oboustranným oknem 5 vzorků. Ukázka vypočtených hodnoticích parametrů u metody ESN je uvedena na Obr. 25 pro detektor ANN a na Obr. 26 pro detektor CWT. Obr. 27 zobrazuje blok vyhodnocení a vykreslení fHR v prostředí aplikace.



Obr. 25: Hodnotící parametry metody ESN pro extrakci fEKG ze záznamu r08 pomocí detektoru ANN.

Parametry detekce metodou ESN								
TP 645	ACC (%)	100						
FP 0	F1 (%)	100						
FN 0	SE (%)	100						
ANN CWT	PPV (%)	100						
Průměrná hodnota fHR	129	bpm						

Obr. 26: Hodnotící parametry metody ESN pro extrakci fEKG ze záznamu r08 pomocí detektoru CWT.



Obr. 27: Třetí blok GUI pro vyhodnocení a vykreslení fHR. Pro ukázku byl využit záznam r08 z databáze Labour dataset.

# 7 EXPERIMENT A VYHODNOCENÍ

Po vytvoření GUI pro načtení signálů aEKG, jejich zpracování, extrakci a vyhodnocení extrakce fEKG, byly jednotlivé metody pomocí této aplikace otestovány na reálných datech. Jako extrakční metody byly využity metody založené na ANN. Konkrétně byla využita metoda ADALINE, ANFIS, ESN a kombinace vícevrstvé dopředné ANN s těmito třemi metodami. Použitá reálná data pocházela ze dvou databází, Labour dataset a Pregnancy dataset, popsaných v následující Kap. 7.1.

# 7.1 Použité databáze

Pro testování navržených extrakčních metod založených na ANN byly využity dvě databáze. Jednalo se o databázi Labour dataset a Pregnancy dataset. Labour dataset obsahuje celkem 12 záznamů, z toho každý záznam obsahuje čtyřsvodové aEKG a jeden signál přímého fEKG (Obr. 28). Pro záznam aEKG bylo využito 6 elektrod, kdy byla 1 aktivní elektroda umístěna nad pupeční jizvou, další 2 aktivní elektrody umístěny vpravo a 1 aktivní elektroda vlevo od pupeční jizvy. Referenční se nacházela nad stydkou sponou a zemnící na levé noze, jak je zobrazeno na Obr. 10b [40]. Přímé fEKG bylo pořízeno skalpovou elektrodou umístěnou přímo na hlavičku plodu. Abdominální signály jsou 5 minut dlouhé a jejich vzorkovací frekvence je 500 Hz [99].



Obr. 28: Vykreslení signálů ze záznamu r01, databáze Labour dataset.

Pregnancy dataset se skládá z 10 záznamů, kdy každý záznam obsahuje čtyřsvodové aEKG signály s délkou trvání 20 minut a vzorkovací frekvencí taktéž 500 Hz (viz Obr. 29). Tyto dvě databáze obsahují kromě signálů také anotace s referenčním umístěním R-kmitů fEKG, čímž mohla být zhodnocena kvalita extrakce a následné detekce R-kmitů v extrahovaném fEKG signálu [99].



Obr. 29: Vykreslení signálů pro záznam rO1 z databáze Pregnancy dataset.

### 7.2 Vyhodnocení pro Labour dataset

Na celkem 12 záznamů z databáze Labour dataset označených r01–r12, byly aplikovány metody ADALINE, ANFIS, ESN, ANN-ADALINE, ANN-ANFIS, ANN-ESN pro extrakci fEKG a následnou detekci fQRS komplexů. Pro zhodnocení byly nejprve stanoveny parametry TP, FP a FN, ze kterých byl proveden výpočet ACC, F1, SE a PPV. Pro detekci byly využity dva detektory, které byly zhodnoceny na základě hodnoty ACC. V další části byla stanovena průměrná hodnota fHR, tepová křivka byla vykreslena pro vizuální zhodnocení a porovnána s referenčním stanovením fHR. V poslední části byly extrahované signály zhodnoceny vizuálně.

### 7.2.1 Zhodnocení kvality extrakce a detekce R-kmitů

Pro každou použitou extrakční metodu byla nalezena vhodná kombinace nastavitelných parametrů a vhodná kombinace vstupních svodů aEKG signálů tak, aby po extrakci bylo dosaženo nejvyšší hodnoty ACC. V Tab. 2 jsou vypsány hodnoty ACC po aplikaci jednotlivých extrakčních metod a následné detekci fQRS komplexů pomocí detektoru ANN. Jak je patrné z Tab. 2, nejvyšší hodnoty ACC bylo dosaženo u všech záznamů metodou ESN. U záznamu r01 vykazovaly stejnou hodnotu ACC 99,07 %, jako metoda ESN, i metody ANN-ADALINE, ANFIS a ANN-ANFIS. Nejvyšší průměrná hodnota ACC byla pro metodu ESN 78,65 %, pro ostatní metody následně: ANN-ESN 63,39 %, ANFIS 53,97 %, ANN-ADALINE 48,73 %, ADALINE 47,39 %, ANN-ANFIS 46,88 %.

U 4 záznamů, konkrétně u záznamů r01, r05, r08 a r11, dosahovala hodnota ACC pro metodu ADALINE přes 90 %. Taktéž u metod ANN-ADALINE, ANFIS i ANN-ANFIS bylo dosaženo pro tyto signály ACC > 90 %. Metoda ANN-ESN navíc vykazovala hodnotu ACC přes 90 % u záznamu r12, oproti předchozím metodám. Pro 7 záznamů (r01, r02, r05, r06, r08, r11 a r12) bylo dosaženo hodnoty ACC vyšší než 90 % pomocí metody ESN. Nejnižších hodnot ACC bylo určeno pro metodu ADALINE u záznamu r10 jako 10,45 %, taktéž i pro metody ANN-ADALINE s hodnotou 11,32 %, ANN-ANFIS s hodnotou 10,81 % a ESN s hodnotou 37,35 %. U metody ANFIS a ANN-ESN bylo dosaženo nejnižší ACC pro záznam r07 s hodnotami 11,88 % a 7,78 %. Veškeré výše zmíněné hodnoty ACC byly získány použitím ANN detektoru, zhodnocení pro detektor CWT je uvedeno v Tab. 3.

Záznam	ADALINE	ANN-ADALINE	ANFIS	ANN-ANFIS	ESN	ANN-ESN
r01	96,49 %	99,07 %	99,07 %	99,07 %	99,07 %	98,00 %
r02	17,80 %	24,07 %	44,28 %	19,22 %	90,60 %	65,48 %
r03	14,67 %	14,08 %	15,00 %	14,18 %	51,05 %	21,06 %
r04	12,92 %	12,61 %	16,72 %	12,85 %	68,14 %	50,60 %
r05	99,10 %	97,01 %	98,20 %	95,84 %	99,55 %	96,83 %
r06	16,84 %	18,45 %	40,75 %	15,01 %	91,46 %	74,15 %
r07	12,30 %	13,40 %	11,88 %	13,04 %	46,06 %	7,78 %
r08	98,62 %	97,25 %	99,23 %	97,86 %	100 %	99,23 %
r09	16,06 %	13,21 %	28,09 %	13,99 %	64,61 %	41,57 %
r10	10,45 %	11,32 %	13,02 %	10,81 %	37,35 %	11,52 %
r11	92,16 %	96,02 %	97,71 %	95,25 %	99,23 %	96,7 %
r12	81,32 %	79,00 %	83,63 %	75,39 %	96,72 %	97,74 %
Průměr	47,39 %	48,73 %	53,97 %	46,88 %	78,65 %	63,39 %

Tab. 2: Hodnoty ACC pro jednotlivé extrakční metody s použitím ANN detektoru; Labour dataset.

Stejně jako pro detektor ANN bylo provedeno zhodnocení na základě parametru ACC i pro detektor CWT, výsledky jsou uvedeny v Tab. 3. Nejvyšší průměrná hodnota ACC 72,16 % byla zaznamenána metodou ESN. Průměrná hodnota ACC pro ostatní metody byla následná: pro metodu ADALINE 65,08 %, ANFIS 64,89 %, ANN-ESN 60,97 %, ANN-ANFIS 59,29 % a ANN-ADALINE 53,31 %. Nejvyšších hodnot ACC bylo dosaženo u metody ESN pro 7 záznamů, pro metodu ANN-ESN u 3 záznamů, pro metodu ADALINE u 2 záznamů a pro ostatní metody u 1 záznamu.

U 3 z 12 záznamů bylo dosaženo hodnoty ACC přes 90 % pro metodu ADALINE, jednalo se o záznamy r01, r05, r08, i pro metodu ANFIS, zde záznamy r01, r08 a r11. Pro 4 záznamy r01, r05, r08 a r11 bylo dosaženo hodnoty ACC > 90 % u metod ANN-ADALINE a ANN-ANFIS. Hodnoty ACC > 90 % bylo dosaženo metodou ANN-ESN navíc i pro záznam r12 (celkem 6 z 12 záznamů) a metodou ESN taktéž navíc pro záznam r12, ale také i pro záznam r09 (celkem 7 z 12 záznamů).

Hodnota ACC > 80 % byla dosažena pro záznamy r01, r05, r08 a r11 u všech testovaných metod a pro záznam r12 u všech metod kromě ANN-ADALINE, která dosahovala 72,34 %. Pro záznamy r02, r06 a r09 vykazovala pouze ESN ACC > 80 %, celkově bylo pro ESN určeno 8 z 12 záznamů s hodnotou přes 80 % (viz Tab. 3).

Nejnižší hodnoty ACC bylo získáno u metody ADALINE pro záznam r03 s hodnotou 23,28 %. U metody ANN-ADALINE, ESN, ANN-ESN pro záznam r07 byla hodnota ACC < 10 %, metoda ANFIS u tohoto záznamu dosahovala hodnoty 19,17 %. Nejnižší hodnoty ACC 9,08 % u metody ANN-ANFIS bylo určeno pro záznam r10.

Záznam	ADALINE	ANN-ADALINE	ANFIS	ANN-ANFIS	ESN	ANN-ESN
r01	97,09 %	95,98 %	92,69 %	98,15 %	99,38 %	97,85 %
r02	60,56 %	33,98 %	66,96 %	60,05 %	87,32 %	64,82 %
r03	23,28 %	11,43 %	24,23 %	11,21 %	50,39 %	13,95 %
r04	38,14 %	19,13 %	39,37 %	25,93 %	32,93 %	33,93 %
r05	91,27 %	96,99 %	89,00 %	94,99 %	97,46 %	97,59 %
r06	63,69 %	43,87 %	76,31 %	77,68 %	87,11 %	59,15 %
r07	25,76 %	9,00 %	19,17 %	9,21 %	8,33 %	3,21 %
r08	99,69 %	100 %	98,62 %	100 %	100 %	100 %
r09	68,71 %	26,93 %	57,54 %	49,35 %	91,78 %	61,31 %
r10	38,94 %	22,86 %	37,24 %	9,08 %	16,24 %	8,67 %
r11	89,39 %	95,63 %	91,18 %	95,63 %	95,58 %	95,92 %
r12	84,45 %	72,34 %	86,40 %	80,22 %	99,39 %	95,25 %
Průměr	65,08 %	53,31 %	64,89 %	59,29 %	72,16 %	60,97 %

Tab. 3: Hodnoty ACC pro jednotlivé extrakční metody s použitím CWT detektoru.

V Tab. 4 je uvedena nejvhodnější varianta metody a detektoru pro jednotlivé záznamy r01–r12. Hodnocení bylo provedeno na základě hodnoty ACC. Pro 10 z 12 záznamů byla pro extrakci fEKG nejvhodnější metoda ESN. Z těchto 10 záznamů byl pro detekci R-kmitů u 7 záznamů (r02, r03, r04, r06, r07, r09, r11) vhodnější detektor využívající dopřednou vícevrstvou ANN, u 2 záznamů (r01, r12) byl vhodnější detektor využívající CWT a u 1 záznamu, což byl záznam r08, byly vhodné oba detektory. Pro záznam r08 byly vhodné i metody ANN-ADALINE, ANN-ANFIS, ANN-ESN s detektorem CWT. U všech těchto zmíněných metod byla hodnota ACC pro záznam r08 rovna 100 %. Metoda ANN-ESN s využitím detektoru CWT dosahovala nejvyšší hodnoty ACC pro záznam r05. Metoda ADALINE s detektorem CWT dosahovala nejvyšších hodnot ACC u záznamu r10, zde se však jednalo pouze o 38,94 %. Jelikož metoda ESN s detektorem ANN dosahovala nejvyšších hodnot ACC pro 8 z 12 záznamů, výsledky dané touto metodou a detektorem pro jednotlivé záznamy s vhodnou kombinací parametrů jsou uvedeny v Tab. 5.

Záznam	Metoda	Detektor	ACC (%)
r01	ESN	CWT	99,38
r02	ESN	ANN	90,60
r03	ESN	ANN	51,05
r04	ESN	ANN	68,14
r05	ANN-ESN	CWT	97,59
r06	ESN	ANN	91,46
r07	ESN	ANN	46,06
	ESN;	ANN;	
r08	ANN-ADALINE,	CWT	100
108	ANN-ANFIS,	CVVI	100
	ESN, ANN-ESN		
r09	ESN	ANN	91,78
r10	ADALINE	CWT	38,94
r11	ESN	ANN	99,23
r12	ESN	CWT	99,39

Tab. 4: Shrnutí nejvhodnějších metod dle ACC pro jednotlivé záznamy z databáze Labour dataset.

Za účelem dosažení co nejvyšší hodnoty ACC, bylo také testováno nastavení parametrů pro jednotlivé metody. Pro ukázku byla zvolena extrakční metoda ESN v kombinaci s detektorem ANN, protože dosahovala nejvyšší hodnoty ACC u většiny záznamů. V Tab. 5 jsou uvedeny vhodné kombinace svodů a parametrů M a  $\alpha$ . Parametr M představuje počet neuronů v rezervoáru, nejčastěji byla jeho hodnota mezi 10 až 50. Parametr byl také volen v závislosti na časové náročnosti metody. S vyšší hodnotou M se zvyšovala i časová náročnost metody. Parametr  $\alpha$  představuje míru zapomínání a byl volen v rozmezí 0,1 až 1, kde  $\alpha = 1$  znamená, že si neurony neuchovávají žádnou informaci o svém předchozím stavu. Dále jsou v Tab. 5 uvedeny hodnoty ACC, F1, PPV a SE, které byly vypočteny z parametrů TP, FP a FN, taktéž uvedených v Tab. 5.

Záznam	М	α	Svody	ACC (%)	F1 (%)	PPV (%)	SE (%)	Počet fQRS ref.	ТР	FP	FN
r01	10	0,4	1, 2, 3, 4	99 <i>,</i> 07	99,53	99,53	99,53	644	641	3	3
r02	20	0,3	1, 2, 3, 4	90,6	95,07	93,34	96,86	637	617	44	20
r03	50	0,5	1, 2, 3, 4	51,05	67 <i>,</i> 6	75,96	60,89	716	436	138	280
r04	50	0,3	1, 2, 3, 4	68,14	81,05	80,46	81,64	681	556	135	125
r05	20	0,2	1, 2, 3, 4	99,55	99,77	99,7	99 <i>,</i> 85	660	659	2	1
r06	50	0,4	1, 2, 3, 4	91,46	95,54	95,61	95,47	684	653	30	31
r07	50	0,2	1, 2, 3, 4	46,06	63,07	74,68	54,59	632	345	117	287
r08	10	0,3	1, 2, 3, 4	100	100	100	100	645	645	0	0
r09	50	0,4	1, 2, 3, 4	64,61	78,51	84,71	73,15	674	493	89	181
r10	50	0,1	1, 3, 4	37,35	54,39	53,92	54,86	627	344	294	283
r11	30	0,1	1, 3, 4	99,23	98,92	99,54	643	646	646	3	24
r12	30	0,2	1, 2, 3, 4	96,72	98,33	98,03	98,63	657	648	13	9

Tab. 5: Nastavené parametry pro metodu ESN a hodnoticí parametry získané ANN detektorem.

#### 7.2.2 Stanovení tepové frekvence z extrahovaných signálů

V druhé části experimentu byla po získání detekovaných fQRS komplexů vypočtena průměrná fHR a vykreslena tepová křivka. Jelikož byla součástí databáze i anotace s uvedenými referenčními pozicemi fQRS komplexů, mohla být fHR z extrahovaných signálů srovnána s hodnotou fHR vypočtenou z anotací.

Tab. 6 udává průměrné referenční hodnoty fHR a průměrné hodnoty fHR získané po aplikaci jednotlivých metod s detektorem ANN. Zvýrazněné hodnoty v tabulce odpovídají rozmezí ± 5 bpm od referenční hodnoty a byly stanoveny pro zlepšení hodnocení dle [67]. Pro záznamy r01, r05, r08, r11 a r12 byly průměrné hodnoty fHR stanoveny u všech testovaných metod v rozmezí ± 5 bpm od referenčních hodnot. U záznamu r03 nebyla poskytnuta průměrná fHR jednotlivými metodami v daném intervalu. Nejbližší hodnota, která byla větší o 8,6 bpm byla dána metodou ESN. Pro záznam r07 byly stanovené hodnoty fHR menší o více než 30 bpm od referenční hodnoty. Pomocí metody ESN byly stanovené fHR v daném rozmezí i pro záznamy r02, r04, r06 a r10. Také pomocí metody ANN-ESN byly stanovený hodnoty fHR v odpovídajícím rozmezí pro záznamy r04, r06, a navíc také pro r09.

Záznam	ADALINE	ANN-ADALINE	ANFIS	ANN-ANFIS	ESN	ANN-ESN
ref. fHR (bpm)	fHR (bpm)	fHR (bpm)	fHR (bpm)	fHR (bpm)	fHR (bpm)	fHR (bpm)
r01 (128,8)	129,0	128,8	128,8	128,8	128,8	128,6
r02 (127,4)	95,0	113,8	139,8	105,8	132,2	134,8
r03 (143,2)	92,8	96,6	96,0	96,8	151,8	104,8
r04 (136,2)	85,8	88,8	94,2	88,6	138,2	140,6
r05 (132,0)	132,4	131,2	132,0	131,6	132,2	131,6
r06 (136,8)	83,8	93,0	125,0	85,4	136,6	139,4
r07 (126,4)	87,2	86,8	86,4	86,8	93,6	64,8
r08 (129,0)	129,2	129,0	129,2	129,4	129,0	129,2
r09 (134,8)	75,2	84,6	109,6	88,4	144,0	135,6
r10 (125,4)	79,6	79,2	79,4	79,6	127,6	79,8
r11 (129,2)	130,6	126,8	129,8	130,4	130,0	130,4
r12 (131,4)	132,6	126,4	133,4	135,2	132,2	131,6

Tab. 6: Průměrné hodnoty fHR stanovené detektorem ANN pro jednotlivé metody; Labour dataset.

Dále byla stanovena průměrná fHR i s využitím detektoru CWT. Průměrné hodnoty fHR po aplikaci jednotlivých metod jsou vypsány v Tab. 7, kde byly taktéž zvýrazněny hodnoty nacházející se v intervalu ± 5 bpm od referenční hodnoty. Stejně jako u detektoru ANN byly pro záznamy r01, r05, r08, r11 a r12 u všech metod zaznamenány hodnoty fHR v daném intervalu. Kromě záznamu r07, kde se stanovené průměrné hodnoty fHR nenacházely v rozmezí ± 5 bpm od referenční hodnoty ani pro jednu extrakční metodu, byla stanovená průměrná fHR pomocí metody ANFIS a detektoru CWT pro všechny záznamy v zadaném intervalu.

Záznam	ADALINE	ANN-ADALINE	ANFIS	ANN-ANFIS	ESN	ANN-ESN
ref. fHR (bpm)	fHR (bpm)	fHR (bpm)	fHR (bpm)	fHR (bpm)	fHR (bpm)	fHR (bpm)
r01 (128,8)	129,0	128,8	129,2	128,8	129,0	128,8
r02 (127,4)	129,0	133,6	132,0	130,4	132,6	135
r03 (143,2)	140,6	102,4	138,8	100,8	140,2	100,6
r04 (136,2)	134,0	110,4	139,2	132,0	114,6	137,8
r05 (132,0)	131,8	131,2	136,0	132,8	131,8	131,4
r06 (136,8)	145,4	140,0	140,0	138,6	139,0	139,8
r07 (126,4)	114,8	86,8	102,4	87,2	37,4	21,4
r08 (129,0)	129,0	129,0	129,2	129,0	129,0	129,0
r09 (134,8)	140,2	132,0	138,2	139,4	136,0	140,4
r10 (125,4)	132,2	106,8	124,8	81,2	84,4	80,4
r11 (129,2)	131,4	130,2	130,8	130,2	127,4	130,2
r12 (131,4)	132,0	132,6	131,8	132,8	131,4	131,8

Tab. 7: Průměrné hodnoty fHR stanovené detektorem CWT pro jednotlivé metody.

Kromě průměrné hodnoty fHR byly stanoveny také průběhy fHR v čase a vykresleny společně s referenční křivkou. Pomocí detektoru ANN a CWT byly stanoveny hodnoty R-kmitů v extrahovaných signálech, dále byl stanoven R-R interval a z něj vypočtena fHR pro každý časový úsek signálu. Poté byl aplikován oboustranný mediánový filtr s oknem 5 vzorků pro vykreslení trendu fHR a odstranění odlehlých vrcholů způsobených chybnou detekcí. Na Obr. 30 jsou vykresleny křivky získané pro záznam r08 od detektoru ANN (horní křivka) a detektoru CWT (spodní křivka) pro metody ADALINE, ANFIS a ESN. Z vykreslených průběhů je patrné, že detektor ANN není v tomto případě tak účinný jako detektor CWT. Totéž vyplývá i pro průběhy zobrazené na Obr. 31, kde jsou vykresleny fHR v čase pro metody ANN-ADALINE, ANFIS a ANN-ESN pomocí obou detektorů.



Obr. 30: Zobrazení fHR v čase pro metody ADALINE, ANFIS a ESN; záznam r08 Labour dataset.



Obr. 31: Zobrazení fHR v čase pro metody ANN-ADALINE, ANN-ANFIS a ANN-ESN; záznam r08 Labour dataset.

#### 7.2.3 Vizuální zhodnocení extrahovaných signálů

V poslední části byly vykresleny průběhy extrahovaných signálů fEKG získaných jednotlivými metodami ze záznamu r08. Na Obr. 32 je vyobrazeno srovnání extrahovaných fEKG signálů získaných metodami ADALINE, ANFIS a ESN společně s pvním svodem aEKG a skalpovým fEKG. Díky vykresleným průběhům lze pozorovat, obzvlášť v extrahovaných signálech u metody ADALINE a ANFIS, části signálu odpovídající původnímu mQRS komplexu. Tyto části byly v signálech vyznačeny. Z vykresleného průběhu u metody ESN vyplývá, že byla fetální komponenta úspěšně extrahována bez mateřské komponenty.

Na Obr. 33 jsou taktéž vykresleny průběhy extrahovaných signálů, tentokrát metodami ANN-ADALINE, ANN-ANFIS a ANN-ESN, třetího svodu aEKG signálu a skalpového fEKG signálu. Aplikací vícevrstvé dopředné ANN před samotnou extrakcí fEKG bylo docíleno většího vyhlazení signálu, kdy v signálu byly ponechány pouze R-kmity, které byly následně detekovány. Pro morfologickou analýzu by však tato metoda nebyla příliš vhodná. V extrahovaných signálech lze taktéž pozorovat mateřské komponenty, které zůstaly v signálu i po extrakci.


Obr. 32: Vykreslení průběhů extrahovaných fEKG signálů metodami ADALINE, ANFIS a ESN společně s původním aEKG signálem a skalpovým fEKG; záznam r08 Labour dataset.



Obr. 33: Vykreslení průběhů extrahovaných fEKG signálů metodami ANN-ADALINE, ANN-ANFIS a ANN-ESN společně s původním aEKG signálem a skalpovým fEKG; záznam r08 Labour dataset.

#### 7.3 Vyhodnocení pro Pregnancy dataset

Další testování metod bylo provedeno na reálných záznamech z databáze Pregnancy dataset. Jednalo se celkem o 10 záznamů označených r01–r10. Taktéž jako u předchozího testování na reálných datech z databáze Labour dataset, byly i zde stanoveny pomocí dvou detektorů parametry TP, FP a FN, ze kterých byla určena hodnota ACC pro zhodnocení metod. V další části byly stanoveny hodnoty fHR a srovnány s referenčními hodnotami. Pro vizuální zhodnocení byly vykresleny jak křivky fHR v čase, tak samotné extrahované signály.

#### 7.3.1 Zhodnocení kvality extrakce a detekce R-kmitů

Srovnání jednotlivých metod dle hodnoty ACC je uvedeno v Tab. 8. Nejvyšších hodnot ACC dosahovala metoda ESN pro 9 z 10 záznamů, u zbylého jednoho záznamu metoda ANN-ADALINE. Z toho vyplývá, že i metoda ESN dosahovala nejvyšší průměrné hodnoty ACC 66,24 %. Pro další metody byla průměrná hodnota ACC následující: ANN-ADALINE 40,52 %, ANN-ANFIS 37,57 %, ANFIS 37,02 %, ADALINE 36,95 %, ANN-ESN 36,40 %. Kombinace vícevrstvé dopředné ANN s metodami ADALINE a ANFIS poskytovala průměrně vyšších hodnot ACC než samostatné metody, ale pouze o 0,55 % u metody ANFIS a o 3,57 % u metody ADALINE.

V případě využití detektoru ANN bylo dosaženo hodnot ACC > 90 % u 4 záznamů (r01, r02, r04, r05) a to po extrakci metodou ESN. U ostatních metod bylo dosaženo hodnoty ACC přes 90 % pouze u jednoho záznamu, kterým byl záznam r05. U záznamu r01 a r05 dosahovaly metody ADALINE, ANFIS a ANN-ESN hodnot ACC přes 80 % a metoda ANN-ADALINE a ANN-ANFIS dosahovaly této hodnoty ACC u záznamů r02 a r05 (viz Tab. 8).

Záznam	ADALINE	ANN-ADALINE	ANFIS	ANN-ANFIS	ESN	ANN-ESN
r01	88,50 %	79,68 %	86,45 %	78,75 %	98,32 %	88,46 %
r02	68,17 %	82,73 %	62,67 %	80,10 %	96,46 %	67,02 %
r03	15,30 %	13,53 %	15,35 %	13,77 %	46,86 %	11,65 %
r04	20,41 %	11,93 %	25,63 %	11,33 %	91,60 %	15,77 %
r05	96,80 %	95,86 %	96,03 %	95,86 %	99,50 %	99 <i>,</i> 35 %
r06	10,89 %	62,69 %	15,04 %	42,96 %	47,71 %	20,51 %
r07	21,64 %	14,33 %	20,57 %	11,50 %	49,06 %	25,30 %
r08	21,21 %	19,42 %	21,09 %	16,07 %	48,02 %	10,19 %
r09	14,64 %	13,38 %	14,72 %	13,39 %	53,16 %	12,99 %
r10	11,98 %	11,68 %	12,69 %	12,00 %	31,68 %	12,79 %
Průměr	36,95 %	40,52 %	37,02 %	37,57 %	66,24 %	36,40 %

Tab. 8: Hodnoty ACC pro jednotlivé extrakční metody s použitím ANN detektoru; Pregnancy dataset.

Lepších výsledků bylo u většiny metod dosaženo pomocí detekce R-kmitů detektorem CWT. Hodnoty ACC jsou vypsány v Tab. 9, kde bylo stanoveno u 9 z 10 záznamů nejvyšších hodnot ACC po extrakci metodou ESN. U záznamu r05 byla nejvyššího hodnota ACC 99,60 % stanovena metodou ANN-ADALINE. Opět bylo dosaženo průměrně nejvyšší hodnoty ACC pomocí metody ESN, v tomto případě s hodnotou 81,37 %. Metoda ANN-ESN dosahovala průměrné hodnoty ACC 50,74 %, metoda ADALINE 49,16 %, metoda ANFIS 48,39 %, metoda ANN-ANFIS 38,75 % a metoda ANN-ADALINE 38,20 %.

Celkem bylo u 6 z 10 záznamů dosaženo hodnoty ACC přes 90 %, jednalo se o záznamy r01, r02, r03, r04, r05 a r09. Tyto hodnoty ACC poskytovala metoda ESN. Metody ADALINE, ANFIS a ANN-ESN dosahovaly také hodnoty ACC > 90 % se záznamem r01. Přes 80 % bylo dosaženo pro záznam r01 také u metod ANN-ADALINE a ANN-ANFIS. Pro záznam r02 kromě zmíněné ESN dosahovala hodnot ACC přes 80 % také metoda ANN-ESN (viz Tab. 9).

Záznam	ADALINE	ANN-ADALINE	ANFIS	ANN-ANFIS	ESN	ANN-ESN
r01	97,01 %	89,20 %	96,82 %	88,29 %	99,27 %	97,78 %
r02	31,92 %	71,20 %	31,76 %	64,05 %	91,19 %	87,74 %
r03	64,04 %	14,55 %	48,98 %	11,08 %	92,63 %	15,21 %
r04	48,40 %	32,57 %	52,15 %	30,49 %	96,95 %	84,42 %
r05	97,75 %	99,60 %	97,82 %	99,57 %	99,53 %	99,46 %
r06	33,02 %	30,38 %	32,87 %	37,14 %	56,61 %	33,74 %
r07	30,82 %	10,40 %	30,42 %	11,17 %	65,99 %	32,72 %
r08	40,42 %	13,11 %	41,47 %	19,13 %	63,31 %	20,06 %
r09	25,09 %	11,83 %	24,45 %	17,34 %	93,29 %	14,09 %
r10	23,13 %	9,16 %	27,18 %	9,21 %	54,95 %	22,19 %
Průměr	49,16 %	38,20 %	48,39 %	38,75 %	81,37 %	50,74 %

Tab. 9: Hodnoty ACC pro jednotlivé extrakční metody s použitím CWT detektoru; Pregnancy dataset.

Shrnutí nejvhodnější varianty metody a detektoru pro záznamy r01–r10 je uvedeno v Tab. 10. Celkem pro 8 z 10 záznamů byla nejvhodnější metoda ESN, z toho v 7 případech s využitím detektoru CWT. U záznamů r05 a r06 dosahovala nejvyšší hodnoty ACC metoda ANN-ADALINE, pro záznam r05 s detektorem CWT, pro záznam r06 s detektorem ANN. Při využití detektoru ANN byla získána nejvyšší hodnota ACC pouze pro záznam r02 a r05, v ostatních případech byl vhodnější detektor CWT. Nejvyšší hodnoty ACC 99,60 % bylo dosaženo u záznamu r05, nejnižší pro záznam r10 s hodnotou 54,95 %. Nejlepších výsledků bylo dosaženo kombinací extrakční metody ESN s využitím detektoru CWT, proto byly výsledky i se stanovenými parametry a kombinacemi svodů vypsány v Tab. 11.

Záznam	Metoda	Detektor	ACC (%)
r01	ESN	CWT	99,27
r02	ESN	ANN	96,46
r03	ESN	CWT	92,63
r04	ESN	CWT	96,95
r05	ANN-ADALINE	CWT	99,60
r06	ANN-ADALINE	ANN	62,69
r07	ESN	CWT	65,99
r08	ESN	CWT	63,31
r09	ESN	CWT	93,29
r10	ESN	CWT	54,95

Tab. 10: Shrnutí nejvhodnějších metod dle ACC pro jednotlivé záznamy z databáze Pregnancy dataset.

Záznam	М	α	Svody	ACC (%)	F1 (%)	PPV (%)	SE (%)	Počet fQRS ref.	ТР	FP	FN
r01	10	0,4	2, 4	99,27	99,63	99,58	99,68	3118	3108	13	10
r02	20	0,3	2, 3, 4	91,19	95,39	94,77	96,02	2791	2680	148	111
r03	10	0,1	1, 4	92,63	96,17	95,95	96,32	2557	2465	104	92
r04	50	0,5	1, 4	96,95	98,45	98,38	98,52	2774	2733	45	41
r05	10	0,3	1, 2, 3, 4	99,53	99,76	99,64	99,89	2764	2761	10	3
r06	20	0,3	1, 4	56,61	72,29	70,74	73,91	2879	2128	880	751
r07	10	0,6	1, 2	65,99	79,51	78,10	80,98	3096	2507	703	589
r08	50	0,5	1, 4	63,31	77,53	76,53	78,56	2897	2276	698	621
r09	50	0,5	3, 4	93,29	96,53	95,36	97,73	2816	2752	134	64
r10	20	0,3	1, 4	54,95	70,93	57,90	91,52	2583	2364	1719	219

Tab. 11: Nastavené parametry pro metodu ESN a hodnoticí parametry získané CWT detektorem, kde M je počet neuronů v rezervoáru a α představuje míru zapomínání.

#### 7.3.2 Stanovení tepové frekvence z extrahovaných signálů

V další části byla ze stanovených R-kmitů vypočtena průměrná fHR a vykreslena v čase vůči referenční křivce. Průměrné hodnoty fHR i s referenčními hodnotami jsou uvedeny pro detektor ANN v Tab. 12 a pro detektor CWT v Tab. 13. V obou tabulkách byly zvýrazněny průměrné hodnoty fHR nacházející se v intervalu ± 5 bpm od referenční hodnoty. Z tabulek je patrné, že průměrných hodnot fHR ve stanoveném rozmezí bylo dosaženo ve více případech detektorem CWT.

U záznamu r01 a r05 se stanovené hodnoty fHR pro všechny metody nacházely v intervalu ± 5 bpm od reference pro oba detektory. Pro detektor CWT také navíc u záznamu r02. Do stanoveného intervalu nebyly zařazeny průměrné hodnoty fHR stanovené detektorem ANN u záznamu r08, r09 a r10. Nejbližší hodnota pro záznam r08, která byla menší o 13 bpm, byla poskytnuta metodou ANFIS, u záznamu r09 byly hodnoty fHR menší u jednotlivých metod o více jak 30 bpm a pro záznam r10 byla hodnota fHR daná metodou ESN větší o přibližně 18 bpm, ostatní metody poskytly nižší fHR než byla referenční hodnota o více jak 30 bpm (viz Tab. 12).

Pro záznam r07 a r10 nebyly stanovené průměrné fHR získané detektorem CWT v intervalu ± 5 bpm od referenční hodnoty. U záznamu r07 se hodnoty fHR dané metodami ESN a ANN-ESN nacházely do 6 bpm od referenční hodnoty. U záznamu r10 pro metody ESN a ANN-ESN byly stanovené hodnoty fHR větší o víc než 9 bpm, pro ostatní metody byly stanoveny nižší o více než 12 bpm (viz Tab. 13).

Záznam	ADALINE	ANN-ADALINE	ANFIS	ANN-ANFIS	ESN	ANN-ESN
ref. fHR (bpm)	fHR (bpm)	fHR (bpm)	fHR (bpm)	fHR (bpm)	fHR (bpm)	fHR (bpm)
r01 (156,1)	157,6	157,4	157,5	157,4	156,6	158,0
r02 (139,8)	144,4	143,2	145,1	142,6	141,1	145,1
r03 (128,1)	128,2	139,3	143,7	122,7	128,7	79,3
r04 (139,0)	125,8	73,9	126,5	73,73	139,8	99,3
r05 (138,5)	139,0	138,9	138,9	138,8	138,9	138,9
r06 (144,2)	67,92	145,8	83,4	148,0	75,1	88,06
r07 (155,1)	159,4	92,0	157,3	102,7	161,0	102,2
r08 (145,1)	113,7	83,15	132,1	78,14	130,8	81,8
r09 (141,1)	104,0	108,6	104,1	104,6	107,7	106,5
r10 (129,4)	97,2	88,5	88,51	89,9	148,17	88,4

Tab. 12: Průměrné hodnoty fHR stanovené detektorem ANN pro jednotlivé metody; Pregnancy dataset.

Tab. 13: Průměrné hodnoty fHR stanovené detektorem CWT pro jednotlivé metody; Pregnancy dataset.

Záznam	ADALINE	ANN-ADALINE	ANFIS	ANN-ANFIS	ESN	ANN-ESN
ref. fHR (bpm)	fHR (bpm)	fHR (bpm)	fHR (bpm)	fHR (bpm)	fHR (bpm)	fHR (bpm)
r01 (156,1)	156,9	157,2	156,7	157,1	156,3	156,6
r02 (139,8)	144,2	144,0	143,9	143,9	141,7	142,5
r03 (128,1)	127,1	107,7	127,4	103,9	128,7	80,2
r04 (139,0)	156,5	143,7	143,4	137,2	139,2	139,0
r05 (138,5)	139,3	138,8	139,1	138,8	138,8	138,9
r06 (144,2)	171,0	148,8	179,2	152,9	150,7	142,7
r07 (155,1)	164,1	92,2	168,1	94,6	160,8	161,0
r08 (145,1)	149,8	90,1	149,5	105,0	148,1	84,2
r09 (141,1)	136,9	104,7	135,3	116,5	144,6	120,6
r10 (129,4)	116,5	87,6	116,3	88,6	139,0	196,1

Byly také vykresleny průběhy stanovených fHR společně s referenční křivkou. Z detekovaných R-kmitů v extrahovaných signálech fEKG, pomocí detektoru ANN i detektoru CWT, byl vypočten R-R interval. Z intervalu byla následně stanovena fHR pro každý časový úsek. Na Obr. 34 lze pozorovat získané křivky pro metodu ADALINE, ANFIS a ESN u záznamu r05. V horním grafu byly vykresleny křivky po detekci R-kmitů detektorem ANN. Spodní graf zobrazuje průběh po detekci R-kmitů detektorem CWT. Z obrázků je patrné, že detektor CWT dosahuje přesnější detekce s vyhlazenými křivkami fHR odpovídající referenčním křivkám na rozdíl od detektoru ANN. Na Obr. 35 jsou vykresleny průběhy fHR v čase získané po extrakci metod ANN-ADALINE, ANN-ANFIS, ANN-ESN.



Obr. 34: Zobrazení fHR v čase pro metody ADALINE, ANFIS a ESN; záznam r05 Pregnancy dataset.



Obr. 35: Zobrazení fHR v čase pro metody ANN-ADALINE, ANN-ANFIS a ANN-ESN; záznam r05 Pregnancy dataset.

#### 7.3.3 Vizuální zhodnocení extrahovaných signálů

Extrahované signály fEKG získané pomocí jednotlivých metod byly také pro srovnání vykresleny. Na Obr. 36 jsou zobrazeny průběhy fEKG získané metodami ADALINE, ANFIS a ESN společně s prvním svodem aEKG. U vykreslených extrahovaných signálů fEKG metodou ADALINE a ANFIS jsou patrné původní mQRS komplexy, které u metody ESN byly úspěšně potlačeny. Části se zbylými mQRS komplexy jsou v extrahovaných signálech vyznačeny. Průběhy extrahovaných signálů fEKG získaných metodami ANN-ADALINE, ANN-ANFIS a ANN-ESN jsou vykresleny na Obr. 37. Zde lze vidět průběhy s potlačeným šumem až na místa, kde se nacházel původně mQRS komplex.



Obr. 36: Vykreslení průběhů extrahovaných fEKG signálů metodami ADALINE, ANFIS a ESN společně s původním aEKG signálem; záznam r05 Pregnancy dataset.



Obr. 37: Vykreslení průběhů extrahovaných fEKG signálů metodami ANN-ADALINE, ANN-ANFIS a ANN-ESN společně s původním aEKG signálem; záznam r05 Pregnancy dataset.

### 8 DISKUZE DOSAŽENÝCH VÝSLEDKŮ

V rámci této práce byly testovány metody využívající ANN pro extrakci fEKG signálu z aEKG signálů. Jednalo se o metody ADALINE, ANFIS, ESN a kombinaci těchto metod s vícevrstvou dopřednou ANN. Použití vícevrstvé dopředné ANN sloužilo v rámci předzpracování vstupního signálu do jednotlivých metod pro potlačení šumu a ponechání pouze R-kmitů. Dohromady bylo tedy aplikováno 6 metod pro testování extrakce. Po extrakci fEKG byly využity dva detektory, jeden využívající dopřednou vícevrstvou ANN, druhý byl založený na CWT. Výsledky extrakce a detekce lze vizuálně zhodnotit pomocí vykreslení tepové křivky získané z detekovaných R-kmitů vůči referenční křivce.

Na Obr. 38 jsou zobrazeny výsledné křivky fHR po extrakci metodami ADALINE, ANFIS, ESN a následné detekci R-kmitů detektorem CWT společně s referenční křivkou fHR. Z obrázku je patrné, že došlo k chybové detekci R-kmitů detektorem, kdy byly detekovány FP hodnoty, v tomto případě obzvláště u metody ADALINE. Chyba v detekci mohla být způsobena například rušením ve vstupním signálu, jak je zobrazeno na Obr. 39, kde byly vykresleny průběhy extrahovaných fEKG signálů společně s prvním vstupním svodem aEKG a skalpovým fEKG. Výsledky extrakce jsou tedy závislé na kvalitě vstupních signálů, kterou ovlivňuje umístění elektrod vůči pozici plodu, přilnavost elektrod, pohyby jak matky, tak plodu atd.



Obr. 38: Vykreslené křivky fHR získané pomocí metody ADALINE, ANFIS a ESN s CWT detektorem; záznam r02 Labour dataset.



Obr. 39: Zobrazení průběhů extrahovaných fEKG signálů metodami ADALINE, ANFIS a ESN při chybové detekci; záznam rO2 Labour dataset.

Nejen kvalita vstupních signálů, ale také jednotlivé parametry pro nastavení dané metody určují kvalitu výsledné extrakce. Například u metody ANFIS byly nastavovány 3 parametry: počet mf, tvar mf a počet epoch. Se zvyšujícím se počtem nastavených mf i epoch se zvyšovala výpočetní náročnost metody. U metody ESN byl čas výpočtu ovlivněn parametrem určující počet neuronů v rezervoáru, čím byl počet neuronů vyšší, tím se zvyšovala i časová náročnost na výpočet. Výsledky extrakce u metody ADALINE byly měněny především koeficientem učení. Velkou výhodou metody ADALINE je její jednoduchost a tím i časová nenáročnost. V Tab. 14 jsou uvedeny časy výpočtu pro délky signálu 5 min (data z Labour dataset) a 20 min (data z Pregnancy dataset). Použití metod v kombinaci s dopřednou vícevrstvou ANN nemělo vliv na časovou náročnost. Například pro nastavení u metody ANFIS s parametry 2 mf s Gaussovským tvarem a počtem epoch 10 byla doba trvání pro 5minutové záznamy 6 s, pro 20minutové 22 s. U metody ESN výpočet trval při zvolených 10 neuronech v rezervoáru přibližně 5 s pro 5minutové a 20 s pro 20minutové záznamy.

Metoda	Doba trvání signálu	Počet vzorků signálu	Čas výpočtu
	5 min	150 000	< 1 s
ADALINE	20 min	598 900	< 1 s
ANEIS	5 min	150 000	6–45 s
	20 min	598 900	22–180 s
FSN	5 min	150 000	5–15 s
	20 min	598 900	20–60 s

Tab. 14: Uvedené časy výpočtů pro jednotlivé metody.

Jelikož vstupní signál velmi ovlivňuje kvalitu výsledné extrakce, byl testován vliv aplikace dopředné vícevrstvé ANN před samotnou extrakcí fEKG jednotlivými metodami. Po použití ANN došlo k potlačení šumu a byly ponechány pouze R-kmity v signálu. Srovnání výsledné vhodné a nevhodné extrakce u metod ADALINE a ANN-ADALINE je zobrazeno na Obr. 40. Kde byl využit záznam r05 (Pregnancy dataset) pro ukázku vhodné extrakce a záznam r02 (Pregnancy dataset) pro ukázku nevhodné extrakce, zde i po extrakci byla ponechána mateřská komponenta. Jestliže se jednalo o kvalitní vstupní signál aEKG, dokázaly obě metody správně extrahovat fEKG signál. U metody ADALINE byly v některých případech viditelnější původní mQRS komplexy než u metody ANN-ADALINE, proto i z výše uvedených výsledků ACC v Tab. 9 vyplývá, že pokud se jednalo o kvalitní vstupní signál, v některých případech docházelo ke zlepšení následné detekce R-kmitů a zvýšení přesnosti metody. Ve většině případů však ANN-ADALINE dosahovala nižší hodnoty ACC než metoda ADALINE. Důvodem je, že vícevrstvá dopředná ANN byla trénována na kvalitním signálu, kde byla výrazná fetální složka, která však bývá u většiny reálných záznamů výrazně nižší.



Obr. 40: Srovnání vhodných a nevhodných extrahovaných průběhů fEKG získaných metodou ADALINE a ANN-ADALINE; záznam r05 (Pregnancy dataset) byl použit pro ukázku vhodné extrakce, záznam r02 (Pregnancy dataset) jako nevhodné extrakce.

Nejen u metody ADALINE, ale také u metod ANFIS a ESN, nedosahovala ve většině případů kombinace s dopřednou vícevrstvou ANN lepších výsledků ACC. Nejvyšších hodnot ACC bylo získáno metodou ESN, jak pro data z databáze Labour dataset (viz Tab. 4), tak pro data z databáze Pregnancy dataset (viz Tab. 10). V případě signálů z databáze Pregnancy dataset byla amplituda fetální složky výrazněji nižší než u mateřské komponenty, což bývá problém pro následnou extrakci metodami využívající ANN. V tomto případě se ukázala metoda ESN jako vhodnou variantou pro extrakci fEKG i z takovýchto signálů, kde dosahovala průměrné hodnoty ACC > 80 %. U záznamů pocházejících z Labour dataset byla průměrná hodnota ACC pro metodu téměř 80 %. Výsledky jsou velmi ovlivněny nastavenými parametry pro jednotlivé metody, zde byla brána v úvahu i výpočetní náročnost daných metod, proto by v některých případech mohlo dojít ke zvýšení hodnoty ACC. Také kombinace vstupních svodů aEKG záznamů ovlivňuje výslednou extrakci, kde je vhodné volit ručně dle vizuálního zhodnocení anebo pomocí algoritmu využitý počet svodů do vstupů metody.

Z výsledného extrahovaného signálu fEKG lze následně detekovat R-kmity, vypočítat R-R intervaly a stanovit fHR, která je důležitým ukazatelem stavu plodu. Velmi využívaný je detektor založený na CWT, proto byl využit pro porovnání s otestovaným detektorem využívající dopřednou vícevrstvou ANN. U záznamů z databáze Labour dataset poskytovala metoda ESN společně s detektorem ANN, nejvyšších hodnot ACC, při použití metod ADALINE nebo ANFIS byla výsledná detekce lepší s využitím detektoru CWT. Pro záznamy z databáze Pregnancy dataset byly vyšší hodnoty ACC dosaženy detektorem CWT. Detektor ANN je citlivější na šum a zbylé mateřské komponenty, které mohou být součástí fEKG signálu i po extrakci, obzvlášť jestliže je provedena extrakce z méně kvalitních signálů aEKG, které obsahují velmi nízkou fetální složku. Pro tyto signály se jeví jako lepší využití detektoru CWT.

## ZÁVĚR

Cílem práce bylo extrahovat fEKG signál s využitím metod založených na ANN. Nejdříve byla prostudována problematika zpracování NI-fEKG, při kterém je z aEKG signálu oddělena fetální složka od mateřské složky a šumu. Literární rešerše se zaměřovala na ty metody, které se zabývají eliminací nežádoucích složek v NI-fEKG signálu. V této práci byly testovány ANN s jednovrstvou i vícevrstvou strukturou.

Pro testování vybraných metod byla navržena SW aplikace, která umožňuje zobrazení vstupních signálů, jejich filtraci a následnou extrakci pomocí metod ADALINE, ANFIS, ESN a kombinaci těchto metod s vícevrstvou dopřednou ANN. V navržené aplikaci lze také stanovit fHR a vykreslit tepovou křivku. Výpočet fHR byl proveden na základě detekce R-kmitů dvěma detektory. První detektor byl založený na vícevrstvé dopředné ANN a k tomu byl pro srovnání využit detektor založený na CWT. Testování bylo provedeno na reálných datech z databáze Labour dataset a Pregnancy dataset. Labour dataset obsahoval 12 záznamů čtyřsvodového aEKG se vzorkovací frekvencí 500 Hz i se záznamem přímého skalpového fEKG. Pregnancy dataset obsahoval 10 záznamů čtyřsvodového aEKG taktéž se vzorkovací frekvencí 500 Hz. Součástí každého záznamu v použitých databázích byla i anotace s referenčními pozicemi R-kmitů, které byly využity pro zhodnocení extrakce a následné detekce.

Na základě stanovených R-kmitů byly vypočteny hodnoty TP, FP a FN, pomocí kterých byly určeny parametry ACC, F1, SE a PPV. Nejlepších výsledků dle průměrné hodnoty ACC dosahovala metoda ESN pro záznamy z obou databází. Pro záznamy z databáze Labour dataset bylo dosaženo u metody ESN průměrné hodnoty ACC 78,65 % s detektorem ANN. Metoda ESN dosahovala hodnot ACC > 90 % u 7 z 12 záznamů. Ostatní metody poskytovaly mnohem nižší hodnoty ACC: metoda ANN-ESN 63,39 %, metoda ANFIS 53,97 %, a u ostatních metod byly průměrné hodnoty ACC < 50 %. S využitím detektoru CWT došlo ke zvýšení průměrné hodnoty ACC u metod ADALINE, ANN-ADALINE, ANFIS a ANN-ANFIS. Pro metody ADALINE, ANFIS a ANN-ANFIS došlo ke zvýšení průměrné hodnoty ACC o více jak 10 %. U záznamů z databáze Pregnancy dataset byla nejvyšší dosažená průměrná hodnota ACC pouze 66,24 %, a to u metody ESN s využitím detektoru ANN. Hodnoty ACC > 90 % bylo dosaženo pouze u 4 z 10 záznamů. S využitím detektoru CWT se průměrná hodnota ACC u metody ESN zvýšila na 81,37 %, a u 6 z 10 záznamů bylo dosaženo metodou ESN hodnot ACC > 90 %. Zvýšení průměrné hodnoty ACC s použitím detektoru CWT bylo taktéž dosaženo u metod ADALINE, ANFIS a ANN-ESN, u těchto metod bylo však dosaženo průměrných hodnot ACC okolo 50 %. Mezi testovanými metodami bylo dosaženo nejlepších výsledků u metody ESN. Ve výsledku bylo vhodnější provést detekci pomocí detektoru CWT, ale například u databáze Labour dataset dosahovala metoda ESN v kombinaci s detektorem ANN v průměru vyšších hodnot ACC než s detektorem CWT. Možné příčiny jsou prodiskutovány v diskuzi, čímž byly všechny body zadání splněny.

Výsledky jsou velmi ovlivněny nastavením parametrů u jednotlivých metod. S využitím optimalizačních technik by mohlo být nalezeno, co nejvhodnější nastavení pro konkrétní metodu, čímž by došlo ke zlepšení výsledné extrakce fEKG. Vliv na extrakci mají také vstupní signály, jejichž kombinace mnohdy velmi ovlivňuje výstupní signál. Nejen kombinace svodů, ale také kvalita samotných vstupních aEKG signálů má taktéž vliv na výsledky extrakce. V tomto případě byly metody testovány na záznamech ze dvou databází, pro další vyhodnocení by mohly být metody otestovány na více aEKG záznamech, a to jak fyziologických, tak patologických. Problémem je však nedostatek takovýchto signálů, které by navíc obsahovaly i anotace s referenčními pozicemi R-kmitů pro následné zhodnocení.

Pro samotné zhodnocení metod bylo v tomto případě využito stanovení fHR, což je důležitý parametr pro sledování stavu plodu během těhotenství i porodu. V rámci další studie by mohla být zaměřena pozornost na morfologickou analýzu a využití ST analýzy, která v dnešní době doplňuje metodu KTG a provádí se z přímého fEKG zaznamenaného skalpovou elektrodou. Z testovaných metod by v tomto případě mohla mít potenciál metoda ESN, protože u některých záznamů dokázala lépe eliminovat mateřské složky bez zůstávajících kmitů než zbylé testované metody.

### LITERATURA

- [1] ČECH, Svatopluk, Drahomír HORKÝ a Miroslava SEDLÁČKOVÁ. *Přehled embryologie člověka*. Brno: Masarykova univerzita, 2011. ISBN 978-80-210-5414-1.
- [2] SLÍPKA, Jaroslav a Zbyněk TONAR. *Základy embryologie*. Praha: Univerzita Karlova, 2019. ISBN 978-80-246-4197-9.
- [3] FABIÁN, Ondřej a David KACHLÍK. *Patologická anatomie vývojových vad srdce*. Praha: Univerzita Karlova, 2020. ISBN 978-80-246-4605-3.
- [4] MATEÁŠIKOVÁ, Zuzana a Martina HANICOVÁ. NEJČASTĚJŠÍ PŘÍČINY PERINATÁLNÍCH ÚMRTÍ VE FNOL ZA POSLEDNÍCH 5 LET [online]. B.m.: Univerzita Palackého v Olomouci. 2017 [vid. 2021-11-01]. Dostupné z: http://old.lf.upol.cz/fileadmin/user\_upload/LFkliniky/hippokrat/Pracoviste/Patologie/Nejcastejsi\_priciny\_perinatalnich\_umrti\_ve\_FNOL\_za\_p oslednich\_5\_let.pdf
- [5] KARVOUNIS, E. C., M. G. TSIPOURAS, C. PAPALOUKAS, D. G. TSALIKAKIS, K. K. NAKA a D. I. FOTIADIS. A Non-invasive Methodology for Fetal Monitoring during Pregnancy. *Methods Inf Med* [online]. nedatováno, **2010**(49(3)), 238–253 [vid. 2021-10-20]. Dostupné z: doi:10.3414/ME09-01-0041
- [6] HASAN, MA, MBI REAZ, MI IBRAHIMY, MS HUSSAIN a J UDDIN. Detection and Processing Techniques of FECG Signal for Fetal Monitoring. *Biological Procedures Online* [online]. 2009, 11, 263–295 [vid. 2021-10-15]. ISSN 1480-9222. Dostupné z: doi:10.1007/s12575-009-9006-z
- JANKŮ, Petr. Analýza ST úseku fetálního EKG v intrapartální diagnostice [online]. Brno, 2007.
  Disertační práce. Lékařská fakulta Masarykovy univerzity. Dostupné z: https://is.muni.cz/th/38558/lf\_d/Disertacni\_prace\_Janku1\_\_2\_.pdf
- [8] VERNER, Miroslav. FETÁLNÍ EKG, ST ANALÝZA. *Moderní babictví* [online]. 2005, **6**, 4 [vid. 2021-10-12]. Dostupné z: https://www.levret.cz/publikace/casopisy/mb/2005-6/?pdf=111
- [9] CLIFFORD, Gari D, Ikaro SILVA, Joachim BEHAR a George B MOODY. Non-invasive fetal ECG analysis. *Physiological Measurement* [online]. 2014, **35**(8), 1521–1536 [vid. 2021-10-25]. ISSN 0967-3334, 1361-6579. Dostupné z: doi:10.1088/0967-3334/35/8/1521
- [10] STRAZZA, Annachiara, Agnese SBROLLINI, Valeria DI BATTISTA, Rita RICCI, Letizia TRILLINI, Ilaria MARCANTONI, Micaela MORETTINI, Sandro FIORETTI a Laura BURATTINI. PCG-Delineator: an Efficient Algorithm for Automatic Heart Sounds Detection in Fetal Phonocardiography. In: 2018 Computing in Cardiology Conference (CinC) [online]. 2018, s. 1–4 [vid. 2021-10-26]. ISSN 2325-887X. Dostupné z: doi:10.22489/CinC.2018.045
- [11] CHETLUR ADITHYA, Prashanth, Ravi SANKAR, Wilfrido Alejandro MORENO a Stuart HART. Trends in fetal monitoring through phonocardiography: Challenges and future directions. *Biomedical Signal Processing and Control* [online]. 2017, **33**, 289–305 [vid. 2021-10-26]. ISSN 1746-8094. Dostupné z: doi:10.1016/j.bspc.2016.11.007
- [12] SAMENI, Reza a Gari D. CLIFFORD. A Review of Fetal ECG Signal Processing; Issues and Promising Directions. *The open pacing, electrophysiology & therapy journal* [online]. 2010, **3**, 4–20 [vid. 2021-10-10]. ISSN 1876-536X. Dostupné z: doi:10.2174/1876536X01003010004

- [13] KOVÁCS, Ferenc, Csaba HORVÁTH, Ádám T. BALOGH a Gábor HOSSZÚ. Fetal phonocardiography—Past and future possibilities. *Computer Methods and Programs in Biomedicine* [online]. 2011, **104**(1), 19–25 [vid. 2021-10-31]. ISSN 0169-2607. Dostupné z: doi:10.1016/j.cmpb.2010.10.006
- [14] CHOURASIA, Vijay S., Anil Kumar TIWARI a Ranjan GANGOPADHYAY. A novel approach for phonocardiographic signals processing to make possible fetal heart rate evaluations. *Digital Signal Processing* [online]. 2014, **30**, 165–183 [vid. 2021-10-28]. ISSN 1051-2004. Dostupné z: doi:10.1016/j.dsp.2014.03.009
- [15] KHANDOKER, Ahsan, Emad IBRAHIM, Sayaka OSHIO a Yoshitaka KIMURA. Validation of beat by beat fetal heart signals acquired from four-channel fetal phonocardiogram with fetal electrocardiogram in healthy late pregnancy. *Scientific Reports* [online]. 2018, 8(1), 13635 [vid. 2022-01-12]. ISSN 2045-2322. Dostupné z: doi:10.1038/s41598-018-31898-1
- [16] LEE, Wesley, Julia DROSE, Joseph WAX, James D. GOLDBERG, Isabelle A. WILKINS, Carol BENSON, Mary C. FRATES, Mary T. DONOFRIO, Benjamin W. EIDEM, Joshua COPEL, Mary NORTON, Lynn SIMPSON, Leslie SCOUTT, Harris L. COHEN, Lin DIACON, J. Christian FOX, Pat FULGHAM, Charlotte HENNINGSEN, Adam HIETT, Lars JENSEN, Anthony ODIBO, Steven PERLMUTTER, Olga RASMUSSEN, Deborah RUBENS, Khaled SAKHEL, Shia SALEM, Jay SMITH a Lami YEO. AIUM practice guideline for the performance of fetal echocardiography. *Journal of Ultrasound in Medicine* [online]. 2013, **32**(6), 1067–1082 [vid. 2021-10-28]. ISSN 0278-4297. Dostupné z: doi:10.7863/ultra.32.6.1067
- [17] Cardiac screening examination of the fetus: guidelines for performing the 'basic' and 'extended basic' cardiac scan. Ultrasound in Obstetrics & Gynecology [online]. 2005, 27(1), 107–113 [vid. 2022-01-12]. ISSN 1469-0705. Dostupné z: doi:10.1002/uog.2677
- [18] PETERS, Maria, John CROWE, Jean-Francois PIÉRI, Hendrik QUARTERO, Barrie HAYES-GILL, David JAMES, Jeroen STINSTRA a Simon SHAKESPEARE. Monitoring the fetal heart non-invasively: a review of methods [online]. 2001, 29(5), 408–416 [vid. 2021-10-25]. Dostupné z: doi:10.1515/JPM.2001.057
- [19] GRIMM, Barbara, Jens HAUEISEN, Minna HUOTILAINEN, Silke LANGE, Peter Van LEEUWEN, Teresa MENENDEZ, Maria J. PETERS, Ekkehard SCHLEUSSNER a Uwe SCHNEIDER. Recommended Standards for Fetal Magnetocardiography. *Pacing and Clinical Electrophysiology* [online]. 2003, 26(11), 2121–2126 [vid. 2021-10-28]. ISSN 1540-8159. Dostupné z: doi:10.1046/j.1460-9592.2003.00330.x
- [20] QUARTERO, H. W. P., J. G. STINSTRA, E. G. M. GOLBACH, E. J. MEIJBOOM a M. J. PETERS. Clinical implications of fetal magnetocardiography. *Ultrasound in Obstetrics & Gynecology* [online]. 2002, 20(2), 142–153 [vid. 2021-11-01]. ISSN 1469-0705. Dostupné z: doi:10.1046/j.1469-0705.2002.00754.x
- [21] SEKI, Yusuke, Akihiko KANDORI, Yukio KUMAGAI, Mitsuru OHNUMA, Akihiko ISHIYAMA, Tetsuko ISHII, Yoshiyuki NAKAMURA, Hitoshi HORIGOME a Toshio CHIBA. Demonstration of Unshielded Fetal Magnetocardiography System Using Two-Dimensional Gradiometers. *IEEE Transactions on Applied Superconductivity* [online]. 2009, **19**(3), 857–860 [vid. 2021-12-12]. ISSN 1558-2515. Dostupné z: doi:10.1109/TASC.2009.2019032
- [22] MĚCHUROVÁ, Alena. *Kardiotokografie: minimum pro praxi*. 2. vydání. Praha: Maxdorf, 2014. ISBN 978-80-7345-388-6.

- [23] INGEMARSSON, Ingemar. Fetal Monitoring during Labor. *Neonatology* [online]. 2009, 95(4), 342–346 [vid. 2021-10-31]. ISSN 1661-7800, 1661-7819. Dostupné z: doi:10.1159/000209299
- [24] HRUBAN, Lukáš a Petr JANKŮ. Monitorování plodu: Kardiotokografie. Vybrané kapitoly Porodní asistence I a II [online]. 2021 [vid. 2021-10-28]. Dostupné z: https://is.muni.cz/do/rect/el/estud/lf/ps20/porodni\_asistence/web/pages/12\_03\_kardiotok ografie.html
- [25] PINAS, Ana a Edwin CHANDRAHARAN. Continuous cardiotocography during labour: Analysis, classification and management. *Best Practice & Research Clinical Obstetrics & Gynaecology* [online]. 2016, **30**, Intrapartum Fetal Surveillance, 33–47 [vid. 2021-10-25]. ISSN 1521-6934. Dostupné z: doi:10.1016/j.bpobgyn.2015.03.022
- [26] *Electronic Fetal Monitoring* [online]. [vid. 2022-01-12]. Dostupné z: https://www.meducination.com/courses/electronic\_fetal\_monitoring/
- [27] MĚCHUROVÁ, A., P. VELEBIL, P. JANKŮ a L. HRUBAN. Interpretace intrapartálního fetálního kardiotokogramu FIGO 2015. Česká Gynekologie [online]. 2016, 81(2), 89–91 [vid. 2021-10-30]. Dostupné z: https://www.porodniasistentky.info/wp-content/uploads/2016/08/p-2016-interpretace-intrapartalniho-fetalniho-kardiotokogramu-figo-2015.pdf
- [28] CHUDÁČEK, Václav, Jiří SPILKA, Miroslav BURŠA, Petr JANKŮ, Lukáš HRUBAN, Michal HUPTYCH a Lenka LHOTSKÁ. Open access intrapartum CTG database. *BMC Pregnancy and Childbirth* [online].
   2014, 14(1), 16 [vid. 2022-01-12]. ISSN 1471-2393. Dostupné z: doi:10.1186/1471-2393-14-16
- [29] AYRES-DE-CAMPOS, Diogo, Catherine Y. SPONG, Edwin CHANDRAHARAN a FIGO Intrapartum Fetal Monitoring Expert Consensus PANEL. FIGO consensus guidelines on intrapartum fetal monitoring: Cardiotocography. *International Journal of Gynecology & Obstetrics* [online]. 2015, 131(1), 13–24 [vid. 2021-11-05]. ISSN 1879-3479. Dostupné z: doi:10.1016/j.ijgo.2015.06.020
- [30] UVÍROVÁ, Kateřina. Poruchy srdečního rytmu ve fetálním období [online]. B.m.: LF UP v Olomouci. [vid. 2021-10-09]. Dostupné z: http://old.lf.upol.cz/fileadmin/user\_upload/LFkliniky/hippokrat/Pracoviste/Detska\_klinika/PORUCHY\_SRDECNIHO\_RYTMU\_VE\_FETALNIM\_OB DOBI.pdf
- [31] PENHAKER, Marek a Martin AUGUSTYNEK. *Zdravotnické elektrické přístroje 1*. Ostrava: Vysoká škola báňská Technická univerzita Ostrava, 2013. ISBN 978-80-248-3107-7.
- [32] JAROŠ, Rene, Radek MARTINEK a Radana KAHANKOVA. Non-Adaptive Methods for Fetal ECG Signal Processing: A Review and Appraisal. *Sensors* [online]. 2018, **18**(11), 3648 [vid. 2021-10-24]. Dostupné z: doi:10.3390/s18113648
- [33] DONG, Y., J. KOVARSKIY a W. K. JENKINS. The addition of adaptive comb filtering to sequential adaptive processing for fetal electrocardiograms (ECGs). In: 2016 50th Asilomar Conference on Signals, Systems and Computers: 2016 50th Asilomar Conference on Signals, Systems and Computers [online]. 2016, s. 1626–1630. Dostupné z: doi:10.1109/ACSSC.2016.7869655
- [34] ZHONG, Wei, Lijuan LIAO, Xuemei GUO a Guoli WANG. Fetal electrocardiography extraction with residual convolutional encoder–decoder networks. *Australasian Physical & Engineering Sciences in Medicine* [online]. 2019, **42**(4), 1081–1089 [vid. 2021-10-14]. ISSN 1879-5447. Dostupné z: doi:10.1007/s13246-019-00805-x

- [35] BEHAR, Joachim, Fernando ANDREOTTI, Sebastian ZAUNSEDER, Julien OSTER a Gari D. CLIFFORD. A practical guide to non-invasive foetal electrocardiogram extraction and analysis. *Physiological Measurement* [online]. 2016, **37**(5), R1 [vid. 2021-11-01]. ISSN 0967-3334. Dostupné z: doi:10.1088/0967-3334/37/5/R1
- [36] KAHANKOVA, Radana, Radek MARTINEK, Rene JAROŠ, Khosrow BEHBEHANI, Adam MATONIA, Michal JEZEWSKI a Joachim A. BEHAR. A Review of Signal Processing Techniques for Non-Invasive Fetal Electrocardiography. *IEEE Reviews in Biomedical Engineering* [online]. 2020, **13**, 51–73 [vid. 2021-10-28]. ISSN 1941-1189. Dostupné z: doi:10.1109/RBME.2019.2938061
- [37] AGOSTINELLI, Angela, Marla GRILLO, Alessandra BIAGINI, Corrado GIULIANI, Luca BURATTINI, Sandro FIORETTI, Francesco DI NARDO, Stefano R. GIANNUBILO, Andrea CIAVATTINI a Laura BURATTINI. Noninvasive Fetal Electrocardiography: An Overview of the Signal Electrophysiological Meaning, Recording Procedures, and Processing Techniques. Annals of Noninvasive Electrocardiology [online]. 2015, 20(4), 303–313 [vid. 2021-11-09]. ISSN 1542-474X. Dostupné z: doi:10.1111/anec.12259
- [38] KARVOUNIS, Evaggelos C., Markos G. TSIPOURAS, Dimitrios I. FOTIADIS a Katerina K. NAKA. An Automated Methodology for Fetal Heart Rate Extraction From the Abdominal Electrocardiogram. *IEEE Transactions on Information Technology in Biomedicine* [online]. 2007, **11**(6), 628–638 [vid. 2021-10-24]. ISSN 1558-0032. Dostupné z: doi:10.1109/TITB.2006.888698
- [39] REINHARD, Joscha, Barrie R. HAYES-GILL, Qian YI, Hendrike HATZMANN a Sven SCHIERMEIER. Comparison of non-invasive fetal electrocardiogram to Doppler cardiotocogram during the 1st stage of labor [online]. 2010, 38(2), 179–185 [vid. 2021-11-02]. ISSN 1619-3997. Dostupné z: doi:10.1515/jpm.2010.025
- [40] JEZEWSKI, Janusz, Adam MATONIA, Tomasz KUPKA, Dawid ROJ a Robert CZABANSKI. 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* [online]. 2012, 57(5), 383–394 [vid. 2021-11-02]. ISSN 1862-278X. Dostupné z: doi:10.1515/bmt-2011-0130
- [41] MAROSSERO, Dorothee, Tammy Y. EULIANO, II Neil Russell EULIANO a Jose C. PRINCIPE. Maternal-fetal monitoring system [online]. US8275451B2. 25. září 2012. [vid. 2021-11-02]. Dostupné z: https://patents.google.com/patent/US8275451/en
- [42] MARTENS, Suzanna M. M., Chiara RABOTTI, Massimo MISCHI a Rob J. SLUIJTER. A robust fetal ECG detection method for abdominal recordings [online]. 2007, 28(4), 373–388 [vid. 2021-11-09]. ISSN 0967-3334. Dostupné z: doi:10.1088/0967-3334/28/4/004
- [43] CLIFFORD, Gari, Reza SAMENI, Jay WARD, Julian ROBINSON a Adam J. WOLFBERG. Clinically accurate fetal ECG parameters acquired from maternal abdominal sensors. *American Journal of Obstetrics and Gynecology* [online]. 2011, 205(1), 47.e1-47.e5 [vid. 2021-11-09]. ISSN 0002-9378. Dostupné z: doi:10.1016/j.ajog.2011.02.066
- [44] AHMED, Mahmoud, Suliman ALI a Xiaoping ZENG. A Novel Technique for Extraction Foetal Electrocardiogram using Adaptive Filtering and Simple Genetic Algorithm. *American Journal of Biostatistics* [online]. 2010, 1(2), 75–81 [vid. 2021-11-02]. ISSN 1948-9889. Dostupné z: https://citeseerx.ist.psu.edu/viewdoc/download?doi=10.1.1.1019.5407&rep=rep1&type=pdf

- [45] VULLINGS, Rik, Chris PETERS, Massimo MISCHI, Guid OEI a Jan BERGMANS. Maternal ECG removal from non-invasive fetal ECG recordings. In: 2006 International Conference of the IEEE Engineering in Medicine and Biology Society [online]. 2006, s. 1394–1397 [vid. 2021-11-02]. ISSN 1557-170X. Dostupné z: doi:10.1109/IEMBS.2006.259675
- [46] ANDREOTTI, Fernando, Maik RIEDL, Tilo HIMMELSBACH, Daniel WEDEKIND, Niels WESSEL, Holger STEPAN, Claudia SCHMIEDER, Alexander JANK, Hagen MALBERG a Sebastian ZAUNSEDER. Robust fetal ECG extraction and detection from abdominal leads [online]. 2014, 35(8), 1551–1567 [vid. 2021-11-06]. ISSN 0967-3334. Dostupné z: doi:10.1088/0967-3334/35/8/1551
- [47] VULLINGS, Rik. *Non-invasive fetal electrocardiogram: analysis and interpretation*. Eindhoven: Technische Universteit Eindhoven, 2010. ISBN 978-90-386-2395-5.
- [48] CASTILLO, E., D. P. MORALES, G. BOTELLA, A. GARCÍA, L. PARRILLA a A. J. PALMA. Efficient wavelet-based ECG processing for single-lead FHR extraction. *Digital Signal Processing* [online]. 2013, 23(6), 1897–1909 [vid. 2021-11-08]. ISSN 1051-2004. Dostupné z: doi:10.1016/j.dsp.2013.07.010
- [49] JAGANNATH, D. J. a A. Immanuel SELVAKUMAR. Issues and research on foetal electrocardiogram signal elicitation. *Biomedical Signal Processing and Control* [online]. 2014, **10**, 224–244 [vid. 2021-11-06]. ISSN 1746-8094. Dostupné z: doi:10.1016/j.bspc.2013.11.001
- [50] MARTINEK, Radek, Radana KAHANKOVA, Rene JAROS, Katerina BARNOVA, Adam MATONIA, Michal JEZEWSKI, Robert CZABANSKI, Krzysztof HOROBA a Janusz JEZEWSKI. Non-Invasive Fetal Electrocardiogram Extraction Based on Novel Hybrid Method for Intrapartum ST Segment Analysis. *IEEE Access* [online]. 2021, **9**, 28608–28631 [vid. 2021-10-31]. ISSN 2169-3536. Dostupné z: doi:10.1109/ACCESS.2021.3058733
- [51] MARTINEK, Radek. Využití komplexních adaptivních metod zpracování signálů pro zpřesnění diagnostické kvality abdominálního fetálního elektrokardiogramu [online]. Ostrava, 2014 [vid. 2021-11-08]. Disertační práce. Vysoká škola báňská Technická univerzita Ostrava. Dostupné z: https://dspace.vsb.cz/bitstream/handle/10084/105753/MAR944\_FEI\_P1807\_2601V018\_201 4.pdf?sequence=1&isAllowed=y
- [52] VONDRÁK, Ivo. Neuronové sítě. In: Umělá inteligence a neuronové sítě [online]. Ostrava: Vysoká škola báňská - Technická univerzita Ostrava, 1994 [vid. 2021-12-01]. ISBN 80-7078-259-5. Dostupné z: http://vondrak.cs.vsb.cz/download/Neuronove\_site.pdf
- [53] VOLNÁ, Eva. Neuronové sítě 1 [online]. 2. Ostrava: Ostravská univerzita v Ostravě, 2008
  [vid. 2021-11-15]. Dostupné z: https://web.osu.cz/~Volna/Neuronove\_site\_skripta.pdf
- [54] MITRENGA, Michal. Konvoluční neuronová síť pro segmentaci obrazu [online]. Brno, 2018 [vid. 2021-12-12]. Bakalářská práce. Vysoké učení technické v Brně. Dostupné z: https://www.vut.cz/www\_base/zav\_prace\_soubor\_verejne.php?file\_id=177588
- [55] ŠKUTOVÁ, Hana. Extrakce plodového elektrokardiogramu metodami soft computingu [online]. Ostrava, 2016 [vid. 2021-12-02]. Diplomová práce. Vysoká škola báňská - Technická univerzita Ostrava. Dostupné z: https://dspace.vsb.cz/bitstream/handle/10084/115918/SKU0035\_FEI\_N2649\_3901T009\_201 6.pdf?sequence=1&isAllowed=y

- [56] REAZ, Mamun Bin Ibne a Lee Sze WEI. Adaptive linear neural network filter for fetal ECG extraction. In: *Proceedings of International Conference on Intelligent Sensing and Information Processing*, 2004 [online]. 2004, s. 321–324 [vid. 2021-10-25]. Dostupné z: doi:10.1109/ICISIP.2004.1287675
- [57] HASAN, M. A., M. I. IBRAHIMY a M. B. I. REAZ. Fetal ECG Extraction from Maternal Abdominal ECG Using Neural Network. *Journal of Software Engineering and Applications* [online]. 2009, 02(05), 330 [vid. 2021-11-29]. Dostupné z: doi:10.4236/jsea.2009.25043
- [58] JIA, Wenjuan, Chunlan YANG, Guocheng ZHONG, Mengying ZHOU a Shuicai WU. Fetal ECG extraction based on adaptive linear neural network. In: 2010 3rd International Conference on Biomedical Engineering and Informatics [online]. 2010, s. 899–902 [vid. 2021-11-22]. ISSN 1948-2922. Dostupné z: doi:10.1109/BMEI.2010.5639886
- [59] ALI, Hazem H. a Mohammed T. HAWEEL. Legendre based equalization for nonlinear wireless communication channels. In: 2013 Saudi International Electronics, Communications and Photonics Conference [online]. 2013, s. 1–4 [vid. 2021-12-10]. Dostupné z: doi:10.1109/SIECPC.2013.6550776
- [60] MA, Yaping, Yegui XIAO, Guo WEI a Jinwei SUN. Fetal ECG extraction using adaptive functional link artificial neural network. In: *Signal and Information Processing Association Annual Summit and Conference (APSIPA), 2014 Asia-Pacific* [online]. 2014, s. 1–4 [vid. 2021-11-20]. Dostupné z: doi:10.1109/APSIPA.2014.7041680
- [61] YIN, Ying, Mao YE, Dongxiao REN, Yuanxiang ZHU a Chenxue YANG. FECG Extraction Using Bayesian Inference and Neural Networks Approximation. *Journal of Computational Information Systems* [online]. 2010, 6, 1769–1778 [vid. 2021-12-02]. Dostupné z: https://www.researchgate.net/profile/Mao-Ye-25/publication/265008715\_FECG\_Extraction\_Using\_Bayesian\_Inference\_and\_Neural\_Network s\_Approximation/links/544660600cf2d62c304db6a5/FECG-Extraction-Using-Bayesian-Inference-and-Neural-Networks-Approximation.pdf
- [62] ASSALEH, K. a H. AL-NASHASH. A novel technique for the extraction of fetal ECG using polynomial networks. *IEEE Transactions on Biomedical Engineering* [online]. 2005, **52**(6), 1148–1152 [vid. 2021-11-10]. ISSN 1558-2531. Dostupné z: doi:10.1109/TBME.2005.844046
- [63] HASAN, M. A., M. B. I. REAZ a M. I. IBRAHIMY. Fetal electrocardiogram extraction and R-peak detection for fetal heart rate monitoring using artificial neural network and Correlation. In: *The* 2011 International Joint Conference on Neural Networks [online]. 2011, s. 15–20 [vid. 2021-11-15]. ISSN 2161-4407. Dostupné z: doi:10.1109/IJCNN.2011.6033193
- [64] PILÁT, Martin. Neuronové sítě RBF sítě a rekurentní sítě [online]. [vid. 2021-12-01]. Dostupné z: https://martinpilat.com/cs/prirodou-inspirovane-algoritmy/neuronove-site-rbf-siterekurentni-site
- [65] BEHAR, Joachim, Alistair E W JOHNSON, Julien OSTER a Gari CLIFFORD. An Echo State Neural Network for Foetal ECG Extraction Optimised by Random Search. Proc. Adv. Neural Inf. Process. Syst [online]. nedatováno, 2013, 5 [vid. 2021-11-30]. Dostupné z: https://www.physionet.org/files/random-search/1.0.0/BeharJohnsonOsterClifford\_RS\_example.pdf

- [66] LUKOŠEVIČIUS, Mantas a Vaidotas MAROZAS. Noninvasive fetal QRS detection using Echo State Network. In: Computing in Cardiology 2013 [online]. 2013, s. 205–208 [vid. 2021-12-06]. ISBN 978-1-4799-0886-8. Dostupné z: https://ieeexplore.ieee.org/abstract/document/6712447
- [67] BEHAR, Joachim, Alistair JOHNSON, Gari D. CLIFFORD a Julien OSTER. A Comparison of Single Channel Fetal ECG Extraction Methods. *Annals of Biomedical Engineering* [online]. 2014, 42(6), 1340–1353 [vid. 2021-11-28]. ISSN 1573-9686. Dostupné z: doi:10.1007/s10439-014-0993-9
- [68] ZHOU, Ziqun, Kejie HUANG, Yue QIU, Haibin SHEN a Zhaoyan MING. Morphology extraction of fetal electrocardiogram by slow-fast LSTM network. *Biomedical Signal Processing and Control* [online]. 2021, 68, 102664 [vid. 2021-12-01]. ISSN 1746-8094. Dostupné z: doi:10.1016/j.bspc.2021.102664
- [69] NASIRI, Maryam, Karim FAEZ a Ali Motie NASRABADI. 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) [online]. 2011, s. 456–461 [vid. 2021-11-29]. Dostupné z: doi:10.1109/ICSIPA.2011.6144151
- [70] PILÁT, Martin. *Hejna a kolonie* [online]. [vid. 2021-12-05]. Dostupné z: https://martinpilat.com/cs/prirodou-inspirovane-algoritmy/hejna-kolonie
- [71] KHANAM, Ruqaiya a Syed Naseem AHMAD. Selection of Wavelets for Evaluating SNR, PRD and CR of ECG Signal. International Journal of Engineering Science and Innovative Technology (IJESIT)
   [online]. 2013, 2(1), 8 [vid. 2021-12-06]. ISSN 2319-5967. Dostupné z: https://www.ijesit.com/Volume%202/Issue%201/IJESIT201301\_17.pdf
- [72] MARTINEK, Radek, Hana SKUTOVA, Radana KAHANKOVA, Petr KOUDELKA, Petr BILIK a Jiri KOZIOREK. Fetal ECG extraction based on adaptive neuro-fuzzy interference system. In: 2016 10th International Symposium on Communication Systems, Networks and Digital Signal Processing (CSNDSP) [online]. 2016, s. 1–6 [vid. 2021-11-15]. Dostupné z: doi:10.1109/CSNDSP.2016.7573973
- [73] PANIGRAHY, D. a P. K. SAHU. Extraction of fetal ECG signal by an improved method using extended Kalman smoother framework from single channel abdominal ECG signal. *Australasian Physical & Engineering Sciences in Medicine* [online]. 2017, **40**(1) [vid. 2021-11-30]. Dostupné z: doi:10.1007/s13246-017-0527-5
- [74] KIRANYAZ, Serkan, Onur AVCI, Osama ABDELJABER, Turker INCE, Moncef GABBOUJ a Daniel J. INMAN. 1D convolutional neural networks and applications: A survey. *Mechanical Systems and Signal Processing* [online]. 2021, **151**, 107398 [vid. 2021-12-12]. ISSN 0888-3270. Dostupné z: doi:10.1016/j.ymssp.2020.107398
- [75] LO, Fang-Wen a Pei-Yun TSAI. Deep Learning for Detection of Fetal ECG from Multi-Channel Abdominal Leads. In: 2018 Asia-Pacific Signal and Information Processing Association Annual Summit and Conference (APSIPA ASC) [online]. 2018, s. 1397–1401 [vid. 2021-11-28]. ISSN 2640-0103. Dostupné z: doi:10.23919/APSIPA.2018.8659503
- [76] FOTIADOU, Eleni a Rik VULLINGS. Multi-Channel Fetal ECG Denoising With Deep Convolutional Neural Networks. *Frontiers in Pediatrics* [online]. 2020, 8, 508 [vid. 2021-11-21]. ISSN 2296-2360. Dostupné z: doi:10.3389/fped.2020.00508

- [77] FOTIADOU, E., R. J. G. van SLOUN, J. O. E. H. van LAAR a R. VULLINGS. A dilated inception CNN-LSTM network for fetal heart rate estimation. *Physiological Measurement* [online]. 2021, 42(4), 045007 [vid. 2021-11-21]. ISSN 0967-3334. Dostupné z: doi:10.1088/1361-6579/abf7db
- [78] CHEN, Yunpeng, Haoqi FAN, Bing XU, Zhicheng YAN, Yannis KALANTIDIS, Marcus ROHRBACH, Yan SHUICHENG a Jiashi FENG. Drop an Octave: Reducing Spatial Redundancy in Convolutional Neural Networks With Octave Convolution. In: 2019 IEEE/CVF International Conference on Computer Vision (ICCV) [online]. Seoul, Korea (South): IEEE, 2019, s. 3434–3443 [vid. 2022-01-09]. ISBN 978-1-72814-803-8. Dostupné z: doi:10.1109/ICCV.2019.00353
- [79] VO, Khuong, Tai LE, Amir M. RAHMANI, Nikil DUTT a Hung CAO. An Efficient and Robust Deep Learning Method with 1-D Octave Convolution to Extract Fetal Electrocardiogram. *Sensors* [online]. 2020, 20(13), 3757 [vid. 2021-12-01]. Dostupné z: doi:10.3390/s20133757
- [80] BÍL, Tomáš. Hluboké neuronové sítě pro analýzu medicínských obrazových dat [online]. Brno, 2019 [vid. 2022-01-04]. Bakalářská práce. Vysoké učení technické v Brně. Dostupné z: https://www.vut.cz/www\_base/zav\_prace\_soubor\_verejne.php?file\_id=198072
- [81] ZHONG, Wei, Lijuan LIAO, Xuemei GUO a Guoli WANG. A deep learning approach for fetal QRS complex detection [online]. 2018, **39**(4), 045004 [vid. 2021-11-01]. ISSN 0967-3334. Dostupné z: doi:10.1088/1361-6579/aab297
- [82] LEE, Jun Seong, Minseok SEO, Sang Woo KIM a Minho CHOI. Fetal QRS Detection Based on Convolutional Neural Networks in Noninvasive Fetal Electrocardiogram. In: 2018 4th International Conference on Frontiers of Signal Processing (ICFSP) [online]. 2018, s. 75–78 [vid. 2021-11-21]. Dostupné z: doi:10.1109/ICFSP.2018.8552074
- [83] POSPÍCHAL, Ondřej. Neuronové sítě s ozvěnou stavu pro předpověď vývoje finančních trhů [online]. Brno, 2018 [vid. 2021-11-11]. Diplomová práce. Vysoké učení technické v Brně. Dostupné z: https://www.vut.cz/www\_base/zav\_prace\_soubor\_verejne.php?file\_id=172709
- [84] CHENG, Jie a Russell GREINER. Comparing Bayesian Network Classifiers [online]. 2013 [vid. 2022-01-06]. Dostupné z: http://arxiv.org/abs/1301.6684
- [85] MRÁZOVÁ, Iveta. Dobývání znalostí: Bayesovské modely. In: [online]. Univerzita Karlova v Praze. [vid. 2022-01-06]. Dostupné z: https://ksvi.mff.cuni.cz/~mraz/datamining/lecture/Dobyvani\_Znalosti\_Prednaska\_Bayes.pdf
- [86] ŽIŽKA, Jan. Support vector machines (SVM): Algoritmy podpůrných vektorů [online]. B.m.: Masarykova univerzita. 2005 [vid. 2021-12-15]. Dostupné z: https://is.muni.cz/el/1433/podzim2006/PA034/09\_SVM.pdf
- [87] FU, Yumei, Shihan XIANG, Tianyi CHEN, Ping ZHOU a Weiyan HUANG. Noninvasive extraction of fetal electrocardiogram based on Support Vector Machine. In: AOPC 2015: Advanced Display Technology; and Micro/Nano Optical Imaging Technologies and Applications [online]. B.m.: SPIE, 2015, s. 140–146 [vid. 2021-12-13]. Dostupné z: doi:10.1117/12.2199662
- [88] LIAO, Lijuan, Wei ZHONG, Xuemei GUO a Guoli WANG. A Mixed Approach for Fetal QRS Complex Detection. In: Yingmin JIA, Junping DU a Weicun ZHANG, ed. *Proceedings of 2018 Chinese Intelligent Systems Conference* [online]. Singapore: Springer, 2018, s. 387–395 [vid. 2021-12-02]. Lecture Notes in Electrical Engineering. ISBN 9789811322884. Dostupné z: doi:10.1007/978-981-13-2288-4\_38

- [89] PESCHEL, Jakub. *Kategorizace obrazových dat* [online]. Brno, 2017 [vid. 2021-12-13]. Diplomová práce. Masarykova Univerzita. Dostupné z: https://is.muni.cz/th/fnsxx/diplomka.pdf
- [90] DELGADO, Juan A., Miguel ALTUVE a Masun Nabhan HOMSI. Haar wavelet transform and principal component analysis for fetal QRS classification from abdominal maternal ECG recordings. In: 2015 20th Symposium on Signal Processing, Images and Computer Vision (STSIVA) [online]. 2015, s. 1–6 [vid. 2021-12-05]. Dostupné z: doi:10.1109/STSIVA.2015.7330451
- [91] JAROŠ, René. Využití hybridních metod pro zpracování plodového elektrokardiogramu [online]. Ostrava, 2019 [vid. 2021-10-10]. Disertační práce. Vysoká škola báňská - Technická univerzita Ostrava. Dostupné z: http://dspace.vsb.cz/handle/10084/139182
- [92] KONOPKA, Ondřej. *Analýza nezávislých komponent* [online]. [vid. 2022-03-13]. Dostupné z: http://amber.feld.cvut.cz/bio/konopka/file/LBR-semestralka.pdf
- [93] BOHRN, Marek. Perspektivní obvodové struktury pro modulární neuronové sítě [online]. Brno, 2014 [vid. 2022-03-13]. Disertační práce. Vysoké učení technické v Brně. Dostupné z: https://www.vut.cz/www\_base/zav\_prace\_soubor\_verejne.php?file\_id=94276
- [94] MACEČEK, Aleš. Rychlost učení vícevrstvé sítě [online]. Brno, 2011 [vid. 2022-03-18]. Bakalářská práce. Vysoké učení technické v Brně. Dostupné z: https://www.vut.cz/www\_base/zav\_prace\_soubor\_verejne.php?file\_id=36627
- [95] MIKOLÁŠOVÁ, Martina. Extrakce plodového elektrokardiogramu pomocí adaptivního lineárního neuronu [online]. Ostrava, 2018 [vid. 2022-01-12]. Bakalářská práce. Vysoká škola báňská -Technická univerzita Ostrava. Dostupné z: https://dspace.vsb.cz/bitstream/handle/10084/128623/MIK0329\_FEI\_B2649\_3901R039\_201 8.pdf?sequence=1&isAllowed=y
- [96] PAN, Jiapu a Willis J. TOMPKINS. A Real-Time QRS Detection Algorithm. *IEEE Transactions on Biomedical Engineering* [online]. 1985, **BME-32**(3), 230–236. ISSN 1558-2531. Dostupné z: doi:10.1109/TBME.1985.325532
- [97] MARTINEK, Radek, Radana KAHANKOVA, Boris MARTIN, Jan NEDOMA a Marcel FAJKUS. A novel modular fetal ECG STAN and HRV analysis: Towards robust hypoxia detection. *Technology and Health Care* [online]. 2019, 27(3), 257–287 [vid. 2022-03-20]. ISSN 0928-7329. Dostupné z: doi:10.3233/THC-181375
- [98] ŠMÍD, Radislav. *Úvod do vlnkové transformace* [online]. B.m.: ČVUT Praha. 2001 [vid. 2022-03-20]. Dostupné z: https://docplayer.cz/19249380-Uvod-do-vlnkove-transformace.html
- [99] MATONIA, Adam, Janusz JEZEWSKI, Tomasz KUPKA, Michał JEZEWSKI, Krzysztof HOROBA, Janusz WROBEL, Robert CZABANSKI a Radana KAHANKOWA. Fetal electrocardiograms, direct and abdominal with reference heartbeat annotations. *Scientific Data* [online]. 2020, 7(1), 200 [vid. 2021-10-14]. ISSN 2052-4463. Dostupné z: doi:10.1038/s41597-020-0538-z

# SEZNAM PŘÍLOH

- **Příloha I** Experiment na datech z databáze Labour dataset
- **Příloha II** Experiment na datech z databáze Pregnancy dataset
- Příloha III Navržené GUI s kódem v programu MATLAB
- Příloha IV Záznamy Labour dataset
- Příloha VZáznamy Pregnancy datasetPříloha v IS EDISON

Příloha v IS EDISON

Příloha v IS EDISON

## PŘÍLOHA I Experiment na datech z databáze Labour dataset

Příloha obsahuje tabulky s nastavenými parametry a výsledky získanými pro jednotlivé metody.

Záznam	μ	Svody	ACC (%)	F1 (%)	PPV (%)	SE (%)	Počet fQRS ref.	ТР	FP	FN
r01	0,0005	1, 2, 3, 4	96,49	98,21	98,14	98,29	644	633	12	11
r02	0,001	1, 2, 3, 4	17,8	30,21	35,37	26,37	637	168	307	469
r03	0,0003	1, 2, 3, 4	14,67	25,59	32,54	21,09	716	151	313	565
r04	0,0009	1, 2, 3, 4	12,92	22,88	29,6	18,65	681	127	302	554
r05	0,0001	1, 2, 3, 4	99,1	99,55	99,4	99,7	660	658	4	2
r06	0,001	1, 2, 3, 4	16,84	28,83	37,95	23,25	684	159	260	525
r07	0,0009	1, 2, 3, 4	12,3	21,91	26,83	18,51	632	117	319	515
r08	0,001	1, 2, 3, 4	98,62	99,3	99,23	99,38	645	641	5	4
r09	0,002	1, 2, 3, 4	16,06	27,68	34,75	23	674	155	291	519
r10	0,001	1, 3, 4	10,45	18,93	24,37	15,47	627	97	301	530
r11	0,005	1, 3, 4	92,16	95,92	95,41	96,44	646	623	30	23
r12	0,001	1, 2, 3, 4	81,32	89,7	89,29	90,11	657	592	71	65

Tabulka 1: Nastavení parametrů a výsledky získané detektorem ANN pro metodu ADALINE

Tabulka 2: Nastavení parametrů a výsledky získané detektorem CWT pro metodu ADALINE

Záznam	μ	Svody	ACC (%)	F1 (%)	PPV (%)	SE (%)	Počet fQRS ref.	ТР	FP	FN
r01	0,0005	1, 2, 3, 4	97,09	98,52	98,45	98,6	644	635	10	9
r02	0,001	1, 2, 3, 4	60,56	75,44	78,74	78,34	637	499	187	138
r03	0,0003	1, 2, 3, 4	23,28	37,77	38,12	37,43	716	268	435	448
r04	0,0009	1, 2, 3, 4	38,14	55,22	55,67	54,77	681	373	297	308
r05	0,0001	1, 2, 3, 4	91,27	95,44	94,24	96,67	660	638	39	22
r06	0,001	1, 2, 3, 4	63,69	77,82	75,52	80,26	684	549	178	135
r07	0,0009	1, 2, 3, 4	25,76	40,96	43,03	39,08	632	247	327	385
r08	0,001	1, 2, 3, 4	99,69	99,84	98,84	99,84	645	644	1	1
r09	0,002	1, 2, 3, 4	68,71	81,46	79,89	83,09	674	560	141	114
r10	0,001	1, 3, 4	38,94	56,06	54,61	57,58	627	361	300	266
r11	0,005	1, 3, 4	89,39	94,4	93,61	95,2	646	615	42	31
r12	0,001	1, 2, 3, 4	84,45	91,57	91,36	91,78	657	603	57	54

Záznam	μ	Svody	ACC (%)	F1 (%)	PPV (%)	SE (%)	Počet fQRS ref.	ТР	FP	FN
r01	0,0005	1, 2, 3, 4	99,07	99,53	99,53	99,53	644	641	3	3
r02	0,001	1, 2, 4	24,07	38,8	41,12	36,73	637	234	335	403
r03	0,0003	1, 2, 3, 4	14,08	24,69	30,64	20,67	716	148	335	568
r04	0,0009	1, 2, 4	12,61	22,4	28,38	18,5	681	126	318	555
r05	0,0006	1, 2, 3, 4	97,01	98,48	98,78	98,18	660	648	8	12
r06	0,0006	1, 2, 4	18,45	31,16	38,49	26,17	684	179	286	505
r07	0,0009	1, 2, 3, 4	13,4	23,64	29,03	19,94	632	126	308	506
r08	0,0009	1, 2, 3, 4	97,25	98,6	98,6	98,6	645	636	9	9
r09	0,003	1, 3, 4	13,21	23,34	30,26	18,99	674	128	295	546
r10	0,001	1, 2, 4	11,32	20,33	26,26	15,69	627	104	292	523
r11	0,0005	1, 3, 4	96,02	97,97	98,9	97,06	646	627	7	6
r12	0,002	1, 2, 3, 4	79	88,27	87,8	88,74	657	583	81	74

Tabulka 3: Nastavení parametrů a výsledky získané detektorem ANN pro metodu ANN-ADALINE

Tabulka 4: Nastavení parametrů a výsledky získané detektorem CWT pro metodu ANN-ADALINE

Záznam	μ	Svody	ACC (%)	F1 (%)	PPV (%)	SE (%)	Počet fQRS ref.	ТР	FP	FN
r01	0,0005	1, 2, 3, 4	95,98	97,95	99,52	96,43	644	621	3	23
r02	0,001	1, 2, 4	33,98	50,73	49,55	51,96	637	331	337	306
r03	0,0003	1, 2, 3, 4	11,43	20,52	24,61	17,6	716	126	386	590
r04	0,0009	1, 2, 4	19,13	32,11	35,87	29,07	681	198	354	483
r05	0,0006	1, 2, 3, 4	96,99	98,47	99,23	97,73	660	645	5	15
r06	0,0006	1, 2, 4	43,87	60,99	60,29	61,7	684	422	278	262
r07	0,0009	1, 2, 3, 4	9	16,51	20,28	13,92	632	88	346	544
r08	0,0009	1, 2, 3, 4	100	100	100	100	645	645	0	0
r09	0,003	1, 3, 4	26,93	42,43	42,88	41,99	674	283	377	391
r10	0,001	1, 2, 4	22,86	37,21	40,45	34,45	627	216	318	411
r11	0,0005	1, 3, 4	95,63	97,76	97,39	98,14	646	634	17	12
r12	0,002	1, 2, 3, 4	72,34	83,95	83,13	84,78	657	557	113	100

Záznam	mf	Tvar mf	Svody	ACC (%)	F1 (%)	PPV (%)	SE (%)	Počet fQRS ref.	ТР	FP	FN
r01	2	Gauss	1, 2, 3, 4	99,07	99,53	99,53	99 <i>,</i> 53	644	641	3	3
r02	2	Gauss	1, 2, 3, 4	44,28	61,38	58,66	64,36	637	410	289	227
r03	2	Zvonová	1, 2, 3, 4	15	26,09	35,5	21,79	716	156	324	560
r04	2	Zvonová	1, 2, 3, 4	16,72	28,65	35,03	24,53	681	165	306	516
r05	2	Zvonová	1, 2, 3, 4	98,2	99,09	99,09	99,09	660	654	6	6
r06	2	Zvonová	1, 2, 3, 4	40,75	57,91	60,64	55,41	684	379	246	305
r07	4	Zvonová	1, 2, 3, 4	11,88	21,24	26,16	26,16	632	113	319	519
r08	2	Zvonová	1, 2, 3, 4	99,23	99,61	99,54	99,69	645	643	3	2
r09	2	Zvonová	1, 2, 3, 4	28,09	43,86	48,91	39,76	674	268	280	406
r10	4	Gauss	1, 2, 3, 4	13,02	23,05	29,72	18,82	627	118	279	509
r11	2	Zvonová	1, 3, 4	97,71	98,84	98,61	99,07	646	640	9	6
r12	2	Gauss	1, 2, 3, 4	83,63	91,08	90,4	91,78	657	603	64	54

Tabulka 5: Nastavení parametrů a výsledky získané detektorem ANN pro metodu ANFIS

Tabulka 6: Nastavení parametrů a výsledky získané detektorem CWT pro metodu ANFIS

Záznam	mf	Tvar mf	Svody	ACC (%)	F1 (%)	PPV (%)	SE (%)	Počet fQRS ref.	ТР	FP	FN
r01	2	Gauss	1, 2, 3, 4	92,69	96,2	95,98	96,43	644	621	26	23
r02	2	Gauss	1, 2, 3, 4	66,96	80,22	78,13	82,42	637	525	147	112
r03	2	Zvonová	1, 2, 3, 4	24,23	39,01	39,63	38,41	716	275	419	441
r04	2	Zvonová	1, 2, 3, 4	39,37	56,5	55,89	57,12	681	389	307	292
r05	2	Zvonová	1, 2, 3, 4	89	94,18	92,79	95,61	660	631	49	29
r06	2	Zvonová	1, 2, 3, 4	76,31	86,56	85,57	87,57	684	599	101	85
r07	4	Zvonová	1, 2, 3, 4	19,17	32,17	35,94	29,11	632	184	328	448
r08	2	Zvonová	1, 2, 3, 4	98,62	99,3	99,23	99,38	645	641	5	4
r09	2	Zvonová	1, 2, 3, 4	57,54	73 <i>,</i> 04	71,94	74,18	674	500	191	174
r10	4	Gauss	1, 2, 3, 4	37,24	54,26	52,37	56 <i>,</i> 3	627	353	321	274
r11	2	Zvonová	1, 3, 4	91,18	95 <i>,</i> 39	94,8	95,98	646	620	34	26
r12	2	Gauss	1, 2, 3, 4	86,4	92,7	92,56	92,85	657	610	49	47

Záznam	mf	Tvar mf	Svody	ACC (%)	F1 (%)	PPV (%)	SE (%)	Počet fQRS ref.	ТР	FP	FN
r01	2	Gauss	1, 2, 3, 4	99,07	99,53	99,53	99,53	644	641	3	3
r02	6	Zvonová	1, 3, 4	19,22	32,25	35,54	29,51	637	188	341	449
r03	2	Zvonová	1, 2, 3, 4	14,18	24,83	30,79	20,81	716	149	335	567
r04	6	Zvonová	1, 2, 4	12,85	22,78	28,89	18,8	681	128	315	553
r05	2	Zvonová	1, 2, 3, 4	95,84	97,87	98,02	97,73	660	645	13	15
r06	4	Gauss	1, 2, 4	15,01	26,1	33,96	21,2	684	145	282	539
r07	4	Zvonová	1, 2, 3, 4	13,04	23,08	28,34	19,46	632	123	311	509
r08	2	Zvonová	1, 2, 3, 4	97,86	98,91	98,76	99,07	645	639	8	6
r09	4	Gauss	1, 2, 3, 4	13,99	24,56	31	20,33	674	137	305	537
r10	6	Gauss	1, 2, 4	10,81	19,51	25,13	15,95	627	100	298	527
r11	2	Zvonová	1, 3, 4	95,25	97,57	98,89	96,28	646	622	7	24
r12	2	Gauss	1, 2, 4	75,39	85,97	84,76	87,21	657	573	103	84

Tabulka 7: Nastavení parametrů a výsledky získané detektorem ANN pro metodu ANN-ANFIS

Tabulka 8: Nastavení parametrů a výsledky získané detektorem CWT pro metodu ANN-ANFIS

Záznam	mf	Tvar mf	Svody	ACC (%)	F1 (%)	PPV (%)	SE (%)	Počet fQRS ref.	ТР	FP	FN
r01	2	Gauss	1, 2, 3, 4	98,15	99,07	99,07	99,07	644	638	6	6
r02	6	Zvonová	1, 3, 4	60,05	75,03	73,24	76,92	637	490	179	147
r03	2	Zvonová	1, 2, 3, 4	11,21	20,16	24,4	17,18	716	123	381	593
r04	6	Zvonová	1, 2, 4	25,93	41,18	44,89	38,03	681	259	318	422
r05	2	Zvonová	1, 2, 3, 4	94,99	97,43	97,14	97,73	660	645	19	15
r06	4	Gauss	1, 2, 4	77,68	87,44	86,87	88,01	684	602	91	82
r07	4	Zvonová	1, 2, 3, 4	9,21	16,87	20,69	14,24	632	90	345	542
r08	2	Zvonová	1, 2, 3, 4	100	100	100	100	645	645	0	0
r09	4	Gauss	1, 2, 3, 4	49,35	66,08	64,99	67,21	674	453	244	221
r10	6	Gauss	1, 2, 4	9,08	16,65	21,18	13,72	627	86	320	541
r11	2	Zvonová	1, 3, 4	95,63	97,76	97,39	98,14	646	634	17	12
r12	2	Gauss	1, 2, 4	80,22	89,02	88,55	89,5	657	588	76	69

Záznam	М	α	Svody	ACC (%)	F1 (%)	PPV (%)	SE (%)	Počet fQRS ref.	ТР	FP	FN
r01	10	0,4	1, 2, 3, 4	99,07	99,53	99,53	99,53	644	641	3	3
r02	20	0,3	1, 2, 3, 4	90,6	95,07	93,34	96,86	637	617	44	20
r03	50	0,5	1, 2, 3, 4	51,05	67,6	75,96	60,89	716	436	138	280
r04	50	0,3	1, 2, 3, 4	68,14	81,05	80,46	81,64	681	556	135	125
r05	20	0,2	1, 2, 3, 4	99,55	99,77	99,7	99,85	660	659	2	1
r06	50	0,4	1, 2, 3, 4	91,46	95,54	95,61	95,47	684	653	30	31
r07	50	0,2	1, 2, 3, 4	46,06	63,07	74,68	54,59	632	345	117	287
r08	10	0,3	1, 2, 3, 4	100	100	100	100	645	645	0	0
r09	50	0,4	1, 2, 3, 4	64,61	78,51	84,71	73,15	674	493	89	181
r10	50	0,1	1, 3, 4	37,35	54,39	53,92	54,86	627	344	294	283
r11	30	0,1	1, 3, 4	99,23	98,92	99,54	643	646	646	3	24
r12	30	0,2	1, 2, 3, 4	96,72	98,33	98,03	98,63	657	648	13	9

Tabulka 9: Nastavení parametrů a výsledky získané detektorem ANN pro metodu ESN

Tabulka 10: Nastavení parametrů a výsledky získané detektorem CWT pro metodu ESN

Záznam	М	α	Svody	ACC (%)	F1 (%)	PPV (%)	SE (%)	Počet fQRS ref.	ТР	FP	FN
r01	10	0,4	1, 2, 3, 4	99,38	99,69	99,54	99,84	644	643	3	1
r02	20	0,3	1, 2, 3, 4	87,32	93,23	91,4	95,13	637	606	57	31
r03	50	0,5	1, 2, 3, 4	50,39	67,01	63,05	71,51	716	512	300	204
r04	50	0,3	1, 2, 3, 4	32,93	49,54	81	35,68	681	243	57	438
r05	20	0,2	1, 2, 3, 4	97,46	97,71	98,79	98,64	660	651	8	9
r06	50	0,4	1, 2, 3, 4	87,11	95,54	92,37	93,86	684	642	53	42
r07	50	0,2	1, 2, 3, 4	8,33	15,39	20,59	9,97	632	63	124	569
r08	10	0,3	1, 2, 3, 4	100	100	100	100	645	645	0	0
r09	50	0,4	1, 2, 3, 4	91,78	95,71	33,69	9,97	674	648	32	26
r10	50	0,1	1, 3, 4	16,24	27,93	41,51	21,05	627	132	186	495
r11	30	0,1	1, 3, 4	95,58	97,74	98,43	97,06	646	627	10	19
r12	30	0,2	1, 2, 3, 4	99,39	99,7	99,7	99,7	657	655	2	2

Záznam	М	α	Svody	ACC (%)	F1 (%)	PPV (%)	SE (%)	Počet fQRS ref.	ТР	FP	FN
r01	10	0,4	1, 2, 3, 4	98	98,99	99,07	98,91	644	637	6	7
r02	20	0,3	1, 3, 4	65,48	79,14	83,33	75,35	637	480	96	157
r03	50	0,3	1, 2, 3, 4	21,06	34,79	48,62	27,09	716	194	205	522
r04	50	0,3	1, 2, 4	50,6	67,2	65,15	68,28	681	465	238	216
r05	20	0,2	1, 3, 4	96,83	98,39	99,53	97,27	660	642	3	18
r06	50	0,5	1, 3, 4	74,15	85,15	84,36	85,96	684	588	109	96
r07	50	0,2	1, 3, 4	7,78	14,44	21,3	10,92	632	69	255	563
r08	10	0,3	1, 3, 4	99,23	99,61	99,54	99,69	645	643	3	2
r09	50	0,4	1, 2, 3, 4	41,57	58,72	58,55	58,9	674	397	281	277
r10	50	0,1	1, 2, 3, 4	11,52	20,67	26,57	16,91	627	106	293	521
r11	30	0,1	1, 3, 4	96,7	98	97,55	98,45	646	636	16	10
r12	30	0,2	1, 2, 4	97,74	98,85	98,78	98,93	657	650	8	7

Tabulka 11: Nastavení parametrů a výsledky získané detektorem ANN pro metodu ANN-ESN

Tabulka 12: Nastavení parametrů a výsledky získané detektorem CWT pro metodu ANN-ESN

Záznam	М	α	Svody	ACC (%)	F1 (%)	PPV (%)	SE (%)	Počet fQRS ref.	ТР	FP	FN
r01	10	0,4	1, 2, 3, 4	97,85	98,91	98,91	98,91	644	637	7	7
r02	20	0,3	1, 3, 4	64,82	78,65	76,44	81	637	516	159	121
r03	50	0,3	1, 2, 3, 4	13,95	24,49	37,01	18,3	716	131	223	585
r04	50	0,3	1, 2, 4	33,93	50,67	59,37	44,2	681	301	206	380
r05	20	0,2	1, 3, 4	97,59	98,78	99,39	98,18	660	648	4	12
r06	50	0,5	1, 3, 4	59,15	74,33	73,53	75,15	684	514	185	170
r07	50	0,2	1, 3, 4	3,21	6,23	21,5	3,64	632	23	84	609
r08	10	0,3	1, 3, 4	100	100	100	100	645	645	0	0
r09	50	0,4	1, 2, 3, 4	61,31	76,02	74,5	58,9	674	523	179	151
r10	50	0,1	1, 2, 3, 4	8,67	15,96	20,45	13,08	627	82	319	545
r11	30	0,1	1, 3, 4	95,92	97,92	97,54	98,3	646	635	16	11
r12	30	0,2	1, 2, 4	95,25	97,57	97,42	97,72	657	642	17	15

## PŘÍLOHA II Experiment na datech z databáze Pregnancy dataset

Tato příloha obsahuje pro ukázku nastavení parametrů, kombinace svodů a výsledné hodnoty získané metodou ESN, která dosahovala nejlepších výsledků. Pro srovnání byly také vypsány parametry pro metodu ANN-ESN.

Záznam	М	α	Svody	ACC (%)	F1 (%)	PPV (%)	SE (%)	Počet fQRS ref.	ТР	FP	FN
r01	10	0,4	2, 4	98,32	99,15	99,01	99,29	3118	3096	31	22
r02	20	0,3	2, 3, 4	96,46	98,2	97,76	98,64	2791	2753	63	38
r03	10	0,1	1, 4	46,86	63,82	63,66	63,98	2557	1636	934	921
r04	10	0,2	1,2,3,4	91,6	95,61	98,21	93,15	2774	2584	47	190
r05	10	0,3	1, 2, 3, 4	99,5	99,74	99,6	99,89	2764	2761	11	3
r06	20	0,3	1, 4	47,71	64,59	94,33	49,11	2879	1414	85	1465
r07	10	0,6	1, 2	49,06	65,82	64,6	67,09	3096	2077	1138	1019
r08	50	0,2	1, 2, 3, 4	48,02	64,88	68,44	61,68	2897	1787	824	1110
r09	20	0,5	3, 4	53,16	69,42	80,15	61,22	2816	1724	427	1092
r10	10	0,1	1, 2, 3, 4	31,68	48,12	59,45	40,42	2583	1044	712	1539

Tabulka 13: Nastavení parametrů a výsledky získané detektorem ANN pro metodu ESN

Tabulka 14: Nastavení parametrů a výsledky získané detektorem CWT pro metodu ESN

Záznam	М	α	Svody	ACC (%)	F1 (%)	PPV (%)	SE (%)	Počet fQRS ref.	ТР	FP	FN
r01	10	0,4	2, 4	99,27	99,63	99,58	99,68	3118	3108	13	10
r02	20	0,3	2, 3, 4	91,19	95,39	94,77	96,02	2791	2680	148	111
r03	10	0,1	1, 4	92,63	96,17	95,95	96,32	2557	2465	104	92
r04	50	0,5	1, 4	96,95	98,45	98,38	98,52	2774	2733	45	41
r05	10	0,3	1, 2, 3, 4	99,53	99,76	99,64	99,89	2764	2761	10	3
r06	20	0,3	1, 4	56,61	72,29	70,74	73,91	2879	2128	880	751
r07	10	0,6	1, 2	65,99	79,51	78,1	80,98	3096	2507	703	589
r08	50	0,5	1, 4	63,31	77,53	76,53	78,56	2897	2276	698	621
r09	50	0,5	3, 4	93,29	96,53	95,36	97,73	2816	2752	134	64
r10	20	0,3	1, 4	54,95	70,93	57,9	91,52	2583	2364	1719	219

Záznam	М	α	Svody	ACC (%)	F1 (%)	PPV (%)	SE (%)	Počet fQRS ref.	ТР	FP	FN
r01	10	0,4	2, 4	88,46	93,88	93,34	94,42	3118	2944	210	174
r02	20	0,3	2, 3, 4	67,02	80,25	78,8	81,76	2791	2282	614	509
r03	10	0,1	1, 4	11,65	20,86	27,27	16,89	2557	432	1152	2125
r04	20	0,2	1,2,3,4	15,77	27,25	32,69	23,36	2774	2370	1334	2126
r05	20	0,3	1, 2, 3, 4	99,35	99,67	99,53	99,82	2764	2759	13	5
r06	10	0,5	1, 4	20,51	34,04	25,97	25,15	2879	724	651	2155
r07	10	0,5	1, 2	25,3	40,38	58,8	30,75	3096	952	667	2144
r08	20	0,3	1, 2, 3, 4	10,19	18,5	25,66	14,46	2897	419	1214	2478
r09	10	0,5	3, 4	12,99	22,99	26,73	20,17	2816	568	1557	2248
r10	40	0,1	1, 2, 3, 4	12,79	22,69	27,95	19,09	2583	493	1271	2090

Tabulka 15: Nastavení parametrů a výsledky získané detektorem ANN pro metodu ANN-ESN

Tabulka 16: Nastavení parametrů a výsledky získané detektorem CWT pro metodu ANN-ESN

Záznam	М	α	Svody	ACC (%)	F1 (%)	PPV (%)	SE (%)	Počet fQRS ref.	ТР	FP	FN
r01	10	0,4	2, 4	97,78	98,88	98,75	99,01	3118	3087	39	31
r02	20	0,3	2, 3, 4	87,74	93,47	92,58	94,37	2791	2634	211	157
r03	10	0,3	1, 4	15,21	26,4	34,27	21,47	2557	549	1053	2008
r04	20	0,2	1, 4	84,42	91,55	91,47	91,64	2774	2542	237	232
r05	20	0,3	1, 2, 3, 4	99,46	99,73	99,57	99,89	2764	2761	12	3
r06	10	0,5	1, 4	33,74	50,45	50,72	50,19	2879	1445	1404	1434
r07	10	0,5	1, 2	32,72	49,31	48,4	50,26	3096	1556	1659	1540
r08	20	0,3	1, 4	20,06	33,42	45,51	26,41	2897	765	916	2132
r09	10	0,5	3, 4	14,09	24,69	26,79	22,9	2816	645	1763	2171
r10	30	0,3	1, 4	22,19	36,32	30,15	45,68	2583	1180	2734	1403