

UNIVERZA V LJUBLJANI
FAKULTETA ZA RAČUNALNIŠTVO IN INFORMATIKO

GAŠPER FELE-ŽORŽ

NELINEARNA ANALIZA SIGNALOV ELEKTROMIOGRAMA
MATERNICE ZA NAPOVEDOVANJE PREZGODNJEGA
PORODA

DOKTORSKA DISERTACIJA

Ljubljana, 2010

Mentor: prof. dr. Franc Jager

ZAHVALA

Hvala vsem porodničarjem, obporodničarjem in pediatrom za delo, ki ga skrbno in nesebično opravlja, še posebej tistim, ki se ob prenatrpanem delovniku ukvarjajo še z različnimi raziskavami. Med njimi sem še posebej hvaležen mag. Gorazdu Kavšku, dr. med., ki je priskrbel posnetke, brez katerih tega doktorata ne bi bilo. Iskreno se zahvaljujem mentorju prof. dr. Francu Jagru, univ. dipl. inž. el., ki me je pri izdelavi doktorske disertacije vseskozi spremjal, usmerjal in mi svetoval. Hvala tudi prof. dr. Živi Novak-Antolič, dr. med. za vse nasvete, tudi tiste, ki z delom nimajo nikakršne zveze. Vsa slava Hipnožabi in Malemu Zelenemu Možu. Na koncu hvala dr. Gregorju Jeršetu za moralno pomoč pri reševanju matematičnih vprašanj in Nuši Zidarič za večkratno branje nedodelanih verzij te doktorske disertacije.

NELINEARNA ANALIZA SIGNALOV ELEKTROMIOGRAMA MATERNICE ZA NAPOVEDOVANJE PREZGODNJEGA PORODA

Gašper Fele-Žorž

Povzetek

Naš namen je bil preizkusiti različne tehnike obdelave signalov za obdelavo posnetkov električne aktivnosti maternice.

Raziskave smo izvajali na 1211 posnetkih, zajetih med leti 1997 in 2005. Večina posnetkov je vsebovala tri kanale z zapisom električne aktivnosti, 53 posnetkov pa je poleg zapisa električne aktivnosti vsebovalo tudi zapis ocene tlaka v maternici, zajet s pomočjo tokografa. Večina posnetkov je bila zajeta okrog 22. ali okrog 31. tedna nosečnosti, njihova dolžina pa je bila 30 minut. Poleg posnetkov so bili v večini primerov zapisani spremiščevalni podatki.

Posnetke smo pregledali in ocenili glede na prisotnost očitnih motenj. Spremljevalne podatke smo zbrali iz več virov in jih uredili. Posnetke in spremiščevalne podatke smo zapisali v relacijsko podatkovno bazo. Tako smo dobili bazo, ki je vsebovala 760 verjetno dobrih posnetkov, zajetih med 532 nosečnostmi, za katere so bili zbrani vsi potrebni spremiščevalni podatki. Vzpostavili smo sistem za hranjenje posnetkov, spremiščevalnih podatkov in rezultatov preračunavanj, izvedenih na posnetkih.

Signale smo predobdelali s šestimi različnimi pasovno-prepustnimi filtri, pri čemer smo za spodnjo mejo prepustnega območja izbrali vrednosti 0.08 Hz in 0.3 Hz, za zgornjo mejo pa vrednosti 2.5 Hz, 3 Hz in 4 Hz. Uporabili smo dvosmerno shemo filtriranja z Butterworthovimi filtri, s čimer smo obdržali prednosti filtrov z neskončnim odzivom na enotin impulz, izognili pa smo se faznemu popačenju, ki je sicer slabost teh filtrov.

Vse 30 minutne posnetke smo vedno obdelovali v celoti. S tem smo se izognili subjektivnim vplivom, ki bi bili prisotni pri eventualni analizi posameznih krčev maternice, kot to delajo drugi avtorji. Poleg tega smo na ta način ohranili informacije, ki jih morda vsebuje električna aktivnost maternice v času mirovanja. Z uporabo filtrov za predobdelavo signalov smo izločili večino šuma, tako da smo lahko obdelovali tudi posnetke, zajete zgodaj v nosečnosti, to je v 22. tednu, ko v posnetkih izrazite salve električne aktivnosti še niso nujno prisotne.

Za pregledovanje posnetkov smo razvili program z uporabniškim vmesnikom, ki omogoča prikaz različnih grafičnih predstavitev signalov. Uporabniški vmesnik podpira prikaz signalov kot časovnih vrst ter njihovih močnostnih spektrov. Poleg tega vmesnik za vsak signal

omogoča tudi prikaz spektrograma in Wigner-Ville-jeve časovno-frekvenčne predstavitev signala. Poleg grafičnih predstavitev signalov vmesnik prikaže tudi vrednosti različnih cenilk, ki se med obdelavo zapisujejo v podatkovno bazo. Grafični vmesnik omogoča izbiro posnetkov iz baze na osnovi pogojev, zapisanih v jeziku SQL.

Med pregledovanjem posnetkov, kjer je bila zajeta tudi ocena tlaka v maternici, smo opazili, da se med krči maternice električna aktivnost spremeni. Spremembe so bile še posebej opazne na prikazu Wigner-Ville-jeve časovno-frekvenčne predstavitev. Poleg različnih predstavitev signalov smo za nekatere posnetke izračunali tudi kratko-intervalne križno-korelacijske koeficiente med vsemi tremi kanali z zapisom električne aktivnosti maternice. Vrh križno-korelacijskih koeficientov je bil praviloma pri zamiku enakem nič vzorcev. Križno-korelacijski koeficienti so med krči maternice praviloma narasli. Pri posnetkih, kjer sta bila na voljo dva posnetka na nosečnost, smo opazovali spremembe močnostnega spektra signalov med nosečnostjo. V spektrih smo opazili več vrhov. V večini primerov so se pozno v nosečnosti vrhovi v močnostnih spektrih premaknili proti nižjim frekvencam.

Za vse signale smo poleg grafičnih prikazov izračunali več cenilk na osnovi različnih tehnik obdelave signalov. Tehnike smo razdelili na dve skupini - na linearne in nelinearne. Linearne tehnike so bile osnovane na močnostnem spektru. Mednje spadajo koren srednje vrednosti kvadratov signala, vrh močnostnega spektra signala, mediana frekvenca in prvi prehod preko ničel koeficientov avtokorelacije. Nelinearne tehnike so bile osnovane na ocenjevanju kompleksnosti signalov. Mednje sta spadali tehniki ocene maksimalnega eksponenta Ljapunova ter korelacijske dimenzije, ki sta obe osnovani na rekonstruiranem faznem prostoru stanja sistema, poleg njiju pa še vzorčna entropija in njena razširitev, to je večločljivostna vzorčna entropija, ki sta osnovani na podobnosti signalov samim sebi.

Uporabljene nelinearne tehnike obdelave signalov so računsko zahtevnejše od uporabljenih linearnih tehnik. Poleg tega nelinearne tehnike obdelave signalov zahtevajo več vhodnih podatkov oziroma daljše časovne vrste. Zadostno dolžino časovnih vrst za izračun cenilk, osnovanih na nelinearnih tehnikah obdelave signalov, smo dosegli z obdelavo celotnih 30 minutnih posnetkov električne aktivnosti maternice.

Običajni algoritem za izračun vzorčne entropije ima časovno zahtevnost $O(N^2)$, kjer je N dolžina signala. Razvili smo nov algoritem za izračun vzorčne entropije, katerega tipična časovna zahtevnost je $O(N \cdot \log(N))$. Pri razvoju novega algoritma smo uporabili učinkovito implementacijo podatkovne strukture preskakajoči seznam.

Med posnetki, ki smo jih ocenili kot dobre in kjer je bil porod spontan, smo izbrali po en posnetek na nosečnost. Tako dobljeno množico 382 posnetkov smo razdelili na skupine glede na trajanje nosečnosti in glede na čas zajema posnetka. Tako smo dobili štiri skupine: posnetke, kjer je bil porod prezgoden in so bili zajeti pred 26. tednom nosečnosti (19 posnetkov); posnetke, kjer je bil porod prezgoden in so bili zajeti po 26. tednu nosečnosti (24); posnetke, kjer je bil porod ob roku in so bili zajeti pred 26. tednom nosečnosti (163); posnetke, kjer je bil porod ob roku in so bili zajeti po 26. tednu nosečnosti (176). Nato smo s Studentovim t-testom izračunali verjetnosti, da so srednje vrednosti cenilk za pare skupin

enake. Tako smo dobili šest verjetnosti ($p_1 \dots p_6$), na osnovi katerih smo sklepali, katere tehnike utegnejo biti najbolj perspektivne za ločevanje skupin posnetkov. Med drugim smo ugotovili, da se že pri posnetkih, zajetih pred 26. tednom nosečnosti, večinoma okrog 22. tedna nosečnosti, električna aktivnost maternic v primerih, ko je bil porod prezgoden, v povprečju razlikuje od električne aktivnosti maternic v primerih, ko je bil porod ob roku.

Kot najbolj obetavni tehniki sta se izkazali mediana frekvenca in vzorčna entropija. Verjetnost, da je mediana frekvenca po predobdelavi s pasovno-prepustnim filtrom od 0.3 Hz do 3 Hz pri posnetkih, kjer je bil porod ob roku, enaka kot pri posnetkih, kjer je bil porod prezgoden (p_6), je bila 0.056. Verjetnost, da je bila ob uporabi istega filtra mediana frekvenca med posnetki, zajetimi okrog 31. tedna nosečnosti, kjer je bil porod prezgoden, enaka kot pri posnetkih, zajetih okrog 31. tedna, kjer je bil porod ob roku (p_2), je bila 0.046. Verjetnost, da je mediana frekvenca pri posnetkih, zajetih okrog 22. tedna nosečnosti enaka, kot pri posnetkih, zajetih okrog 31. tedna nosečnosti (p_5), je bila 0.003.

Verjetnosti, da so povprečne vrednosti cenilke enake za obe izbrani skupini, so bile najpogosteje majhne pri vzorčni entropiji. Verjetnost, da je vzorčna entropija pri $m = 3$ in $r = 0.15$ po predobdelavi s pasovno-prepustnim filtrom od 0.3 Hz do 3 Hz pri posnetkih, kjer je bil porod ob roku, enaka kot pri posnetkih, kjer je bil porod prezgoden (p_6), je bila 0.005. Verjetnost, da je bila ob uporabi istega filtra mediana frekvenca med posnetki, zajetimi okrog 31. tedna nosečnosti, kjer je bil porod prezgoden, enaka kot pri posnetkih, zajetih okrog 31. tedna, kjer je bil porod ob roku (p_2), je bila 0.042. Verjetnost, da je mediana frekvenca pri posnetkih, zajetih okrog 22. tedna nosečnosti enaka, kot pri posnetkih, zajetih okrog 31. tedna nosečnosti (p_5), je bila manj kot 0.001.

V primerih, ko sta bila na voljo po dva posnetka električne aktivnosti maternice na nosečnost, smo s pomočjo vezanega Studentovega t-testa izračunali verjetnosti, da se vrednosti cenilk med nosečnostjo niso spremenile (p_5). Te verjetnosti so bile nizke pri večini cenilk. Ob uporabi primernih filtrov je bila verjetnost, da se mediana frekvenca med nosečnostjo ni spremenila, manjša od 0.001. Verjetnost, da se vzorčna entropija med nosečnostjo ni spremenila, je bila največ 0.007, ne glede na izbrani filter, običajno pa še manjša, pod 0.001. Izračunali smo tudi verjetnosti, da so bile spremembe enake v primerih, ko je bil porod prezgoden, kot v primerih, ko je bil porod ob roku (p_6). Te verjetnosti so bile vedno visoke, nad 0.05, kar pomeni, da med skupinama nismo opazili statistično pomembnih razlik.

Posnetke smo na osnovi pridobljenih cenilk poizkusili tudi klasificirati v skupine - najprej na tiste posnetke, kjer je bil porod prezgoden proti tistim, kjer je bil porod ob roku, nato še na tiste, ki so bili zajeti pred 26. tednom nosečnosti proti tistim, ki so bili zajeti med ali po 26. tednu nosečnosti. Klasifikacijo glede na čas poroda smo nato poizkusili izvesti še na posnetkih, ki so bili zajeti pred 26. tednom in nato na tistih, zajetih po 26. tednu, klasifikacijo glede na čas zajema posnetka pa smo poizkusili izvesti še na posnetkih, kjer je bil porod prezgoden in nato na posnetkih, kjer je bil porod ob roku. Za klasifikacijo smo uporabili naivni Bayesov klasifikator in odločitvena drevesa, Kriterij največje zmogljivosti klasifikatorja je bila vsota občutljivosti in specifičnosti. Vsak klasifikator smo testirali na

tri načine - na učni množici, z navzkrižno validacijo in s pristopom „izpusti enega“. Pri uporabi naivnega Bayesovega klasifikatorja za klasifikacijo posnetkov, kjer je bil porod prezgoden, med vsemi posnetki (v smislu p_6 pri statistični analizi), je bila ob testiranju na učni množici občutljivost 40% pri specifičnosti 94%. Pri uporabi naivnega Bayesovega klasifikatorja za klasifikacijo posnetkov, kjer je bil porod prezgoden, med posnetki, zajetimi zgodaj v nosečnosti (v smislu p_2 pri statistični analizi), je bila ob testiranju na učni množici občutljivost 74% pri specifičnosti 98%. Pri uporabi naivnega Bayesovega klasifikatorja za klasifikacijo posnetkov, zajetih zgodaj v nosečnosti (pred 26. tednom), med vsemi posnetki (v smislu p_5 pri statistični analizi), je bila ob testiranju na učni množici občutljivost 74% pri specifičnosti 72%.

Izkazalo pa se je tudi, da se odločitvena drevesa pogosto pretirano prilagodijo učni množici.

NON-LINEAR ANALYSIS OF UTERINE ELECTROMYOGRAM SIGNALS

Gašper Fele-Žorž

Abstract

Our aim was to analyze uterine electrical activity using various signal processing techniques.

We carried out our research on 1211 records of uterine electrical activity which were recorded between the years 1997 and 2005. Most of the records contained three channels to record the electrical activity. 53 records also contained an estimate of the intra-uterine pressure as measured by a tocograph. Most of the records were taken either around the 22nd or around the 31st week of gestation. The duration of most records was 30 minutes. In addition, for most records accompanying data was collected.

We checked the records for excessive noise and rated them accordingly. The accompanying information was collected from multiple sources and organized. We stored the records in a relational database. The database contained 760 records where all three signals were almost certainly good, and for which all necessary accompanying data was available, recorded during 532 pregnancies. We implemented a system for the storage of records, their signals, their accompanying data and the results of various computations, performed on the signals.

We filtered the signals using six band-pass filters. The lower band-pass frequency limits were 0.08 Hz and 0.3 Hz. The upper band-pass frequency limits were 2.5 Hz, 3 Hz and 4 Hz. We used Butterworth filters with a double-pass filtering scheme. This scheme maintains most benefits of infinite impulse response filters while eliminating the group delay which might be problematic.

We implemented a graphical user interface to view the records using various signal visualization techniques. The user interface supported the display of signals as time series and their power spectra. In addition, the interface could display spectrogram and the Wigner-Ville time-frequency distribution of each signal. The results of various calculations were also displayed for each signal. The records and the signals to be displayed were selected by writing simple SQL queries into entry fields in the user interface.

While observing the records which contained an estimate of intra-uterine pressure, we observed changes in the electrical activity of the uterus during contractions. The changes were especially evident while observing the Wigner-Ville time-frequency distribution of the signals. We also calculated the short-time cross-correlation coefficients between the signals

of these records. We observed that the correlation between signals was almost always highest during the same time instant. The peaks of the cross-correlation coefficients usually rose during contractions.

In addition to visualising of records, we also calculated some properties of the signals using different signal processing techniques. We divided the techniques into two groups - the linear and non-linear techniques. The linear techniques were based on the power spectrum of each signal. They included the root mean square value of the signal, the peak frequency of the power spectrum, its median frequency and the first zero-crossing of the autocorrelation coefficients. The non-linear techniques were based on the estimation of complexity of each signal. They included the maximum Lyapunov exponent and the correlation dimension, both of which are based on the reconstructed phase-space of the system, and sample entropy along with its extension, the multi-scale sample entropy, which are based on the self-similarity of each signal.

The non-linear signal processing techniques used are computationally more demanding than the linear ones. The time complexity of the most widely used algorithm for the calculation of sample entropy is $O(N^2)$, where N represents the length of the signal. We developed a new algorithm to calculate the sample entropy of a signal. The time-complexity of the new algorithm on typical signals is $O(N \cdot \log(N))$. As part of the implementation of the new algorithm, we also created a fast implementation of the skip-list data-structure.

We divided the records where all signals with their accompanying data were good and where labor was spontaneous, into multiple groups. We formed the groups according to the duration of pregnancy and the time of recording. This yielded four groups of records - those records where birth was premature, those records where birth was on term; those records which were taken before the 26th week of gestation and those records which were taken during or after the 26th week of gestation. We then used the Student's t-test to calculate the probabilities that the means of various signal properties were the same across pairs of groups. We thus obtained six probabilities, which we then used to identify the most promising techniques. We observed that the average value for some properties of records, taken before the 26th week of gestation, was different when calculated for those records where birth was premature versus those records where birth was on term.

On the basis of the Student's t-test we concluded that the most promising signal processing techniques were the median frequency of the power spectrum and the sample entropy.

In cases where two records were available for each pregnancy, we used the Student's t-test for paired samples to estimate the changes of various signal properties throughout the pregnancy. We also calculated the probability that the average changes were different for those records where birth was premature than for those records where birth was on term.

We also tried to classify records on the basis of the calculated properties. We attempted the classification in pairs. We first tried to classify those records where birth was premature versus those where birth was on term. Then, we tried to classify those records which were taken before the 26th week of gestation versus those which were taken later. We repeated

the classification of pre-term versus term records for those records which were taken before the 26th week of gestation and then for those taken later. We also repeated the classification of records taken before the 26th week of gestation versus those taken later, among those records where birth was premature and among those records where birth was on term.

For classification we used the naive Bayesian classifier and decision trees. We tested each classifier using three tests - first by testing the classifier on the learning set, then by using cross-validation and finally using the leave-one-out approach. The results of testing the classifiers on the learning sets were excessively optimistic. Decision trees in particular were shown to be prone to overfitting. The Naive Bayesian classifier was better in this regard and generally performed better, despite its simplicity. In general, the results of classification were worse than expected.

We also tried to classify records by using features, obtained using principal components analysis of their original features. The classification results using principal components analysis were even worse than the results from classifying the records using their original features. In particular, the performance of decision trees when using principal components analysis often turned out to be worse than randomly guessing the classes of the records.

KAZALO

Zahvala	iii
Povzetek	v
Abstract	ix
 Kazalo	xiii
 Seznam Slik	xxiv
Seznam Tabel	xxvii
Seznam Simbolov	xxxii
 1 Uvod	1
1.1 Problemska domena	1
1.1.1 Fiziološko ozadje	3
1.2 Cilji	4
1.3 Kratek pregled poglavij	5
 2 Hipoteze	7
 3 Fiziološko ozadje	11
3.1 Maternica	11
3.1.1 Krčenje maternice	12
3.2 Hipoteza kalcijevih valov	13
3.2.1 Vzdrževanje nosečnosti	15
3.3 Hormonalni vplivi med nosečnostjo	15
3.3.1 Pomembnejši hormoni in njih vplivi	15
3.4 Ovulatorni ciklus	17
3.4.1 Folikularna faza	17
3.4.2 Luteinska faza	18
3.5 Endometrijski ciklus	18
3.5.1 Faza rasti endometrija	18
3.5.2 Plodna faza	18
3.5.3 Krvavitev	19
3.6 Hipoteza o pomenu kortikotropin sproščajočega hormona	19

3.7 Salve električne aktivnosti na površju maternice	19
4 Razvoj podatkovne baze posnetkov elektromiogramov maternice	21
4.1 Zbrani posnetki	21
4.2 Položaj elektrod	23
4.3 Kvaliteta posnetkov	24
4.4 Predizbor posnetkov	24
4.5 Načini zapisa podatkov	26
4.5.1 Posnetki v binarni obliki, spremljevalni podatki v eni ali več tekstovnih datotekah	26
4.5.2 Posnetki v tekstovni obliki, spremljevalni podatki v eni ali več tekstovnih datotekah	27
4.5.3 Posnetki v tekstovni ali binarni obliku na datotečnem sistemu, spremljevalni podatki v eni datoteki	27
4.5.4 Posnetki na datotečnem sistemu, spremljevalni podatki v relacijski bazi	27
4.5.5 Posnetki in spremljevalni podatki v relacijski bazi	28
4.6 Izbira načina zapisa podatkov	28
4.6.1 Podatki o posnetkih in nosečnostih	29
4.7 Organizacija podatkovne baze	33
5 Predobdelava posnetkov	39
5.1 Butterworthovi filtri	39
5.2 Dvosmerna shema filtriranja	40
5.3 Izbor mejnih frekvenc filtriranja signalov	47
6 Karakterizacija posnetkov	49
6.1 Kratko-intervalni križno-korelacijski koeficienti	49
6.2 Karakterizacija spektrov na osnovi spektrograma	51
6.3 Časovno-frekvenčna predstavitev Wignerja in Villeja	51
6.4 Pregledovanje signalov	54
6.5 Lastnosti salv električne aktivnosti maternice	57
6.6 Ocena močnostnega spektra	66
6.7 Lastnosti močnostnega spektra 30-minutnih signalov	66
7 Utemeljitev izbranih tehnik obdelave signalov	71
7.1 Linearne tehnike	71
7.1.1 Koren srednje kvadratne vrednosti signala	71
7.1.2 Frekvenca vrha močnostnega spektra signala	71
7.1.3 Mediana frekvenca močnostnega spektra signala	72
7.1.4 Prvi prehod preko ničle koeficientov avtokorelacije	72
7.2 Nelinearne tehnike	72

7.2.1	Maksimalni eksponent Ljapunova in korelacijska dimenzija	72
7.2.2	Vzorčna entropija in večločljivostna vzorčna entropija	73
7.3	Robustna avtomatska analiza	73
7.4	Utemeljitev analize v 22. tednu nosečnosti	75
8	Linearne tehnike obdelave elektromiogramov maternice	77
8.1	Koren srednje kvadratne vrednosti signala	77
8.2	Frekvenca vrha močnostnega spektra	77
8.3	Mediana frekvenca močnostnega spektra signala	78
8.4	Prvi prehod preko ničle avtokorelacije	79
9	Nelinearne tehnike obdelave elektromiogramov maternice	83
9.1	Maksimalni eksponent Ljapunova in korelacijska dimenzija	83
9.1.1	Maksimalni eksponent Ljapunova	86
9.1.2	Korelacijska dimenzija	86
9.2	Vzorčna entropija	87
9.2.1	Klasični pristop	88
9.2.2	Novi pristop	88
9.2.3	Preskakajoči sezname	92
9.2.4	Primerjava hitrosti izvajanja algoritmov za izračun vzorčne entropije	93
9.2.5	Večločljivostna vzorčna entropija	97
10	Statistična analiza pridobljenih cenilk	99
10.1	Studentov t-test	99
10.1.1	Analiza variance	100
10.2	Strategija evaluacije uporabljenih tehnik	100
10.3	Skupine posnetkov	101
10.3.1	Skupina s po enim posnetkom na nosečnost	104
10.3.2	Skupina z dvema posnetkoma na nosečnost	106
10.4	Rezultati	108
10.4.1	Posnetki s prezgodnjimi porodi in porodi ob roku	109
10.4.2	Posnetki okrog 22. in 31. tedna nosečnosti	126
10.5	Povzetek rezultatov statistične analize	129
10.5.1	Spremembe cenilk med nosečnostjo	134
11	Avtomatska klasifikacija posnetkov	149
11.1	Naivni Bayesov klasifikator	150
11.2	Klasifikacija z odločitvenimi drevesi	150
11.2.1	Pribitek informacije	151
11.2.2	Obrezovanje dreves	152
11.3	Analiza principalnih komponent	154

11.4 Ocena delovanja klasifikatorjev	154
11.4.1 Občutljivost in specifičnost	154
11.4.2 Karakteristika delovanja sprejemnika	155
11.4.3 Ocena delovanja na učni množici	156
11.4.4 Ocena delovanja z navzkrižno validacijo	156
11.4.5 Ocena delovanja po principu „izpusti enega“	156
11.5 Rezultati klasifikacije	157
11.5.1 Lastnosti posnetkov, izbrane za klasifikacijo	157
11.5.2 Klasifikacija z majoritetnim klasifikatorjem	158
11.5.3 Klasifikacija z naivnim Bayesovim klasifikatorjem	158
11.5.4 Klasifikacija z odločitvenimi drevesi	165
11.5.5 Klasifikacija z uporabo analize principalnih komponent	172
12 Razprava	175
12.1 Izbira filtrov za predobdelavo ter kanalov za zajem posnetkov elektromiograma maternice	175
12.2 Tehnike vizualizacije	176
12.3 Karakterizacija posnetkov elektromiograma maternice	177
12.4 Delitev tehnik obdelave signalov na linearne in nelinearne	177
12.5 Določanje parametrov pri nelinearnih tehnikah obdelave signalov	178
12.6 Primernost tehnik za ločevanje skupin posnetkov	180
12.7 Rezultati statistične analize	181
12.8 Izbira lastnosti za klasifikacijo	182
12.9 Testiranje klasifikatorjev	182
13 Zaključek	185
13.1 Prispevki znanosti	185
13.2 Nadaljnje delo	187
13.2.1 Izvoz posnetkov iz baze	187
13.2.2 Razširitev baze	188
13.2.3 Analiza večkanalnih posnetkov	188
13.2.4 Izračun drseče vzorčne entropije	188
13.2.5 Izboljšava klasifikacije	189
Dodatek	191
A Tabele izračunanih statistik	191
A.1 Povzetki statistik, urejeni po filtrih	191
B Karakteristike klasifikatorjev z uporabo analize principalnih komponent	199

C Tabele z rezultati preizkusov klasifikatorjev	207
D Izjava	221
Seznam Literature	223

SEZNAM SLIK

1.1	Uporabniški vmesnik za pregledovanje posnetkov in spremljajočih podatkov	2
1.2	Električna aktivnost maternice in ocena pritiska v maternici	4
2.1	Električna aktivnost maternice v primerih, ko je bil porod prezgoden ali ob roku	8
3.1	Primer salv električne aktivnosti maternice	20
4.1	Sistem zajema posnetkov EMG maternice	22
4.2	Položaji elektrod nad površino maternice. Kanal 1: E2 - E1, kanal 2: E2 - E3, kanal 3: E4 - E3.	23
4.3	Uporabniški vmesnik programa za ocenjevanje posnetkov EMG maternice	25
4.4	Organizacija podatkovne baze - pregled	34
4.5	Organizacija podatkovne baze - cenilke.	35
4.6	Organizacija podatkovne baze - spremjevalni podatki	36
5.1	Frekvenčni (levo) in fazni (desno) odziv na enotin impulz filtra 0.08 Hz - 2.5 Hz z in brez dvosmerne sheme filtriranja. Črtkana črta predstavlja odziv filtra brez dvosmerne sheme filtriranja, polna z dvosmerno shemo filtriranja. Na sliki so odzivi nizko-prepustnega filtra (zgoraj), visoko-prepustnega filtra (v sredini) in nizko-prepustnega filtra (spodaj)	41
5.2	Frekvenčni (levo) in fazni (desno) odziv na enotin impulz filtra 0.08 Hz - 3 Hz z in brez dvosmerne sheme filtriranja. Črtkana črta predstavlja odziv filtra brez dvosmerne sheme filtriranja, polna z dvosmerno shemo filtriranja. Na sliki so odzivi nizko-prepustnega filtra (zgoraj), visoko-prepustnega filtra (v sredini) in nizko-prepustnega filtra (spodaj)	42
5.3	Frekvenčni (levo) in fazni (desno) odziv na enotin impulz filtra 0.08 Hz - 4 Hz z in brez dvosmerne sheme filtriranja. Črtkana črta predstavlja odziv filtra brez dvosmerne sheme filtriranja, polna z dvosmerno shemo filtriranja. Na sliki so odzivi nizko-prepustnega filtra (zgoraj), visoko-prepustnega filtra (v sredini) in nizko-prepustnega filtra (spodaj)	43

5.4	Frekvenčni (levo) in fazni (desno) odziv na enotin impulz filtra 0.3 Hz - 2.5 Hz z in brez dvosmerne sheme filtriranja. Črtkana črta predstavlja odziv filtra brez dvosmerne sheme filtriranja, polna z dvosmerno shemo filtriranja. Na sliki so odzivi nizko-prepustnega filtra (zgoraj), visoko-prepustnega filtra (v sredini) in nizko-prepustnega filtra (spodaj)	44
5.5	Frekvenčni (levo) in fazni (desno) odziv na enotin impulz filtra 0.3 Hz - 3 Hz z in brez dvosmerne sheme filtriranja. Črtkana črta predstavlja odziv filtra brez dvosmerne sheme filtriranja, polna z dvosmerno shemo filtriranja. Na sliki so odzivi nizko-prepustnega filtra (zgoraj), visoko-prepustnega filtra (v sredini) in nizko-prepustnega filtra (spodaj)	45
5.6	Frekvenčni (levo) in fazni (desno) odziv na enotin impulz filtra 0.3 Hz - 4 Hz z in brez dvosmerne sheme filtriranja. Črtkana črta predstavlja odziv filtra brez dvosmerne sheme filtriranja, polna z dvosmerno shemo filtriranja. Na sliki so odzivi nizko-prepustnega filtra (zgoraj), visoko-prepustnega filtra (v sredini) in nizko-prepustnega filtra (spodaj)	46
6.1	Primer kratko-intervalnih križnih koeficientov dveh kanalov (signalov) istega posnetka EMG maternice	50
6.2	Primer spektrograma signala EMG maternice	52
6.3	Primer časovno-frekvenčne predstavitev Wignerja in Villeja signala EMG maternice	53
6.4	Grafični vmesnik programa za pregledovanje posnetkov v podatkovni bazi	55
6.5	Prikaz usklajenega približevanja dela posnetka med pregledovanjem	56
6.6	Grebeni na spektrogramu pri frekvenci 4 Hz brez filtriranja (zgoraj) in ob uporabljenem filtru 0.3 Hz do 2.5 Hz (spodaj)	57
6.7	Salve električne aktivnosti pred dvigom tlaka v maternici	58
6.8	Vpliv izbire spodnje meje frekvenčnega območja na spektrogram. Pri zgornji sliki je bila meja pri 0.08 Hz, pri spodnji 0.3 Hz. Zanimiva je še primerjava s sliko 6.6, na kateri je prikazan spektrogram istega signala, le brez uporabe filtrov. Večina energije signala je zbrana pri nizkih frekvencah.	59
6.9	Primer dviga vrha močnostnega spektra med salvo električne aktivnosti	60
6.10	Časovno-frekvenčna predstavitev Wignerja in Villeja - posnetek 1721, 2. kanal - artefakti	61
6.11	Časovno-frekvenčna predstavitev Wignerja in Villeja - posnetek 1718, 1. kanal - artefakti	62
6.12	Salve električne aktivnosti, poudarjene z uporabo časovno-frekvenčne predstavitev Wignerja in Villeja	63
6.13	Kratko-intervalni križno-korelacijski koeficienti	64
6.14	Normalizirani kratko-intervalni križno-korelacijski koeficienti	65
6.15	Vrhovi močnostnega spektra signala	67

6.16	Spremembe močnostnega spektra EMG maternice s spodnjo mejo 0.08 Hz	68
6.17	Spremembe močnostnega spektra EMG maternice s spodnjo mejo 0.3 Hz .	69
8.1	Koren srednje kvadratne vrednosti signala EMG maternice z drsečim oknom	78
8.2	Močnostni spekter signala EMG maternice z označenim vrhom	79
8.3	Močnostni spekter signala EMG maternice z označeno mediano frekvenco	80
8.4	Koeficienti avtokorelacijske signalu EMG maternice. Prvi prehod preko ničle je pri zamiku 11 vzorcev.	81
9.1	Primer rekonstruiranega faznega prostora s premajhno časovno zakasnitvijo	84
9.2	Primer rekonstruiranega faznega prostora, kjer je časovna zakasnitev enaka prvemu prehodu preko ničel avtokorelacijske	85
9.3	Prikaz ocene korelacijske dimenzije	87
9.4	Ilustracija vozlišč v preskakajočem seznamu	92
9.5	Primerjava hitrosti izvajanja algoritmov za izračun vzorčne entropije na različno dolgih odsekih daljšega signala EMG maternice.	95
9.6	Primerjava hitrosti izvajanja novega in starega algoritma za izračun vzorčne entropije na umetnih podatkih, ki vsebujejo signal s konstantno vrednostjo (najslabših za novi algoritem).	96
9.7	Primerjava hitrosti izvajanja novega algoritma za izračun vzorčne entropije na različno dolgih odsekih signala EMG maternice ter na umetnih podatkih, ki vsebujejo signal, kjer se noben vzorec ne ponovi (najboljših za novi algoritem).	97
9.8	Prikaz povprečenja pri izračunu večločljivostne vzorčne entropije	98
10.1	Simbolična predstavitev podskupin posnetkov z izračunanimi verjetnostmi. Označene so vrednosti poljubne cenilke za različne skupine - C_{ZP} za <26-PRE, C_{KP} za >=26-PRE, C_{ZR} za <26-TERM in C_{KR} za skupino >=26-TERM.	104
10.2	Časi snemanj in trajanja nosečnosti za skupino posnetkov s po enim posnetkom na nosečnost	105
10.3	Koren srednje kvadratne vrednosti signalov za skupino z enim posnetkom na nosečnost ob uporabljenem filtru od 0.3 Hz do 2.5 Hz na kanalu 3	111
10.4	Frekvence vrha močnostnega spektra za skupino z enim posnetkom na nosečnost ob uporabljenem filtru od 0.3 Hz do 2.5 Hz na kanalu 3	114
10.5	Mediane frekvence za skupino z enim posnetkom na nosečnost ob uporabljenem filtru od 0.3 Hz do 4 Hz na kanalu 1	117
10.6	Prvi prehodi preko ničle koeficientov avtokorelacijske signalu za skupino z enim posnetkom na nosečnost ob uporabljenem filtru od 0.3 Hz do 2.5 Hz na kanalu 3	119

10.7	Maksimalni eksponenti Ljapunova za skupino z enim posnetkom na nosečnost ob uporabljenem filtru od 0.3 Hz do 2.5 Hz na kanalu 3	121
10.8	Korelacijske dimenzijske entropije za skupino z enim posnetkom na nosečnost ob uporabljenem filtru od 0.08 Hz do 4 Hz na kanalu 2	123
10.9	Vzorčna entropija pri $m = 3$ in $r = 0.15$ za skupino z enim posnetkom na nosečnost ob uporabljenem filtru od 0.3 Hz do 3 Hz na kanalu 3.	125
10.10	Medianne frekvence za skupino z enim posnetkom na nosečnost ob uporabljenem filtru od 0.3 Hz do 3 Hz na kanalu 1	131
10.11	Vzorčne entropije pri $m = 3$ in $r = 0.15$ za skupino z enim posnetkom na nosečnost ob uporabljenem filtru od 0.3 Hz do 3 Hz na kanalu 3	133
10.12	Spremembe korena srednje kvadratne vrednosti signala skozi nosečnost.	135
10.13	Spremembe frekvence vrha močnostnega spektra signala skozi nosečnost.	137
10.14	Spremembe mediane frekvence močnostnega spektra signala skozi nosečnost.	139
10.15	Spremembe prvega prehoda preko ničle koeficientov avtokorelacije skozi nosečnost.	141
10.16	Spremembe maksimalnega eksponenta Ljapunova skozi nosečnost.	143
10.17	Spremembe korelacijske dimenzijske entropije skozi nosečnost.	145
10.18	Spremembe vzorčne entropije skozi nosečnost pri $m = 3$ in $r = 0.15$ pri uporabljenem filtru od 0.3 Hz do 2.5 Hz na kanalu 3	147
11.1	Karakteristike klasifikatorjev za Bayesov naivni klasifikator pri klasifikaciji posnetkov, kjer je bil porod prezgoden med vsemi posnetki (v smislu p_6 iz poglavja 10).	159
11.2	Karakteristike klasifikatorjev za Bayesov naivni klasifikator pri klasifikaciji posnetkov, kjer je bil porod prezgoden med posnetki, zajetimi pred 26. tednom nosečnosti (v smislu p_1 iz poglavja 10).	160
11.3	Karakteristike klasifikatorjev za Bayesov naivni klasifikator pri klasifikaciji posnetkov, kjer je bil porod prezgoden med posnetki, zajetimi med ali po 26. tednu nosečnosti (v smislu p_2 iz poglavja 10).	161
11.4	Karakteristike klasifikatorjev za Bayesov naivni klasifikator pri klasifikaciji posnetkov, zajetih pred 26. tednom nosečnosti, med vsemi posnetki (v smislu p_5 iz poglavja 10).	162
11.5	Karakteristike klasifikatorjev za Bayesov naivni klasifikator pri klasifikaciji posnetkov, zajetih pred 26. tednom nosečnosti, med posnetki, kjer je bil porod prezgoden (v smislu p_3 iz poglavja 10).	163
11.6	Karakteristike klasifikatorjev za Bayesov naivni klasifikator pri klasifikaciji posnetkov, zajetih pred 26. tednom nosečnosti, med posnetki, kjer je bil porod ob roku (v smislu p_4 iz poglavja 10).	164

11.7	Karakteristike klasifikatorjev za odločitvena drevesa pri klasifikaciji posnetkov, kjer je bil porod prezgoden med vsemi posnetki (v smislu p_6 iz poglavja 10).	165
11.8	Karakteristike klasifikatorjev za odločitvena drevesa pri klasifikaciji posnetkov, kjer je bil porod prezgoden med posnetki, zajetimi pred 26. tednom nosečnosti (v smislu p_1 iz poglavja 10).	166
11.9	Karakteristike klasifikatorjev za odločitvena drevesa pri klasifikaciji posnetkov, kjer je bil porod prezgoden, med posnetki, zajetimi med ali po 26. tednu nosečnosti (v smislu p_2 iz poglavja 10).	167
11.10	Karakteristike klasifikatorjev za odločitvena drevesa pri klasifikaciji posnetkov, zajetih pred 26. tednom nosečnosti, med vsemi posnetki (v smislu p_5 iz poglavja 10).	169
11.11	Karakteristike klasifikatorjev za odločitvena drevesa pri klasifikaciji posnetkov, zajetih pred 26. tednom nosečnosti, med posnetki, kjer je bil porod prezgoden (v smislu p_3 iz poglavja 10).	170
11.12	Karakteristike klasifikatorjev za odločitvena drevesa pri klasifikaciji posnetkov, zajetih pred 26. tednom nosečnosti, med posnetki, kjer je bil porod ob roku (v smislu p_4 iz poglavja 10).	171
B.1	Karakteristike klasifikatorjev za Bayesov naivni klasifikator pri klasifikaciji posnetkov, kjer je bil porod prezgoden, med vsemi posnetki (v smislu p_6 iz poglavja 10) z uporabo analize principalnih komponent.	199
B.2	Karakteristike klasifikatorjev za Bayesov naivni klasifikator pri klasifikaciji posnetkov, zajetih pred 26. tednom nosečnosti, med vsemi posnetki (v smislu p_5 iz poglavja 10) z uporabo analize principalnih komponent.	200
B.3	Karakteristike klasifikatorjev za Bayesov naivni klasifikator pri klasifikaciji posnetkov, kjer je bil porod prezgoden, med posnetki, zajetimi pred 26. tednom nosečnosti (v smislu p_1 iz poglavja 10), z uporabo analize principalnih komponent.	200
B.4	Karakteristike klasifikatorjev za Bayesov naivni klasifikator pri klasifikaciji posnetkov, kjer je bil porod prezgoden, med posnetki, zajetimi med ali po 26. tednu nosečnosti (v smislu p_2 iz poglavja 10), z uporabo analize principalnih komponent.	201
B.5	Karakteristike klasifikatorjev za Bayesov naivni klasifikator pri klasifikaciji posnetkov, zajetih pred 26. tednom nosečnosti, med posnetki, kjer je bil porod prezgoden (v smislu p_3 iz poglavja 10), z uporabo analize principalnih komponent.	201

B.6	Karakteristike klasifikatorjev za Bayesov naivni klasifikator pri klasifikaciji posnetkov, zajetih pred 26. tednom nosečnosti, med posnetki, kjer je bil porod ob roku (v smislu p_4 iz poglavja 10), z uporabo analize principalnih komponent	202
B.7	Karakteristike klasifikatorjev za odločitvena drevesa pri klasifikaciji posnetkov, kjer je bil porod prezgoden, med vsemi posnetki (v smislu p_6 iz poglavja 10), z uporabo analize principalnih komponent.	203
B.8	Karakteristike klasifikatorjev za odločitvena drevesa pri klasifikaciji posnetkov, zajetih pred 26. tednom nosečnosti, med vsemi posnetki (v smislu p_5 iz poglavja 10), z uporabo analize principalnih komponent	203
B.9	Karakteristike klasifikatorjev za odločitvena drevesa pri klasifikaciji posnetkov, kjer je bil porod prezgoden, med posnetki, zajetimi pred 26. tednom nosečnosti (v smislu p_1 iz poglavja 10), z uporabo analize principalnih komponent	204
B.10	Karakteristike klasifikatorjev za odločitvena drevesa pri klasifikaciji posnetkov, kjer je bil porod prezgoden, med posnetki, zajetimi med ali po 26. tednu nosečnosti (v smislu p_2 iz poglavja 10), z uporabo analize principalnih komponent	204
B.11	Karakteristike klasifikatorjev za odločitvena drevesa pri klasifikaciji posnetkov, zajetih pred 26. tednom nosečnosti, med posnetki, kjer je bil porod prezgoden (v smislu p_3 iz poglavja 10), z uporabo analize principalnih komponent	205
B.12	Karakteristike klasifikatorjev za odločitvena drevesa pri klasifikaciji posnetkov, zajetih pred 26. tednom nosečnosti, med postnetki, kjer je bil porod ob roku (v smislu p_4 iz poglavja 10), z uporabo analize principalnih komponent	205

SEZNAM TABEL

5.1	Koeficienti uporabljenih filtrov	48
10.1	Števila posnetkov v izžrebanih skupinah	103
10.2	Števila posnetkov v skupinah z enim posnetkom na nosečnost	108
10.3	Koren srednje vrednosti kvadrata - povzetek rezultatov	110
10.4	Frekvenca vrha močnostnega spektra - povzetek rezultatov	113
10.5	Frekv. vrha močnostnega spektra z drsečim oknom - povzetek rezultatov	113
10.6	Mediana frekvenca - povzetek rezultatov	116
10.7	Mediana frekvenca z drsečim oknom - povzetek rezultatov	116
10.8	Prvi prehod preko ničle koef. avtokorelacije - povzetek rezultatov	118
10.9	Maksimalni eksponent Ljapunova - povzetek rezultatov	120
10.10	Korelacijska dimenzija - povzetek rezultatov	122
10.11	Vzorčna entropija - $m = 3, r = 0.15$ - povzetek rezultatov	124
10.12	Števila posnetkov v skupinah z dvema posnetkoma na nosečnost	134
10.13	Koren srednje vrednosti kvadratov - povzetek rezultatov za spremembe med nosečnostjo	135
10.14	Frekvenca vrha močnostnega spektra - povzetek rezultatov za spremembe med nosečnostjo	136
10.15	Frekv. vrha močnostnega spektra z drsečim oknom - povzetek rezultatov za spremembe med nosečnostjo	137
10.16	Mediana frekvenca - povzetek rezultatov za spremembe med nosečnostjo	138
10.17	Mediana frekvenca z drsečim oknom - povzetek rezultatov za spremembe med nosečnostjo	139
10.18	Prvi prehod preko ničle koef. avtokorelacije - povzetek rezultatov za spremembe med nosečnostjo	140
10.19	Maksimalni eksponent Ljapunova - povzetek rezultatov za spremembe med nosečnostjo	142
10.20	Korelacijska dimenzija - povzetek rezultatov za spremembe med nosečnostjo	144
10.21	Vzorčna entropija $m=3, r=0.15$ - povzetek rezultatov za spremembe tekom nosečnosti	146

11.1	Rezultati klasifikacije posnetkov z majoritetnim klasifikatorjem na različnih skupinah z različnimi razredi	158
A.1	Povzetek rezultatov za pasovno-prepustni filter 0.08Hz - 2.5Hz	192
A.2	Povzetek rezultatov za pasovno-prepustni filter 0.08Hz - 3Hz	193
A.3	Povzetek rezultatov za pasovno-prepustni filter 0.08Hz - 4Hz	194
A.4	Povzetek rezultatov za pasovno-prepustni filter 0.3Hz - 2.5Hz	195
A.5	Povzetek rezultatov za pasovno-prepustni filter 0.3Hz - 3Hz	196
A.6	Povzetek rezultatov za pasovno-prepustni filter 0.3Hz - 4Hz	197
C.1	Rezultati klasifikacije posnetkov, zajetih pred 26. tednom nosečnosti, z naivnim Bayesovim klasifikatorjem na vseh posnetkih	207
C.2	Rezultati klasifikacije posnetkov, kjer je bil porod prezgoden, z naivnim Bayesovim klasifikatorjem na vseh posnetkih	208
C.3	Rezultati klasifikacije posnetkov, kjer je bil porod prezgoden, z naivnim Bayesovim klasifikatorjem na posnetkih, zajetih pred 26. tednom nosečnosti,	208
C.4	Rezultati klasifikacije posnetkov, kjer je bil porod prezgoden, z naivnim Bayesovim klasifikatorjem na posnetkih, zajetih med ali po 26. tednu nosečnosti,	209
C.5	Rezultati klasifikacije posnetkov, zajetih pred 26. tednom nosečnosti, z naivnim Bayesovim klasifikatorjem na posnetkih, kjer je bil porod prezgoden,	209
C.6	Rezultati klasifikacije posnetkov, zajetih pred 26. tednom nosečnosti, z naivnim Bayesovim klasifikatorjem na posnetkih, kjer je bil porod ob roku,	210
C.7	Rezultati klasifikacije posnetkov, zajetih pred 26. tednom nosečnosti, z odločitvenimi drevesi na vseh posnetkih	211
C.8	Rezultati klasifikacije posnetkov, kjer je bil porod prezgoden, z odločitvenimi drevesi na vseh posnetkih	211
C.9	Rezultati klasifikacije posnetkov, kjer je bil porod prezgoden, z odločitvenimi drevesi na posnetkih, zajetih pred 26. tednom nosečnosti,	212
C.10	Rezultati klasifikacije posnetkov, kjer je bil porod prezgoden, z odločitvenimi drevesi na posnetkih, zajetih med ali po 26. tednu nosečnosti,	212
C.11	Rezultati klasifikacije posnetkov, zajetih pred 26. tednom nosečnosti, z odločitvenimi drevesi na posnetkih, kjer je bil porod prezgoden,	213
C.12	Rezultati klasifikacije posnetkov, zajetih pred 26. tednom nosečnosti, z odločitvenimi drevesi na posnetkih, kjer je bil porod ob roku,	213
C.13	Rezultati klasifikacije posnetkov, zajetih pred 26. tednom nosečnosti, z naivnim Bayesovim klasifikatorjem z uporabo PCA na vseh posnetkih . . .	214
C.14	Rezultati klasifikacije posnetkov, kjer je bil porod prezgoden, z naivnim Bayesovim klasifikatorjem z uporabo PCA na vseh posnetkih	214

C.15	Rezultati klasifikacije posnetkov, kjer je bil porod prezgoden, z naivnim Bayesovim klasifikatorjem z uporabo PCA na posnetkih, zajetih pred 26. tednom nosečnosti,	215
C.16	Rezultati klasifikacije posnetkov, kjer je bil porod prezgoden, z naivnim Bayesovim klasifikatorjem z uporabo PCA na posnetkih, zajetih med ali po 26. tednu nosečnosti,	215
C.17	Rezultati klasifikacije posnetkov, zajetih pred 26. tednom nosečnosti, z naivnim Bayesovim klasifikatorjem z uporabo PCA na posnetkih, kjer je bil porod prezgoden,	216
C.18	Rezultati klasifikacije posnetkov, zajetih pred 26. tednom nosečnosti, z naivnim Bayesovim klasifikatorjem z uporabo PCA na posnetkih, kjer je bil porod ob roku,	216
C.19	Rezultati klasifikacije posnetkov, zajetih pred 26. tednom nosečnosti, z odločitvenimi drevesi z uporabo PCA na vseh posnetkih	217
C.20	Rezultati klasifikacije posnetkov, kjer je bil porod prezgoden, z odločitvenimi drevesi z uporabo PCA na vseh posnetkih	217
C.21	Rezultati klasifikacije posnetkov, kjer je bil porod prezgoden, z odločitvenimi drevesi z uporabo PCA na posnetkih, zajetih pred 26. tednom nosečnosti,	218
C.22	Rezultati klasifikacije posnetkov, kjer je bil porod prezgoden, z odločitvenimi drevesi z uporabo PCA na posnetkih, zajetih med ali po 26. tednu nosečnosti,	218
C.23	Rezultati klasifikacije posnetkov, zajetih pred 26. tednom nosečnosti, z odločitvenimi drevesi z uporabo PCA na posnetkih, kjer je bil porod prezgoden,	219
C.24	Rezultati klasifikacije posnetkov, zajetih pred 26. tednom nosečnosti, z odločitvenimi drevesi z uporabo PCA na posnetkih, kjer je bil porod ob roku,	219

SEZNAM SIMBOLOV

- A, B, C - množice
- $A(s)$ - imenovalec prenosne funkcije filtra v zveznem prostoru
- $A(z)$ - imenovalec prenosne funkcije filtra v diskretnem prostoru
- $a(1), a(2), \dots$ - členi števca prenosne funkcije filtra
- $B(s)$ - števec prenosne funkcije filtra v zveznem prostoru
- $B(z)$ - števec prenosne funkcije filtra v diskretnem prostoru
- $b(1), b(2), \dots$ - členi imenovalca prenosne funkcije filtra
- C - množica razredov
- c - razred
- D_{smp} - časovna zakasnitev
- D - razlika skupin
- E - matematično upanje
- $En(S)$ - entropija sistema
- $E(T)$ - ocena napake poddrevesa
- $e(v)$ - napaka vozlišča
- $F_{1,\dots,k}$ - nabori lastnosti množice primerov
- $f_{1,\dots,k}$ - nabor lastnosti konkretnega primera
- f_{med} - mediana frekvenca
- f_s - frekvenca vzorčenja
- FN - število neresnično negativnih primerov (false negatives)

- FP - število neresnično pozitivnih primerov (false positives)
- G - nabor vzorcev
- $H(s)$ - prenosna funkcija filtra v zveznem prostoru
- $H(z)$ - prenosna funkcija filtra v diskretnem prostoru
- i - števec
- $J(m), K(m)$ - števca pri izračunu *sampEn*
- $K_d(m)$ - razlika med $J(m)$ in $K(m)$ pri izračunu *sampEn*
- k - število lastnosti
- L - razmerje (scale) pri večločljivostni vzorčni entropiji
- M - množica vzorcev pri *sampEn*, ki se od nekega vzorca razlikujejo za manj kot r
- $MSE(x, L, r, m)$ - večločljivostna vzorčna entropija signala x s parametri L, r, m
- m - dolžina vzorca pri vzorčni entropiji, parameter m pri odločanju za vejitev pri odločitvenem drevesu.
- N - dolžine signalov
- N_A, N_B - velikosti množic
- N_w - dolžina okna
- n - indeks
- o - število dejavnikov, ki vplivajo na sistem
- PDP - predvideni datum poroda
- P - močnostni spekter
- p - verjetnost pri Studentovem t-testu, verjetnost stanj sistema
- p_C - verjetnost, da vzorec pripada večinskemu razredu
- p_{s_1}, \dots, p_{s_N} - verjetnosti stanj sistema
- Q - vložitvena dimenzija
- RMS - koren srednje vrednosti kvadratov
- R_{xx} - avtokorelacija

- R_{xy} - križna korelacija
- r - radij, znotraj katerega naj bosta dve točki pri korelacijski dimenziji ali vzorčni entropiji
- Se - senzitivnost
- Sp - specifičnost
- SP - spektrogram
- S - sistem
- $STFT$ - kratko-intervalna Fourierjeva transformacija short-time Fourier transform
- s_1, \dots, s_N - stanja sistema
- $sampEn(x, r, m)$ - vzorčna entropija signala x s parametromi r, m
- TN - število dejansko negativnih primerov (true negatives)
- T - poddrevo
- TP - število dejansko pozitivnih primerov (true positives)
- t - čas, statistika pri Studentovem t-testu.
- u - primer v množici
- V - varianca
- v - vozlišče
- WD - Wigner-Villejeva časovno-frekvenčna predstavitev
- $w(t)$ - okno
- X - matrika
- $x(t), y(t)$ - signal
- y_i - komponenta vektorja v faznem prostoru
- $\mathbf{y}(t)$ - vektor stanja v faznem prostoru ob času t
- Γ - gama funkcija
- λ - eksponent Ljapunova
- ν - stopnja prostosti

- Σ - kovariančna matrika
- τ - časovni zamik
- ω - frekvenca
- ω_n - n-ta frekvenca

POGLAVJE 1

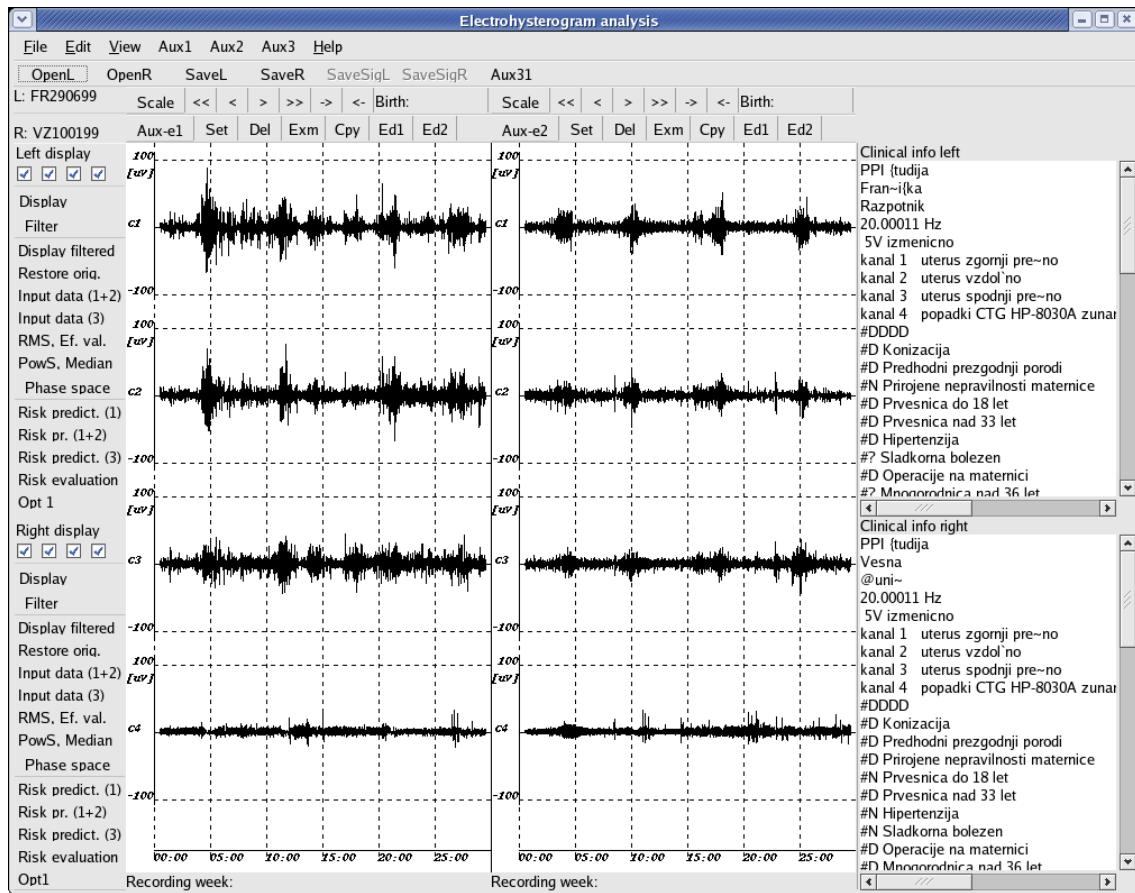
Uvod

Ne glede na razvoj medicine v zadnjem stoletju tudi v razvitih državah nosečnost in porod še vedno predstavlja precejšnje tveganje za (bodočo) mater in otroka. Razni zapleti med nosečnostjo in ob porodu včasih zdravnike postavijo v nezavidljiv položaj, ko se morajo odločati med zdravjem otroka in matere.

Še posebej so ogroženi tisti otroci, ki imajo ob rojstvu prenizko težo. Glavna razloga za premajhno težo ob porodu sta zato rasti v maternici in spontan prezgodnji porod. V primeru zastoja rasti v maternici se zdravniki pogosto odločijo za umetno sprožitev poroda, ne glede na pričakovane kasnejše zaplete. Skupaj se prezgodaj, torej pred dopolnjenim 37. tednom nosečnosti, rodi okrog 6% dojenčkov. Vseeno je 70% obporodnih smrti povezanih s prezgodnjim porodom [1]. Nedonošenčki zahtevajo dodatno nego, ki je lahko zelo draga. Posebej za zelo zgodne nedonošenčke lahko celo velja, da bo cena njihovega zdravljenja višja od njihovega zasluga v celotnem življenju.

1.1 Problemska domena

Napovedovanje prezgodnjega poroda je težavno. Trenutni napovedni modeli [2] temeljijo na več dejavnikih tveganja, kot so slatkorna bolezen, povišan srčni pritisk, kajenje, prirojene nepravilnosti maternice, kratek maternični vrat, konizacija, pozitivni rezultati testa za fibronektin in drugi [2, 3, 4]. Vseeno je napovedovanje prezgodnjega poroda še vedno nezanesljivo, zato raziskovalci po vsem svetu iščemo metode, ki bi lahko napovedovanje prezgodnjega poroda izboljšale. Ena izmed smeri, v katerih tečejo raziskave, je analiza električne aktivnosti maternice. Primer uporabniškega vmesnika za pregledovanje posnetkov električne aktivnosti maternice in spremljajočih podatkov je prikazan na sliki 1.1. Vmesnik



Slika 1.1: Uporabniški vmesnik za pregledovanje posnetkov in spremljajočih podatkov

je bil razvit s strani dr. Aleša Smrdela v okviru raziskave, katere del je tudi to delo [5].

Salve električne aktivnosti sovpadajo s krči maternice. Posnetke električne aktivnosti maternice bi morda lahko uporabili za napovedovanje bližajočega se prezgodnjega poroda [6, 7]. Merjenje električne aktivnosti maternice (zajem elektromiogramov, EMG) na površini trebuha je neinvazivno. Zato bi kakršno koli metodo, ki bi na osnovi električne aktivnosti maternice izboljšala napovedovanje prezgodnjega poroda, lahko dokaj hitro vpeljali v klinično rabo.

Na žalost so v EMG maternice električni aktivnosti maternice primešani šumi. Poleg tega iz same jakosti signala ne moremo sklepati o dejanskem stanju maternice. Zato uporaba EMG maternice do prihoda poceni zmogljivih računalnikov, na katerih lahko izvajamo obdelave in analizo signalov, ni bila praktična.

Večina raziskav na področju analize EMG maternice se je doslej osredotočala na linearne

tehnike obdelave signalov, predvsem na analizo močnostnega spektra signala [8, 9]. Med doslej uporabljane tehnike spadajo frekvenca vrha močnostnega spektra med salvami električne aktivnosti maternice [8]; moč signala med salvami električne aktivnosti maternice [10]; frekvenca vrha močnostnega spektra med salvami električne aktivnosti maternice, trajanje salv, njihovo število, srednje vrednosti in deviacija močnostnega spektra v povezavi z nevronskimi mrežami [7]; pristopi z uporabo več tehnik, kot so mediana frekvenca, vrh močnostnega spektra, mera sploščenosti in koeficient simetrije v povezavi z analizo principalnih komponent [6]. Nekatere raziskave so se osredotočile tudi na koren srednje vrednosti kvadratov in mediano frekvenco celotnih 30-minutnih posnetkov električne aktivnosti maternice [11, 12]. Možnosti uporabe nelinearnih tehnik obdelave signalov so bile doslej večinoma neraziskane, čeprav so nekatere skupine začele tudi že z delom v tej smeri [13].

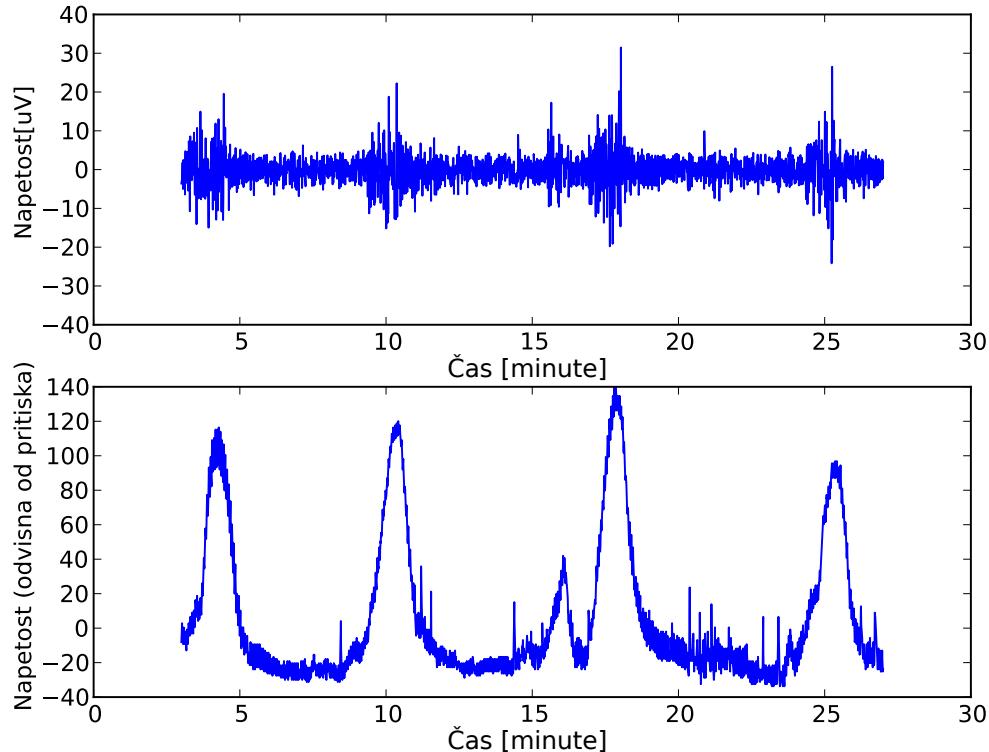
Uporaba nelinearnih tehnik obdelave signalov na drugih fizioloških signalih [14, 15, 16] je dala vzpodbudne rezultate. Na žalost so nelinearne tehnike obdelave signalov običajno računsko zahtevnejše od linearnih.

1.1.1 Fiziološko ozadje

Električna aktivnost maternice je povezana z mehansko aktivnostjo, tako med nosečnostjo, kot tudi med porodom [17]. Primer filtriranega električnega signala, zajetega na površini trebuha, ter ocene pritiska v maternici, zajete s pomočjo tokografa, je predstavljen na sliki 1.2. Signali, zajeti na površini, so popačeni, ampak zelo podobni signalom, ki bi bili zajeti neposredno na maternici [18]. Znano je, da se spontani krči maternice lahko začnejo pojavljati že okoli 3. meseca nosečnosti [19]. Upamo lahko, da se krči in z njimi povezana električna aktivnost maternice pri tistih nosečnicah, kjer je tveganje za prezgodnji porod večje, razlikujejo od električne aktivnosti in krčev pri tistih nosečnicah, ki rodijo ob roku.

Vseeno pa precej vprašanj še ni povsem razjasnjениh. Tako na primer še ni povsem jasno, kako točno se krči začenjajo in ali obstajajo v maternici posebna tkiva, celice ali področja, t.i. *pacemakerji*, kjer se akcijski potenciali tvorijo [20]. Nekateri raziskovalci idejo *pacemakerjev* zavračajo [9]. Tudi če tovrstni izvori krčev obstajajo, zaenkrat ni znano, kje se nahajajo.

Zaradi slabo razjasnjene fiziologije trenutno tudi še ni jasno, kako se krči širijo po maternici in kakšno vlogo pri proženju in širjenju krčev igra živčevje. Verjetno je, da živčevje pri krčih sploh ne igra pomembne vloge [21]. Nadzor nad delovanjem maternice se torej izvaja pretežno preko hormonov.



Slika 1.2: Električna aktivnost maternice in ocena pritiska v maternici

Ker je miometrij sestavljen iz ogromne množice med seboj povezanih gladkih mišičnih celic, katerih odziv na dražljaje ni linearen, ga lahko smatramo za kompleksen nelinearen sistem.

1.2 Cilji

Cilji našega dela so bili naslednji:

- Razvoj robustnih avtomatskih tehnik za analizo posnetkov EMG maternice;
- Karakterizacija posnetkov EMG maternice v različnih obdobjih nosečnosti;
- Izbor linearnih in nelinearnih tehnik analize signalov za ločevanje skupin posnetkov

EMG maternice s prezgodnjim porodom in porodom ob roku, narejenih tako okrog 22. kot okrog 31. tedna nosečnosti;

- Pokazati, da je posnetke EMG maternice mogoče analizirati zgodaj v nosečnosti, že okrog 22. tedna;
- Razvoj hitrejšega algoritma za izračun vzorčne entropije.

Za podporo razvoju in preizkušanju robustnih avtomatskih tehnik za analizo posnetkov EMG maternice smo razvili podatkovno bazo posnetkov s spremljajočimi podatki. V okviru karakterizacije posnetkov EMG maternice v različnih obdobjih nosečnosti smo implementirali različne tehnike vizualizacije EMG maternice in razvili uporabniški vmesnik za pregleđovanje posnetkov EMG maternice.

1.3 Kratek pregled poglavij

- V uvodu je predstavljena problemska domena. Na hitro je povzeto fiziološko ozadje ter našteti cilji raziskave, opisanih v tem delu.
- V poglavju „Hipoteze“ so predstavljene hipoteze, na osnovi katerih smo izbrali smeri raziskave, predstavljene v tem delu.
- V poglavju „Fiziološko ozadje“ je predstavljena fiziologija maternice, dejavniki, ki verjetno nadzirajo njeno delovanje. Predstavljena je električna aktivnost maternice.
- V poglavju „Razvoj podatkovne baze posnetkov EMG maternice“ je predstavljen razvoj podatkovne baze. Opisani so posnetki in spremjevalni podatki. Predstavljene so prednosti in slabosti različnih načinov zapisa podatkov ter naša izbira načina zapisa.
- V poglavju „Predobdelava posnetkov“ so predstavljeni filtri, s katerimi smo predobdelali posnetke. Opisana je dvosmerna shema filtriranja, ki izboljša delovanje filtrov z neskončnim odzivom na enotin impulz.
- V poglavju „Karakterizacija posnetkov“ so opisani kriteriji in način izbora posnetkov za nadaljnjo obdelavo. Predstavljene so različne tehnike vizualizacije posnetkov, vključujuč časovno-frekvenčno predstavitev Wignerja in Villeja. Predstavljena

so opažanja na nekaterih izbranih posnetkih, kjer je bila poleg električne aktivnosti zajeta tudi meritev ocene tlaka v maternici z uporabo tokograma.

- V poglavju „Utemeljitev izbranih tehnik obdelave signalov“ so strnjeno predstavljene linearne in nelinearne tehnike obdelave signalov, ki smo jih uporabili v raziskavi. Za vsako tehniko je podana temeljitev, zakaj smo jo uporabili. Pojasnjeno je, zakaj smo obdelovali celotne posnetke in zakaj smo obdelovali posnetke, zajete zgodaj v nosečnosti.
- V poglavju „Linearne tehnike obdelave EMG maternice“ so natančneje predstavljene uporabljeni linearne tehnike obdelave EMG maternice.
- V poglavju „Nelinearne tehnike obdelave EMG maternice“ so natančneje predstavljene uporabljeni nelinearne tehnike obdelave EMG maternice. V prvem delu poglavja sta predstavljeni tehnički, osnovani na konstruktu faznega prostora. V drugem delu poglavja je predstavljena vzorčna entropija, tehnika, ki se je v raziskavi izkazala za najbolj perspektivno. Predstavljen je nov, hitrejši algoritem za izračun vzorčne entropije.
- V poglavju „Statistična analiza pridobljenih cenilk“ je predstavljena statistična analiza cenilk, pridobljenih s pomočjo v raziskavi preverjanih tehnik obdelave signalov. Predstavljeni so rezultati raziskave, najprej v smislu ločevanja skupin posnetkov, kjer je bil porod prezgoden ali ne, nato še v smislu ločevanja skupin posnetkov, zajetih zgodaj ali pozno v nosečnosti. Na koncu poglavja so izpostavljene najbolj perspektivne tehnike obdelave signalov.
- V poglavju „Avtomatska klasifikacija posnetkov“ so predstavljeni poizkusi klasifikacije posnetkov na osnovi cenilk, pridobljenih s pomočjo v raziskavi preverjanih tehnik obdelave signalov. Predstavljeni so rezultati klasifikacije z uporabo dveh klasifikatorjev - naivnega Bayesovega klasifikatorja in odločitvenih dreves.
- V poglavju „Razprava“ so še enkrat povzeti rezultati raziskave.
- V poglavju „Zaključek“ so predstavljeni prispevki znanosti in nadaljnje smeri dela.

POGLAVJE 2

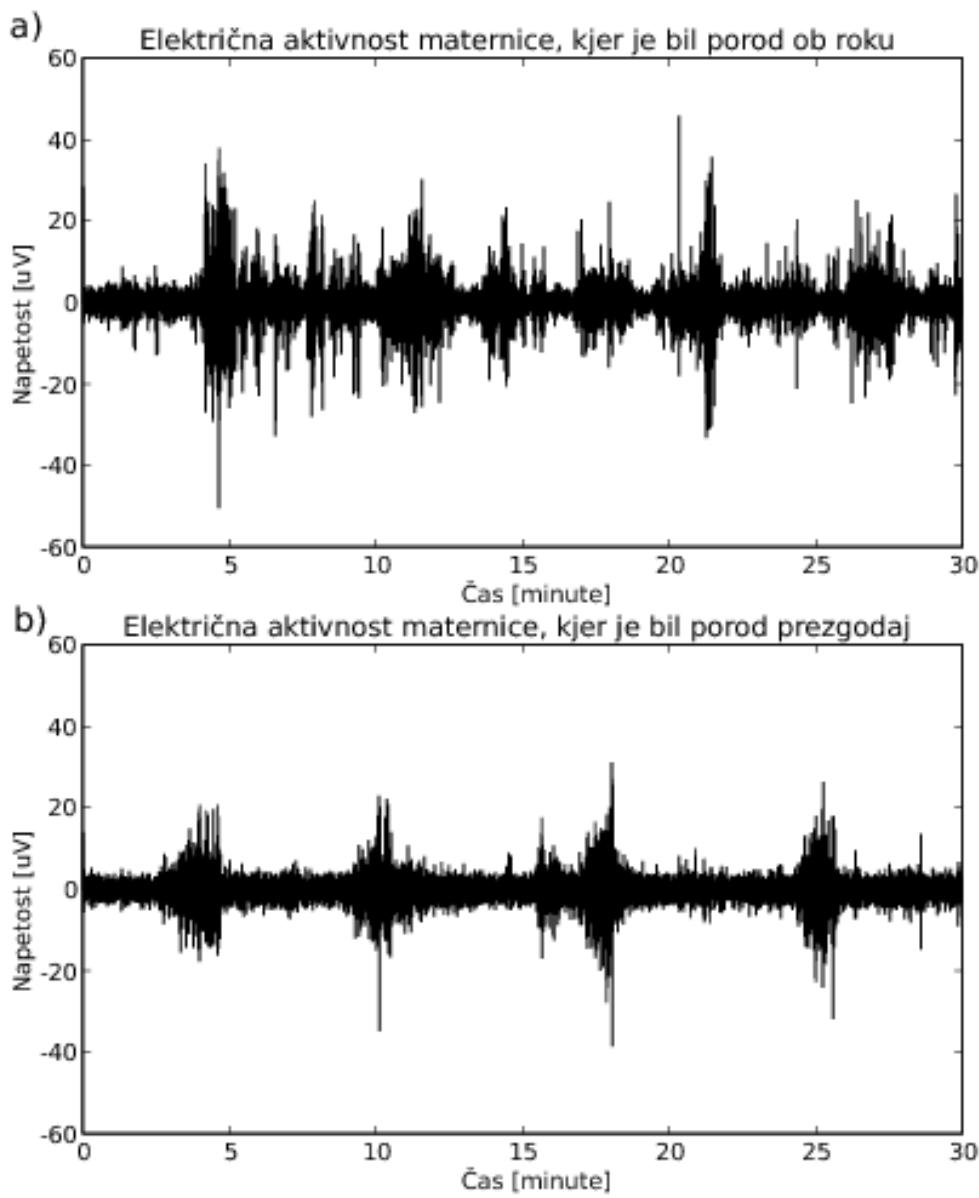
Hipoteze

- **Narava električne aktivnosti maternice narekuje uporabo nelinearnih tehnik analize signalov**

Mišičasti del maternice, miometrij, je sestavljen iz velikega števila (nekaj sto milijonov) gladkomišičnih celic. Celice maternice se odzivajo na električne dražljaje, pri čemer je njihov odziv nelinearen. Vzburjene mišične celice se lahko odzivajo na akcijske potenciale, lahko pa jih tudi prožijo.

Kako točno so celice med seboj povezane, zaenkrat še ni znano, kot tudi ni znano, kako točno se usklaja delovanje celic med krči maternice in med popadki. Vseeno lahko trdimo, da je maternica kompleksen, dinamičen, nelinearen sistem, saj so fiziološki mehanizmi, ki upravljajo njeno delovanje, nelinearni [22]. Zaradi nelinearnosti sistema smo pričakovali, da bodo pri analizi električnih signalov maternice uporabne nelinearne tehnike obdelave signalov. Na to misel so nas napeljali tudi rezultati nekaterih raziskav, v katerih so bile uporabljenе nelinearne tehnike obdelave signalov [23], med katerimi je bila tudi ocena fraktalne dimenzije salv električne aktivnosti maternice [13].

Predhodna opazovanja nekaterih posnetkov električne aktivnosti maternice so nas napeljala na misel, da bi utegnila biti električna aktivnost maternic v primerih, ko je porod ob roku, bolj urejena in manj kaotična od električne aktivnosti maternic v primerih, ko je porod prezgoden. Primera dveh signalov, zajetih na površini maternic, kjer je bil en porod prezgoden, drugi pa ne, sta prikazana na sliki 2.1. Za posnetek, kjer je bil porod prezgoden, se zdi, da je električna aktivnost pod nadzorom le enega procesa. Za posnetek, kjer je bil porod ob roku, se zdi, da je električna aktivnost pod nadzorom več ločenih procesov (3).



Slika 2.1: Električna aktivnost, kjer je v enem primeru (zgoraj) do poroda prišlo ob roku (v 39. tednu nosečnosti), v drugem (spodaj) pa prezgodaj (v 31. tednu nosečnosti). Oba posnetka sta bila zajeta v 30. tednu nosečnosti.

- **Značilnosti in spremembe močnostnega spektra električne aktivnosti maternice lahko nakažejo prezgodnji porod**

Na žalost iz surovih zapisov električne aktivnosti maternice ne znamo razbrati nobenih uporabnih značilnosti. Dosedanje raziskave so pokazale, da je od same jakosti signala najverjetnejše pomembnejši močnostni spekter signala [24]. Za prikaz sprememb močnostnega spektra signala skozi čas lahko uporabimo različne časovno-frekvenčne predstavitev signala.

Predpostavljamo, da se bo na spektrogramih signalov pokazala kakšna značilna razlika med posnetki, kjer je bil porod prezgodaj in tistimi, kjer je bil porod ob roku, ali med tistimi, ki so bili zajeti zgodaj v nosečnosti in tistimi, ki so bili zajeti kasneje.

Frekvenčna ločljivost spektrogramov je omejena. Višja ločljivost v frekvenčnem prostoru lahko dosežemo z uporabo časovno-frekvenčne predstavitev Wignerja in Villeja. Odločili smo se, da preizkusimo tudi to metodo vizualizacije signalov.

- **Obstoječe linearne metode obdelave signalov so slabši pokazatelj prezgodnjega poroda od nelinearnih metod**

Dosedanje raziskave EMG maternice so se osredotočale predvsem na analizo moči in močnostnega spektra signalov električne aktivnosti maternice [6, 11, 12, 18, 25]. Da bi ocenili, kako se obnesejo nelinearne tehnike obdelave signalov, smo se odločili, da jih primerjamo s preverjenimi linearimi metodami obdelave signalov - korenom srednje vrednosti kvadratov (RMS , root mean square), frekvenco vrha močnostnega spektra in mediano frekvenco. Poleg preverjenih metod smo se odločili, da v vlogi cenilke preizkusimo tudi prvi prehod preko ničle koeficientov avtokorelacije.

Da bi identificirali tiste cenilke, ki bi bile lahko dobre za napovedovanje grožnje prezgodnjega poroda, lahko za začetek preverimo, ali se pri kateri od cenilk pokaže statistično pomembna razlika med skupinama posnetkov, kjer je bil porod prezgodaj in posnetkov, kjer je bil porod ob roku. Za napovedovanje grozečega prezgodnjega poroda bi bile uporabne tudi cenilke, ki se med nosečnostjo pomembno spremenijo, saj bi z njihovo uporabo verjetno lahko napovedali, če bo do poroda prišlo kmalu. Zato smo se odločili, da preverimo še, ali se pri kateri od cenilk pokaže statistično pomembna razlika med posnetki, ki so bili zajeti zgodaj med nosečnostjo in tistimi, ki so bili zajeti kasneje.

Odločili smo se, da za preverjanje, ali se je pokazala kakšna statistično pomembna razlika med skupinami posnetkov, uporabimo Studentov t-test.

Za samo napovedovanje prezgodnjega poroda bi potrebovali ne samo uporabne cenilke, temveč tudi klasifikator, ki bi lahko avtomatično uvrstil poljuben posnetek v eno od izbranih skupin. V ta namen smo se odločili na preverjanih cenilkah preizkusiti tudi različne klasifikatorje. Izbrali smo dva. Naivni Bayesov klasifikator je preprost, a robusten. Odločitvena drevesa so bolj zapletena in zmogljivejša, ampak se lahko pretirano prilagodijo učni množici.

- **Nelinearne metode obdelave signalov lahko nakažejo prezgodnji porod**

Raziskave nelinearnih metod obdelave signalov za analizo električne aktivnosti maternice so trenutno redke [13]. Zato smo se odločili, da preizkusimo nekaj doslej nepreizkušenih nelinearnih tehnik obdelave signalov.

Odločili smo se, da preizkusimo tri nelinearne tehnike obdelave signalov. Prvi dve sta osnovani na rekonstruiranem faznem prostoru. Maksimalni eksponent Ljapunova predstavlja oceno količine kaosa v sistemu. Korelacijska dimenzija predstavlja oceno kompleksnosti časovne vrste. Tretja izbrana tehnika, vzorčna entropija, predstavlja oceno, pogosto se vzorci v signalu ponavljajo. Vse preizkušene tehnike na tak ali drugačen način ocenjujejo kompleksnost, kaotičnost ali entropijo signala. Predpostavljamo, da se bodo posnetki v eni skupini po kateri od teh lastnosti razlikovali od posnetkov v drugi skupini.

POGLAVJE 3

Fiziološko ozadje

3.1 Maternica

Maternica je ženski reproduktivni organ, značilen za vse sesalce. V ženskih zarodkih se maternica, jajcevodi in del vagine razvijejo iz Müllerjevih vodov. Maternice so pri različnih sesalcih lahko različnih oblik. Tako je maternica pri miših razdeljena v dve cevi, ki se na eni strani zaključita blizu jajčnikov, na drugi pa sta združeni skoraj pri materničnem ustju. Pri ovcah je maternica razdeljena na dva roga, ki sta skoraj stožaste oblike in v spodnjem delu združena. Pri ljudeh in nekaterih primatih sta se rogova popolnoma zlila v eno samo votlino. Stena maternice je sestavljena iz treh plasti: notranje sluznice - endometrija, mišične plasti - miometrija in tanke zunanje serozne plasti. Anatomsko jo delimo na tri dele: telo (corpus uteri), ustje (isthmus) in vrat (cervix), funkcionalno pa med porodom na telo in cervikositnični del. V telo zgoraj ob straneh vstopata jajcevoda, medtem ko se maternični vrat odpira v阴道. Miometrij je sestavljen iz nekaj sto milijonov gladkomišičnih celic. Organizacija teh celic je zapletena in še ni povsem raziskana. Vseeno je znano, da je mišičasti del maternice sestavljen iz najmanj treh plasti: notranje, srednje ter zunanje. Notranja plast je sestavljena iz krožno potekajočih mišičnih vlaken. V srednji plasti se mišične vitre, izhajajoče iz tubarnih kotov, kjer v maternično telo vstopajo jajcevodi, diagonalno prepletajo. Zunanja plast je sestavljena iz dveh podplasti: notranje, kjer vlakna potekajo krožno, ter zunanje, kjer vlakna potekajo vzdolž telesa maternice. Odstotek mišičnih vlaken je v različnih delih maternice različen - ob porodu maternično telo sestavlja približno 69% mišičnih vlaken in 31% ostalega tkiva, zgornji del vratu sestavlja 29% vlaken in 71% ostalega tkiva, v spodnji del vratu maternice pa je sestavljen iz le okrog 6% mišičnih vlaken in kar 94% ostalega tkiva. Za dovod krvi v maternico skrbijo v glavnem maternične arterije, delno pa lahko za

prekrvavitev poskrbi tudi ožilje jajčnikov. Za prekrvavitev same maternice in posteljice v nosečnosti skrbijo spiralne arterije v maternici. Za normalno rast mora biti plodu ves čas na voljo dovolj krvi. Motnje v preskrbi s krvjo lahko povzročijo tudi zastoj v rasti ploda.

Večina živčevja v maternici je del avtonomnega živčnega sistema in prihaja preko spodnjega hipogastričnega živca ter uterovaginalnega pleksusa v bazi širokega ligamenta. Živčno nitje maternice je navzgor povezano z živčnim pleksusom ob jajčnikih. Živčno nitje, ki povzroča krčenje žil in maternice, izhaja iz segmentov hrbtenjače Th12 do L1. Živčno nitje, ki povzroča širjenje žil in sproščanje maternice, izhaja iz segmentov S2 do S4. Zanimivo je, da se gostota živčnih vlaken med nosečnostjo ne poveča, temveč se lahko celo zmanjša [21]. V vsakem primeru je krčenje maternice pod močnim hormonskim vplivom, vloga živcev pri krčenju, če je sploh pomembna, pa nedokazana. Somatsko živčevje nad krčenjem maternice nima nadzora, kar pomeni, da potiskanje med porodom nima bistvenega vpliva [26].

3.1.1 Krčenje maternice

Gladke mišične celice, iz katerih so sestavljena mišična vlakna miometrija, so zelo vzdražljive. Običajno se ritmično krčijo že same po sebi. Frekvenca in amplituda krčenja se od celice do celice razlikujeta. Ob vzburjenju mišične celice na njeni membrani pride do nastanka akcijskega potenciala. Običajno med okolico in notranjostjo celice obstaja električna napetost okrog 50 mV. Če ta napetost pade pod določen prag, se v celični steni odprejo posebni kanali, ki v notranjost celice spustijo pozitivno nabite ione. Napetost med okolico in notranjostjo celice tako doseže vrednost okrog -40 mV. Nato se v celični steni odprejo drugi kanali in tok nabitih delcev steče v obratno smer, dokler se ne vzpostavi začetna napetost. Ker med prečrpavanjem ionov naraste električna napetost po celotni celični membrani, se celice lahko vzburjajo ena za drugo, tako da se akcijski potenciali širijo od celice do celice po celotnem tkivu. V mnogih organih za prenašanje akcijskih potencialov skrbijo specializirane celice v posebnih tkivih. To so na primer živci v večini organov ali Purkinjejeva vlakna v srcu. Zaradi podobnosti med srčno gladko mišico in gladkim mišičevjem maternice se je pojavila hipoteza, da bi utegnila tudi v maternici obstajati posebna tkiva ali področja, kjer se ustvarjajo akcijski potenciali in ki skrbijo za tvorjenje ter uspešno širjenje popadkov. Ta hipoteza doslej še ni bila z ničemer potrjena, v zadnjem času pa se je celo bolj uveljavila alternativna hipoteza, po kateri naj bi kot prožilec akcijskih potencialov lahko služila katetera koli gladka mišična celica v miometriju, komunikacija med njimi pa naj bi potekala s pomočjo valov kalcijevih ionov [27]. Območja maternice, kjer so celice bolj vzburljive, se

rahlo depolarizirajo (napetost med zunanjostjo in notranjostjo celice pade za 5 do 15 mV). Takšna, rahla depolarizacija se večkrat ponovi, s čimer se membranski potencial sosednjih celic zniža do praga vzburjenja, s čimer se sproži plaz akcijskih potencialov [28, 29]. Kje se tovrstna območja nahajajo, zaenkrat ni znano.

Za uspešen iztis vsebine maternice je nujno, da se vse celice maternice krčijo usklajeno. Depolarizaciji ene celice sledi depolarizacija sosednjih, pri čemer mora plaz potekati v pravi smeri. Kako je za to poskrbljeno, zaenkrat ne vemo. Znano je, da je med nosečnostjo povezanost med področji maternice zmanjšana, tako da so spontani popadki, do katerih prihaja med nosečnostjo, omejeni na posamezna področja in se ne razširijo na celotno maternico. Učinkovito širjenje popadkov po maternici je preprečeno s pomočjo hormonov, ki vplivajo na delovanje mišičnih celic miometrija. Blokado širjenja popadkov lahko kadarkoli med nosečnostjo premagamo s pomočjo zdravil za pospeševanje popadkov in tako povzročimo porod ali splav [30, 31]. Na žalost pa do odpovedi te blokade lahko pride tudi spontano, kar vodi lahko do prezgodnjega poroda. Pri nekaterih živalih je plasti miometrija mogoče dobro ločiti. Pri podghanah so tako opazili, da se v vzdolžni smeri po maternici širijo drugačni akcijski potenciali, kot so tisti, ki se širijo krožno. To seveda napeljuje na misel o različni funkciji posameznih plasti. Na žalost plasti mišic v človeški maternici ni mogoče lepo razslojiti na vzdolžno in krožno plast, vseeno pa lahko ugibamo, da so lastnosti teh plasti različne [32]. To nas napeljuje na misel, da bi se električna aktivnost maternice v vzdolžni smeri lahko razlikovala od električne aktivnosti maternice v prečni (krožni) smeri.

3.2 Hipoteza kalcijevih valov

Električna vzburljivost posameznih mišičnih celic je že dokaj dobro znana. Na žalost pa širjenje akcijskih potencialov ne razлага dovolj dobro kompleksnega obnašanja maternice med popadki. Precej obetavna razлага širjenja popadkov po maternici je hipoteza kalcijevih valov. Po tej hipotezi so popadki v veliki meri nadzirani s pomočjo presnove kalcija in z njo povezanih dogajanj v maternici. Krčenje naj bi bilo posledica povišane koncentracije prostih ionov kalcija znotraj celice. Ko koncentracija prostih ionov kalcija pade na mirovni nivo, naj bi se mišice sprostile. Glavni povod za takšno hipoteze je trajanje popadkov pri porodu. Dolgo je veljala hipoteza, da se popadki širijo skupaj z akcijskimi potenciali preko presledkovnih stikov, s katerimi so med seboj povezane mišične celice. Število presledkovnih stikov se namreč tik pred porodom poveča. Težava pri tej preprosti razlagi širjenja popadkov je, da se akcijski potenciali po maternici širijo prehitro. Izmerjena hitrost širjenja akcijskih

potencialov v miometriju nosečih podgan je 13.5 cm/s . Če bi bila hitrost širjenja akcijskih potencialov pri ljudeh enaka, bi plaz aktivnosti zajel vse celice maternice z obsegom 40 cm v približno 3 sekundah. Maksimalni pritisk v maternici bi moral torej nastopiti v približno treh sekundah po začetku popadka. Koncenetracija kalcija v mišičnih celicah maternice ostane povišana približno 25 sekund. To pomeni, da bi moral popadek skupaj trajati okrog 28 sekund. V resnici popadki običajno trajajo več kot minuto. Verjetno je torej, da se celice med seboj sporazumevajo s pomočjo še kakega dodatnega mehanizma, ne le preko akcijskih potencialov. Valove kalcija znotraj celic so opazili že v več različnih tkivih, med drugim v srcu. Pri teh valovih se prosti kalcijevi ioni znotraj celic širijo počasi. Njihova hitrost znotraj celic povrhnjice sapnika je manj kot $20 \mu\text{m/s}$. Tovrstni valovi se lahko širijo tudi med celicami, kjer se širijo še počasneje, s približno $15 \mu\text{m/s}$. Pri tem lahko valovi kalcija med sosednjimi celicami prehajajo tako preko presledkovnih stikov kot tudi preko medceličnine. V kulturah človeških gladih mišičnih celic maternice se tovrstni valovi lahko širijo na razdalje, večje od $700 \mu\text{m}$ s hitrostjo okrog $6.2 \mu\text{m/s}$. Mišične celice v maternici so povezane v vlakna, ki so nato povezana v svitke, ti pa naprej v trakove, ki tvorijo večino miometrija. Svitki in trakovi so drug od drugega ločeni z vezivnim tkivom, ki pa ima ponekod premostitve, s pomočjo katerih lahko signali potujejo med trakovi. Ker kalcijevi valovi s hitrostjo $6.2 \mu\text{m/s}$ v času popadka (60s) ne morejo prepotovati več kot $372 \mu\text{m}$, najverjetneje delujejo znotraj svitkov. Po hipotezi kalcijevih valov širjenje popadka po maternici poteka takole:

1. Akcijski potenciali se razširijo po celotni maternici in sprožijo nastanek kalcijevih valov. Na ta način se na začetku popadka uskladi delovanje vseh delov miometrija. Pri tem ni potrebno, da bi se zaradi akcijskega potenciala vzburiše vse celice; lahko se jih vzburi tudi manj kot 1%. Pomembno je le, da so preko presledkovnih stikov povezani vsi svežnji.
2. Z akcijskim potencialom sproženi kalcijevi valovi se začno širiti znotraj svežnjev, pri čemer se celice krčijo, ko jih doseže val prostega kalcija.
3. Trajanje krča je odvisno od presnove kalcija znotraj celic. Celica ostane skrčena, dokler je koncentracija kalcija znotraj nje povišana.

V primeru, da kalcijeva hipoteza velja, bi morala biti električna aktivnost na začetku ali tik pred začetkom popadka precej večja kot proti koncu.

3.2.1 Vzdrževanje nosečnosti

Točen mehanizem proženja poroda trenutno še ni znan. Vseeno pa je znanih nekaj dejavnikov, ki pomagajo pri vzdrževanju maternice v mirujočem stanju. Predvsem na krčljivost maternice najverjetneje ključno vplivajo koncentracije hormonov v krvi.

3.3 Hormonalni vplivi med nosečnostjo

3.3.1 Pomembnejši hormoni in njih vplivi

Oksitocin

Povzroča popadke. Po porodu povzroči stiskanje mešičkov v dojkah in s tem izločanje mleka.

CRH (Corticotropine releasing hormone), Kortikoliberin - Kortikotropin sproščajoči hormon

Vloga CRH v nosečnosti in izven nje še ni povsem raziskana. Med drugim ga izloča hipotalamus, nakar se v hipofizi pretvarja v kortikotropin. Izven nosečnosti igra pomembno vlogo pri odzivu na stres. Med nosečnostjo ga v velikih količinah izločajo posteljica in plodovi ovoji. Njegova koncentracija v krvi med nosečnostjo narašča eksponentno.

GNRH (Gonadotropin releasing hormone) - Gonadotropin sproščajoči hormon

Izloča se v hipofizi, povzroča izločanje lutenizirajočega hormona in folikle stimulirajočega hormona v hipotalamu. GNRH se sprošča v pulzih. Nizka frekvenca pulzov povzroči izločanje folikle stimulirajočega hormona, medtem ko višja frekvenca pulzov stimulira izločanje lutenizirajočega hormona.

LH - Lutenizirajoči hormon ter FSH - Folikle stimulirajoči hormon

Oba se izločata v hipofizi, izločanje se začne v puberteti. Vežeta se na receptorje v membranah jajčnih celic, stimulirata njihovo rast in izločanje.

V prvih dneh ovulatornega cikla se izločajo velike količine FSH in manjše LH. FSH povzroči rast od 6 do 12 foliklov v jajčnikih vsak mesec. Običajno dozori le eden, v njem

se ustvari več plasti granuloznih celic ter vezivna ovojnica, ki ima zunanjou in notranjo plast. Celice notranje plasti vezivne ovojnice izločajo estrogene in progesteron, celice njene zunanje plasti pa so ožiljene in pokrivajo folikel. Po tednu rasti se ustvari votlina, ki vsebuje folikulo tekočino, v kateri je velika količina estrogenov.

Estrogeni

Estrogeni so skupina steroidov, ki imajo pomembno vlogo v menstrualnem ciklu in predstavljajo glavne ženske spolne hormone. Pri ljudeh v krvi nastopajo estradiol, estriol in estron. Najpomembnejši estrogen je beta estradiol. Nastaja predvsem v jajčnikih iz testosterona in estrona. Nekaj estrogenov nastaja tudi v jetrih, nadledvičnih žlezah in dojkah. Estrogeni povzročajo razvoj dojk, odebelenje endometrija, rast miometrija, izboljšano prekravavitev nožnice, aktivnost žlez v materničnem vratu, povečano aktivnost fibril v jajcevodih, hitrejše zapiranje rastnega hrustanca, dvigajo metabolizem, zmanjšujejo mišično maso, mehko kožo in prekravavitev, povečujejo resorbco kalcija v kosti, izboljšajo strjevanje krvi, povzročajo zadrževanje natrija in vode, povečajo izločanje rastnega hormona, kortizola, SHBG, zmanjšajo aktivnost črevesja, po rojstvu ustavlja produkcijo mleka. Omogočajo preživetje in širjenje nekaterih vrst raka.

Povečujejo število FSH receptorjev. Skupaj s FSH aktivirajo receptorje na membranah granuloznih celic ter stimulira izločanje LH. Skupaj z LH povzročajo množenje celic vezivne ovojnice folikla in tako njihovo izločanje.

Progesterageni

Edini človeški progesteragen je progesteron. Vpliv progesterona je večinoma nasproten vplivom estrogenov. Poleg tega progesteron povzroča povečano izločanje endometrija, zmanjša imunski odziv, zmanjša krčljivost celic miometrija, zaustavlja produkcijo mleka. Progesteron tudi zavira krčenje maternice.

Humani horijev gonadotropin

Humani horijev gonadotropin se izloča v posteljici. Preprečuje, da bi rumeno telesce v jajčniku matere atrofiralо, s čimer bi prišlo do menstruacije. Poleg tega v primeru, da je plod moškega spola, stimulira celice, ki izločajo testosteron, v testisih ploda. Je torej ključnega pomena za rast moških spolnih organov ploda.

3.4 Ovulatorni ciklus

Vsak mesečni ciklus (ki lahko traja od 20 do 45 dni) lahko razdelimo v dve fazи - folikularno in luteinsko.

3.4.1 Folikularna faza

V folikularni fazi v jajčnikih prihaja do zorenja jajčec. Ob rojstvu ima vsaka ženska v skorji obeh jajčnikov več 100000 jajčec. Jajčeca se nahajajo v foliklih in so obdana s plastjo granuloznih celic. Te celice med otroštvom prehranjujejo jajče in obenem izločajo snov (oocyte maturation-inhibiting factor), ki drži jajčno celico v mirovanju. Foliklom v tem stanju pravimo primordialni folikli.

Ob začetku novega menstrualnega ciklusa redki (nizkofrekvenčni) pulzi izločanja GNRH v hipotalamu povzročijo izločanje večjih količin FSH in manjših količin LH. Povečana koncentracija FSH povzroči rast od 6 do 12 foliklov. V foliklih se pod vplivom estrogena in LH granulozne celice namnožijo in ustvarijo več plasti. Obenem se okrog foliklov oblikujejo dvoplastne vezivne ovojnica. Notranja plast te ovojnica izloča steroidne hormone, kot sta estrogen in progesteron, zunanjega pa vsebuje žilice. Pod vplivom estrogena se v granuloznih celicah poveča število receptorjev FSH, kar naprej povzroči še večje izločanje estrogena. Poleg tega FSH in estrogen skupaj stimulirata izločanje LH, LH in estrogen pa vspodbujata množenje celic vezivne ovojnica in njihovo izločanje različnih snovi.

Tako povečanim foliklom pravimo sekundarni folikli.

Po tednu rasti se v foliku začne tvoriti votlina, napolnjena s foliklovo tekočino, ki vsebuje veliko estrogena. Takšnemu foliku pravimo terciarni ali Grafov folikel.

Običajno se v jajčniku iz neznanega vzroka v Grafov folikel razvije le en, ostali pa propadejo.

V običajnem menstrualnem ciklusu približno 12 dni po zadnji menstruaciji koncentracija LH v krvi začne strmo naraščati, poveča se tudi koncentracija FSH. Pod vplivom obeh hormonov pride do ovulacije. Po obdobju rasti se tik pred ovulacijo zunanjega stena folikla začne tanjšati, razjedati in razpadati zaradi encima, ki ga pod vplivom LH izločajo granulozne celice. V centru folikla se ustvari mehurček. Po približno 30 minutah foliklova tekočina vdre v mehurček, ki nato v nekaj minutah poči, pri čemer tekočina odplakne iz folikla jajčno celico, obdana s plastjo granuloznih celic.

3.4.2 Luteinska faza

Po sprostitvi jajčeca se granulozne celice in notranja vezivna plast celic v foliku spremenijo v luteinske celice. Le-te se povečajo in napolnijo z lipidi, ki jim dajo značilno rumeno barvo. Tako nastane rumeno telo. Celice teka začnejo izločati testosteron, ki se nato preoblikuje v progesteron in nekaj estrogena. Rumeno telo v 7 do 8 dneh po ovulaciji zraste do premera 1.5 cm, nakar začne zaradi pomanjkanja LH počasi propadati. Če do oploditve ne pride, se po 12. dnevu spremeni v vezivno tkivo, izgubi barvo in se spremeni v belo telo. Če do oploditve pride, vlogo LH prevzame humani horijev gonadotropin, ki ga izloča placenta, rumeno telo pa se obdrži.

3.5 Endometrijski ciklus

Vzporedno z ovulacijskim ciklom se seveda dogajajo tudi ciklične spremembe v maternici. Endometrij je sestavljen iz dveh plasti, bazalne (lamina basalis) in funkcionalne (lamina functionalis). S krvjo ga preskrbujejo spiralne arterije, ki med nosečnostjo skrbijo tudi za preskrbo ploda.

3.5.1 Faza rasti endometrija

Na začetku mesečnega cikla v endometriju ostane le tanka plast celic funkcionalne plasti. Iz žilic bazalne plasti lahko še uhaja kri, prav tako v bazalni plasti ostanejo nekatere globlje žleze. Pod vplivom estrogena se celice povrhnjice teh žlez začnejo množiti in se razširijo po celotni površini endometrija. Prav tako se razširi vezivno tkivo, tako da se endometrij odebeli. V povrhnjici se ustvari veliko število žlez, ki so v tej fazi še ozke in zvite. Prav tako se v funkcionalno plast začno širiti spiralne arterije. Ob koncu rasti je debelina povrhnjice okrog 2mm.

3.5.2 Plodna faza

V plodni ali sekretorni fazi začne z žlezami prepletena povrhnjica endometrija izločati glikoproteine, ki povzročijo, da se žleze raztegnejo in razprejo. V tej fazi žleze izločajo hranilne snovi, ki olajšajo vgnezdenje oplojenega jajčeca. V okolini materničnega vratu žleze izločajo sluz, ki se v trakovih širi skozi maternični vrat. Ti trakovi pomagajo usmerjati spermije proti jajčecu. V primeru, da pride do oploditve, začne razvijajoči se zarodek prebavljati endometrij in se vgnezdi. Za vzdrževanje plodnega endometrija so v zgodnji nosečnosti nujni

hormoni, ki jih izloča rumeno telesce.

3.5.3 Krvavitev

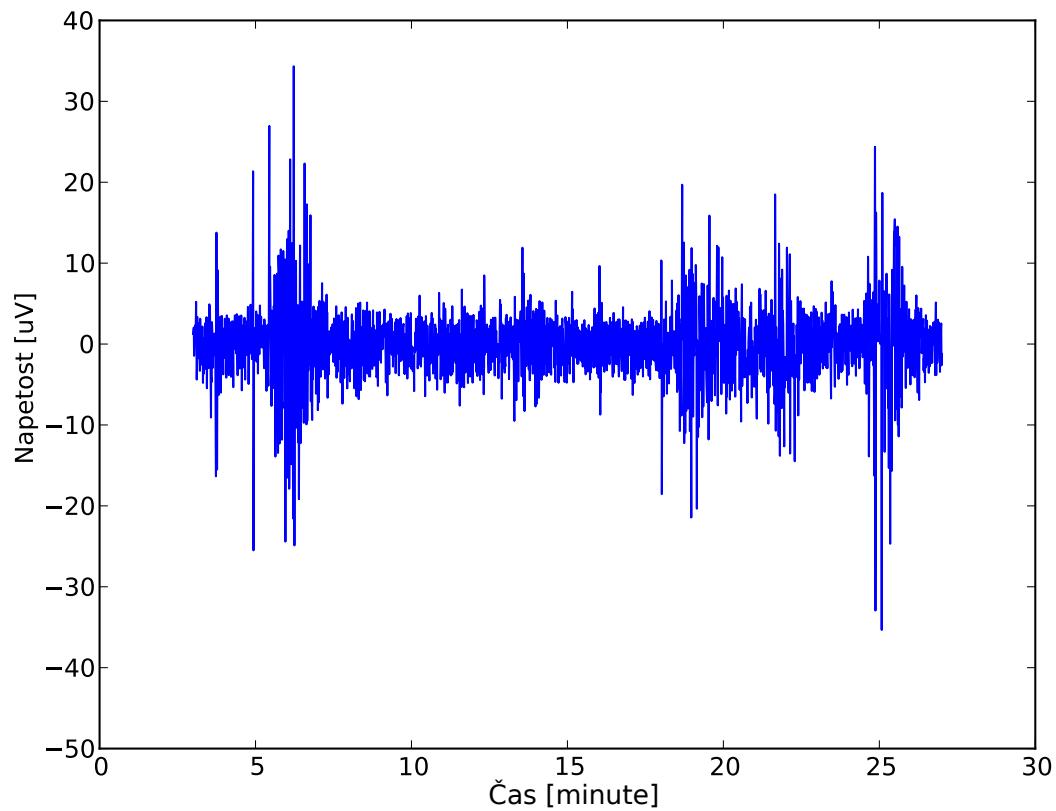
Dva dni pred koncem cikla se količina hormonov, ki jih izločajo jajčniki, zmanjša. Endometrij se začne tanjšati. Dan pred začetkom krvavitve se spiralne arterije, ki skrbijo za prehranjevanje sluznice endometrija, začnejo krčiti. Tkiva začnejo odmirati, še posebej to velja za žile. Po približno 48 urah se vrhnji deli endometrija začnejo luščiti, maternica pa se začne krčiti, tako da se odmrla tkiva izločijo. Odluščena tkiva izločajo tudi fibrinolizin, ki onemogoča strjevanje krvi, tako da se odmrla tkiva skupaj s krvjo in ostalo tekočino izločijo. Krvavitev se konča, ko se povrhnjica endometrija spet razraste.

3.6 Hipoteza o pomenu kortikotropin sproščajočega hormona

Eksponentno naraščanje koncentracije CRH med nosečnostjo kaže na to, da bi koncentracija tega hormona lahko bila ključna pri proženju poroda [33].

3.7 Salve električne aktivnosti na površju maternice

Med krči maternice je na njeni površini mogoče zaznati salve električne aktivnosti [34]. Primer takšnih salv lahko vidimo na sliki 3.1. Na žalost spontani krči maternice niso edini, ki lahko povzročijo takšne salve. Do zaznave salv električne aktivnosti lahko namreč pride tudi zaradi premikov ploda, zaradi premikov nosečnice ali zaradi premikov elektrod, s katerimi merimo električno aktivnost. Ločevanje med različnimi vrstami salv električne aktivnosti je težavno, čeprav se tudi na tem področju izvajajo raziskave [24]. Čeprav lahko spontane krče maternice zaznamo že zgodaj v nosečnosti [19], so v 22. tednu nosečnosti krči razmeroma redki. Večino signala torej lahko predstavlja „tišina“ med popadki. Ker ne vemo, ali tudi električna aktivnost maternice zunaj salv aktivnosti nosi koristne informacije, se nam izbiranje posameznih salv znotraj posnetkov zdi nesmotrno. Poleg tega bi za zanesljivo ločevanje popadkov od drugih dogodkov potrebovali poleg meritve električne napetosti še zapis ocene intrauterinega tlaka, zajet s pomočjo tokografa. Pri večini posnetkov v naši bazi ta podatek ni bil zajet.



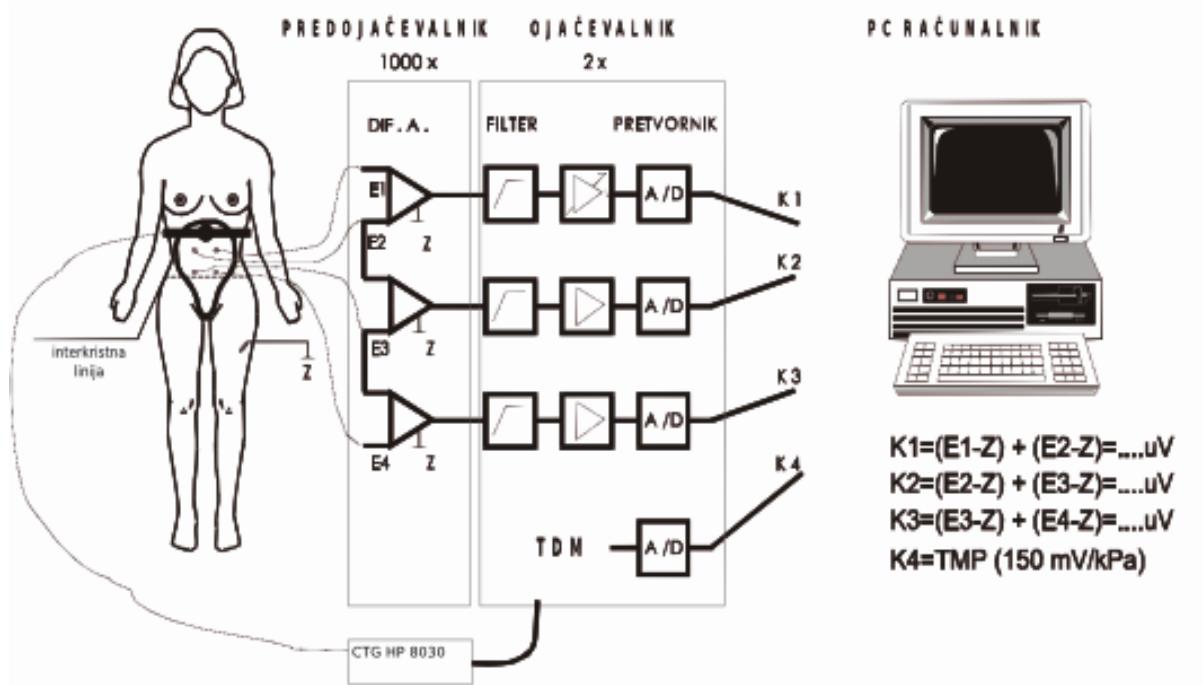
Slika 3.1: Primer salv električne aktivnosti maternice

POGLAVJE 4

Razvoj podatkovne baze posnetkov elektromiogramov maternice

4.1 Zbrani posnetki

Med leti 1997 in 2005 je bilo na Kliničnem oddelku za perinatologijo Ginekološke klinike Univerzitetnega kliničnega centra v Ljubljani (v nadaljevanju v Porodnišnici Ljubljana) zbranih 1211 posnetkov električne aktivnosti. Večina posnetkov, 1187, je bila zbrana med opazovanjem 692 nosečnosti, nekaj (24) posnetkov pa je bilo testnih. Med testnimi posnetki je na primer posnetek električne aktivnosti, merjene na trebuhi avtorja doktorata. Posnetki so bili merjeni z aparatujo, razvito v Porodnišnici Ljubljana. Sistem za zajem podatkov je sestavljen iz nastavljivega predajačevalnika, ojačevalnika, pasovno-prepustnih filterov, A/D pretvornika v obliki ISA razširitevne kartice ter računalnika, v katerega je kartica vgrajena (slika 4.1). Za zajem posnetkov je bil uporabljen program, ki teče pod operacijskim sistemom DOS. Posnetki so bili vzorčeni z natančnostjo 16 bitov pri frekvenci vzorčenja 20 Hz. V aparatujo je bil vgrajen nizko-prepustni Butterworthov filter 3. reda z mejno frekvenco pri 5 Hz. Čeprav je bilo število posnetkov doslej dokaj obvladljivo, pričakujemo, da se bodo posnetki v prihodnosti še zbirali. Poleg tega je bilo potrebno skupaj s posnetki zbrati in urediti še cel kup spremljajočih podatkov. Zato smo se odločili razviti podatkovno bazo, v kateri so in bodo shranjeni podatki o posnetkih in nosečnostih.

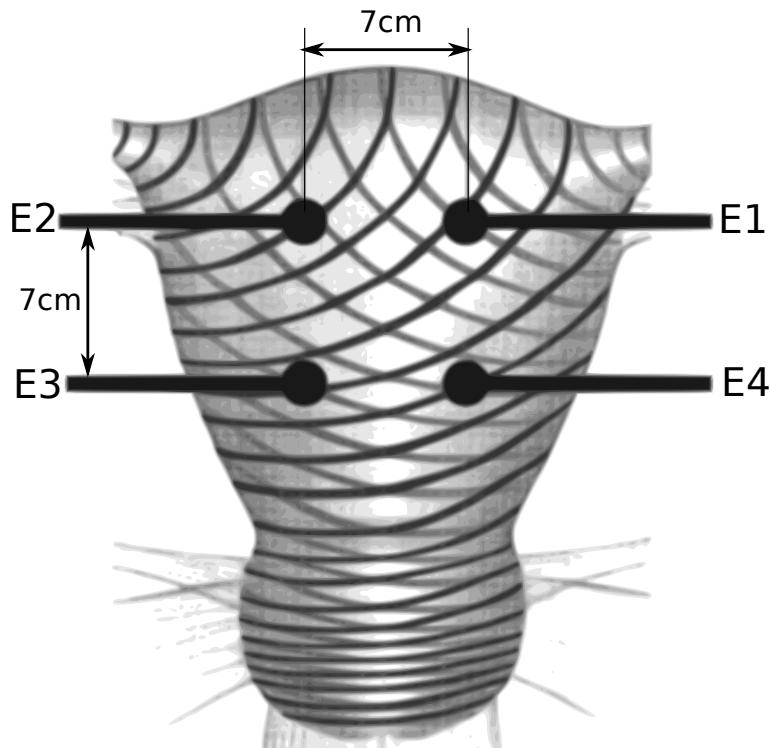


Slika 4.1: Sistem zajema posnetkov EMG maternice

4.2 Položaj elektrod

V raziskavi smo uporabili posnetke, zajete s pomočjo štirih elektrod. Elektrode smo namestili s pomočjo šablone, simetrično okrog popka, na razdalji 7 cm drugo od druge. Položaji elektrod so prikazani na sliki 4.2. Vsak posnetek vsebuje signale, zajete na treh kanalih:

1. med zgornjima elektrodama (E2 - E1),
2. med levima elektrodama (E2 - E3),
3. med spodnjima elektrodama (E4 - E3).



Slika 4.2: Položaji elektrod nad površino maternice. Kanal 1: E2 - E1, kanal 2: E2 - E3, kanal 3: E4 - E3.

Zaradi večanja prostornine maternice je bil zgodaj v nosečnosti položaj elektrod glede na maternico drugačen, kot kasneje v nosečnosti. Vseeno je uporaba šablone poskrbela, da so bile meritve med različnimi nosečnicami konsistentne. Pri nekaterih posnetkih je bil poleg treh kanalov z električno aktivnostjo prisoten tudi četrти kanal z oceno tlaka v maternici, izmerjeno s pomočjo tokografa, torej tipala, nameščenega na površini trebuha.

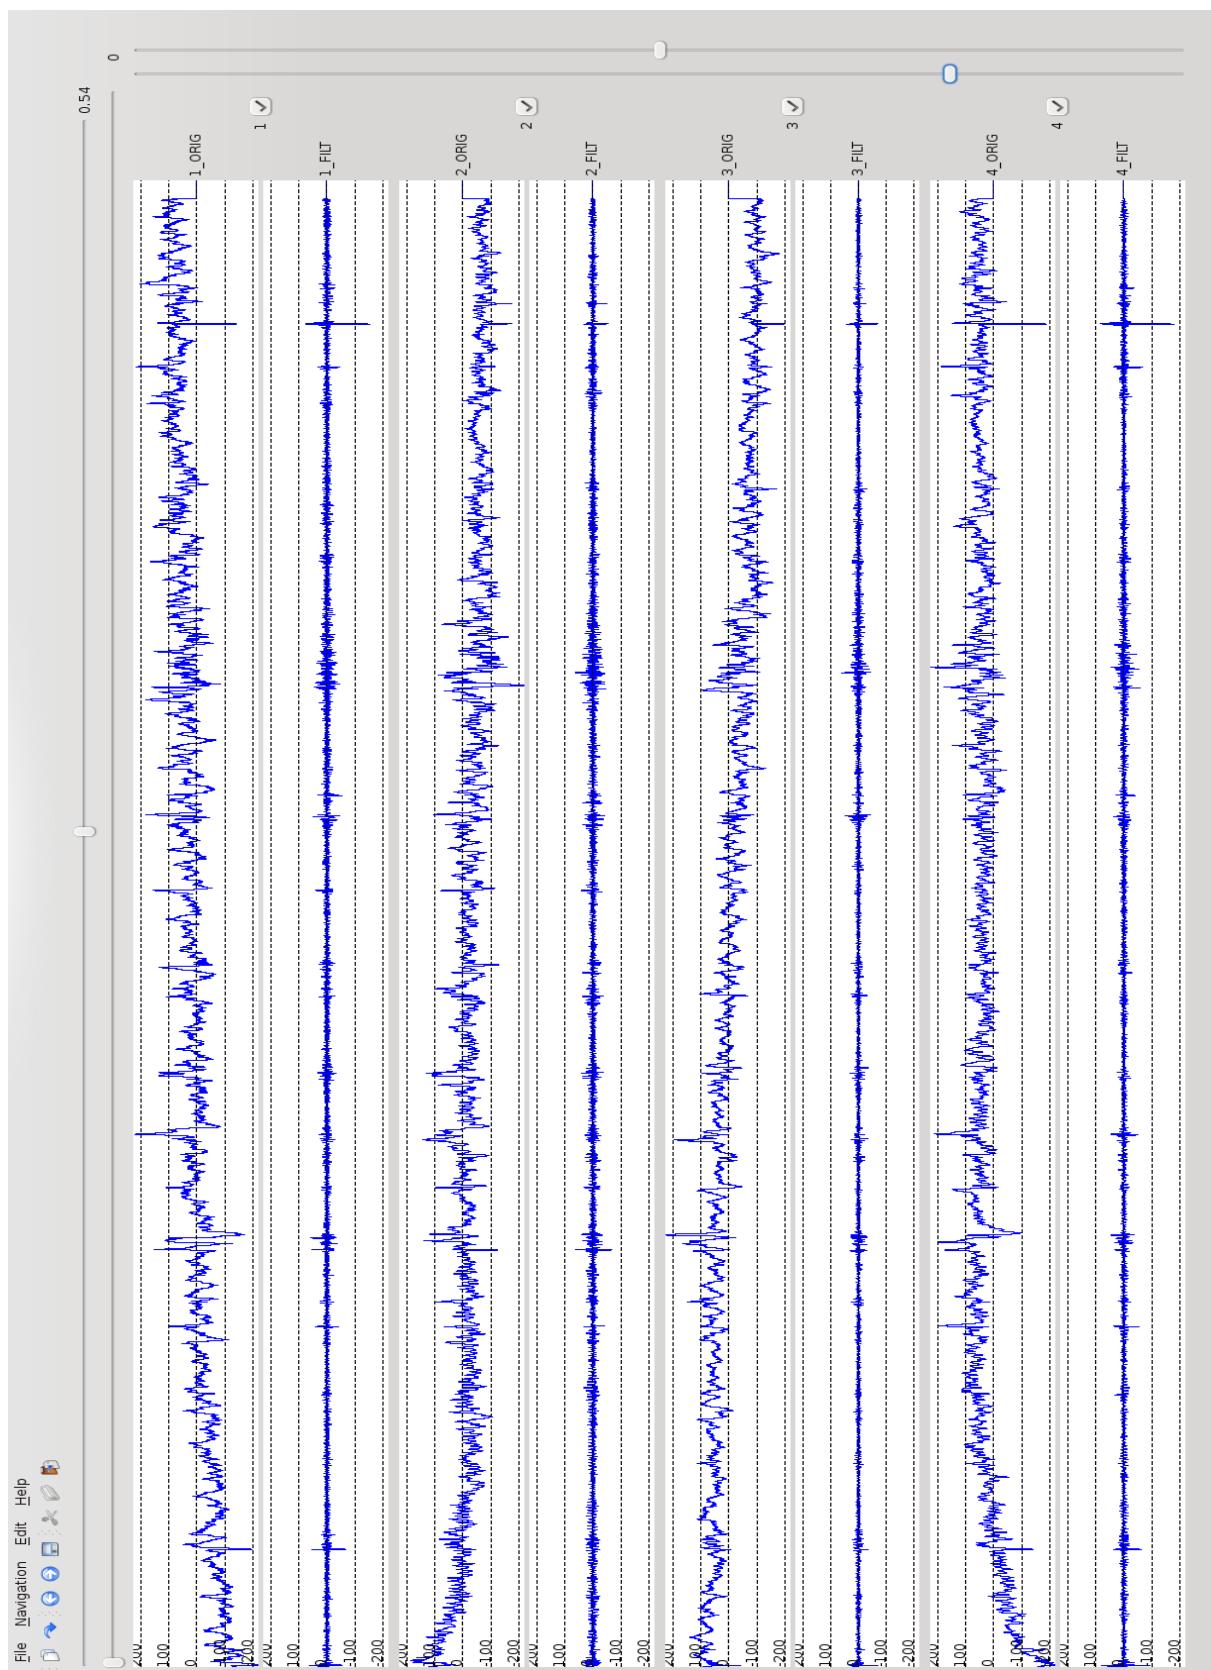
4.3 Kvaliteta posnetkov

Med zajemom posnetkov EMG maternice lahko pride do različnih napak. Tako je lahko na primer koža slabo očiščena, elektrode nameščene na napačna mesta, med snemanjem elektrode zdrsnejo, itd. V izogib večini napak je bil že v začetku raziskave, v kateri so bili v Porodnišnici Ljubljana zajemani posnetki, vzpostavljen natančen protokol za merjenje [11]. Nosečnici smo z acetonom in etrom očistili in razmastili kožo. Za zmanjšanje upornosti smo kožo očistili še z zelo finim brusnim papirjem. Na površino trebuha smo namestili šablono za namestitev elektrod. Vse štiri elektrode smo namazali s kontaktnim prevodnim gelom ter jih namestili. Nato smo pomerili upornost med vsakim parom elektrod, ki je morala biti manjša od $20\text{ K}\Omega$. Če je bila večja, smo ponovili postopek namestitve elektrod. Predojačevalnik smo namestili na levo stegno nosečnice. V primerih, ko je bila zajeta tudi ocena pritiska znotraj maternice, smo na fundus maternice namestili tipalo (tokograf) za odjemanje pritiska. Meritev je trajala 30 minut. Po pogovoru s preiskovanko in z uporabo njene dokumentacije smo izpolnili obrazec s spremljajočimi podatki.

Na žalost protokol ni vseboval navodil za primer zdrsa ali odklopa elektrod med samo meritvijo. Prav tako v protokol ni bilo vključeno preverjanje, ali je predojačevalnik vklopljen in nastavljen na pravo vrednost. Podatki o tem, ali je med meritvijo prišlo do kakšne morebitne napake, torej niso bili zapisani.

4.4 Predizbor posnetkov

Med snemanjem posnetkov električne aktivnosti maternice lahko pride do različnih napak. Med takšne napake sodijo premiki nosečnice, zdrsi elektrod, odklop predojačevalnika med snemanjem ter razne električne motnje iz okolja. Da bi izločili posnetke s preveč ali prehudmi motnjami, smo morali vse posnetke najprej pregledati in izločiti tiste, pri katerih je med snemanjem prišlo do napak. Za pregledovanje posnetkov smo razvili program z uporabniku prijaznim vmesnikom, ki je prikazan na sliki 4.3. Za izdelavo grafičnega vmesnika smo uporabili knjižnico Qt, kar nam je omogočilo, da program uporabljam na več operacijskih sistemih - v našem primeru Windows XP in Debian GNU/Linux.



Slika 4.3: Uporabniški vmesnik programa za ocenjevanje posnetkov EMG maternice

Program omogoča hkratno pregledovanje več signalov istega posnetka. Posnetki so zapisani kot datoteke v imeniku na disku računalnika, na katerem dela uporabnik. Uporabnik lahko izbere posnetke, ki jih bo ocenil kot dobre, nakar jih program premakne v nek drug imenik. Na ta način lahko uporabnik najprej posnetke razdeli na tiste, ki so zagotovo neuporabni in tiste, ki bi lahko bili uporabni. V naslednjem koraku lahko uporabnik iz imenika s posnetki, ki bi lahko bili uporabni, odstrani tiste, ki so verjetno neuporabni. Ta postopek uporabnik ponavlja, dokler ni razvrstil vseh posnetkov po skupinah glede na njihovo uporabnost. Pri ocenjevanju posnetkov v naši bazi smo vsak posnetek uvrstili v natanko eno izmed štirih skupin:

1. Signal je zagotovo neuporaben.
2. Signal je verjetno neuporaben.
3. Signal je verjetno uporaben.
4. Signal je zagotovo uporaben.

Pri razvrščanju sta sodelovala strokovnjak s področja medicine (Gorazd Kavšek, perinatolog) in avtor te doktorske disertacije. To, v katero skupino smo uvrstili posnetek, smo pri nadaljnji obdelavi posnetkov uporabili kot subjektivno oceno kvalitete posnetka.

4.5 Načini zapisa podatkov

Pri gradnji baz podatkov z biološkimi signali in spremljajočimi podatki je pomembno, v kakšni obliki so podatki shranjeni. Različni pristopi k shranjevanju podatkov imajo svoje prednosti in slabosti, izbira najpreimernejšega pa je odvisna od potreb uporabnika.

4.5.1 Posnetki v binarni obliki, spremljevalni podatki v eni ali več tekstovnih datotekah

Prednosti tega pristopa so hitro branje posnetkov z diska ter manj porabljenega prostora, prav tako pa ni izgube natančnosti zaradi pretvarjanja med različnimi načini zapisa izmerjenih vrednosti. Slabosti takšnega pristopa so predvsem oteženo iskanje posnetkov glede na spremljevalne podatke oziroma njihovo razvrščanje v skupine glede na poljubno lastnost, oteženo pregledovanje posnetkov, nevarnost, da se zaradi površnega programiranja posnetki narobe dekodirajo ter otežena uporaba podatkov z obstoječimi orodji, kot so na primer

sistemi za numerično matematiko (MATLAB, OCTAVE), razni programi za delo z razpredelnicami (EXCEL, OPENOFFICE CALC) ter knjižnice in programi za obdelavo in prikaz podatkov (PYTHON + SCI PY, GNUPLOT).

4.5.2 Posnetki v tekstovni obliki, spremeljevalni podatki v eni ali več tekstovnih datotekah

Prednosti zapisa posnetkov v tekstovni obliki sta dve: preprost je ročno pregledovanje vrednosti in možnost preproste uporabe posnetkov v različnih programih za obdelavo podatkov. Ravno zaradi preprostosti ta pristop pogosto uporablja, še posebej, če število posnetkov ni previsoko. Še vedno je pri tem pristopu prisoten problem urejanja posnetkov glede na spremeljevalne podatke.

4.5.3 Posnetki v tekstovni ali binarni obliki na datotečnem sistemu, spremeljevalni podatki v eni datoteki

Pri tem pristopu so posnetki običajno v posameznih datotekah, medtem ko so spremeljevalni podatki spravljeni v eni datoteki, običajno v razpredelnici. Prednost tega pristopa je predvsem možnost preproste obdelave podatkov v poljubnem programu za delo z razpredelnicami. Zaradi minimalnega potrebnega predznanja se lahko z obdelavo podatkov ukvarjajo tudi strokovnjaki brez poglobljenega računalniškega predznanja, kot so na primer zdravniki. Slabost tega pristopa je, da se slabo obnese pri velikem številu podatkov. Število vrstic v tabeli je predvsem pri starejših različicah programov za delo s tabelami pogosto omejeno. Poleg tega je v tabeli težko opisati bolj zapleteno strukturo spremljajočih podatkov. Strukturirane spremeljevalne podatke smo v naši raziskavi potrebovali, saj smo obdelovali posnetke, pri čemer je bilo lahko narejenih več posnetkov med vsako nosečnostjo, vsaka nosečnica je imela lahko več kot eno nosečnost, nekateri spremeljevalni podatki so se nanašali na posnetek, drugi na nosečnost, tretji pa na nosečnico samo.

4.5.4 Posnetki na datotečnem sistemu, spremeljevalni podatki v relacijski bazi

Hranjenje posnetkov na datotečnem sistemu in spremljajočih podatkov v relacijski bazi omogoča veliko fleksibilnost pri iskanju posnetkov po poljubnih kriterijih. Ta pristop je mogoče uporabiti tudi pri več tisoč posnetkih in milijonih spremljajočih podatkov. Iskanje posnetkov po različnih kriterijih je posebej ob uporabi primernih imenikov (indeksov) v

relacijski bazi v primerjavi z iskanjem po tabelah hitro. Slabosti tega pristopa sta rahlo otežen izvoz spremjevalnih podatkov v različne programe za nadaljnjo obdelavo podatkov in dejstvo, da so spremjevalni podatki in posnetki shranjeni na različnih mestih, kar otežuje izdelavo varnostnih kopij.

4.5.5 Posnetki in spremjevalni podatki v relacijski bazi

Hranjenje posnetkov skupaj s spremjevalnimi podatki v relacijski bazi omogoča preprosto izdelavo varnostnih kopij. Poleg tega lahko tako do podatkov, kot tudi do posnetkov, dostopamo preko omrežja. Na žalost shranjevanje posnetkov v podatkovni bazi s seboj prinese kar nekaj težav. Hitrost branja posnetkov je nižja, kot če so posnetki shranjeni v datotekah. Poleg tega se pojavi vprašanje, kako naj bodo posnetki zapisani v bazi podatkov - kot binarno polje, kot ločena tabela, kot tekstovno polje ali še kako drugače. Težave se pojavijo tudi zato, ker je potrebno posnetke za uvoz v različne programe za izdelavo nekako izvoziti iz baze podatkov.

4.6 Izbera načina zapisa podatkov

Kot je bilo že omenjeno, so bili posnetki v začetku spravljeni ločeno od spremjevalnih podatkov. Zaradi strukturiranosti spremjevalnih podatkov in pričakovanega pogostega iskanja posnetkov glede na določene lastnosti, smo se odločili, da se spremjevalni podatki shranijo v relacijsko podatkovno bazo. Težavnejša pa je bila odločitev, kako shranjevati posnetke. Branje datotek je namreč hitrejše od branja podatkov iz relacijske podatkovne baze, medtem ko relacijska podatkovna baza omogoča preprosto izdelavo varnostnih kopij, s pomočjo dostopa preko omrežja pa tudi porazdeljeno računanje različnih cenilk. Ker je bil velik del tehnik obdelave signalov implementiran v obliki programov, pisanih v jeziku C, je bilo v vsakem primeru potrebno sestaviti sistem za preračunavanje cenilk v enem od skriptnih jezikov. Zaradi večje fleksibilnosti in preglednejše kode smo za implementacijo tega sistema namesto običajne lupine, kot je bash, uporabili jezik PYTHON. Za vsakega od programov smo napisali funkcijo, ki je kot argument sprejela posnetek, nato pa je pognala program za izračun cenilke oziroma cenilk ter vrnila rezultat. Nekateri deli obdelave signalov, kot na primer filtriranje, so bili implementirani kot čiste pythonovske funkcije z uporabo knjižnice SciPY, ki vključuje tudi funkcije za izdelavo različnih digitalnih filtrov. Uporaba PYTHONA nam je tudi omogočila, da poljubno obdelane posnetke serializiramo z uporabo knjižnice CPICKLE

in jih tako shranimo na disk. Kot relacijsko podatkovno bazo za shranjevanje spremjevalnih podatkov smo uporabili POSTGRES. To podatkovno bazo smo izbrali predvsem zaradi dobre dokumentacije, ker podpira transakcije in ker je dovolj razširljiva, da bi lahko v prihodnosti služila kot osnova sistema za širše zbiranje velikih količin spremjevalnih podatkov. Poleg tega je POSTGRES prosta programska oprema, kar pomeni, da je dostopna zastonj. Namestitev je preprosta, v primeru, da bi se v bazi shranjevale večje količine občutljivih zdravstvenih podatkov, pa je izvorna koda dostopna in delovanje podatkovne baze zato bolj transparentno, kot bi bilo, če bi uporabili eno od zastonj, a zaprtih rešitev. Da bi izbrali najprimernejšo rešitev problema shranjevanja posnetkov in spremljajočih podatkov, smo izvedli primerjalni test hitrosti dostopa do podatkov. Izkazalo se je, da branje posnetkov naravnost z datotečnega sistema ni bistveno hitrejše od dostopa do posnetkov, shranjenih v relacijski podatkovni bazi. Ker je računanje nekaterih cenilk časovno potratno, je bilo to, da smo do posnetkov v relacijski podatkovni bazi lahko dostopali tudi preko omrežja, velika prednost. Za izračun cenilk smo namreč lahko uporabili več računalnikov, ki so delali vzporedno. Poleg tega je izdelava varnostnih kopij za slučaj odpovedi diskov postala trivialna.

4.6.1 Podatki o posnetkih in nosečnostih

V datotekah, ki jih je ustvaril program za zajem posnetkov EMG maternice, so bili na voljo naziv raziskave, ime in priimek matere, vzorčna frekvanca, merilno območje in podatki o tem, kateri signal je bil zajet na katerem kanalu. Nekateri drugi podatki so bili shranjeni v EXCEL datoteki, v MICROSOFT ACCESS bazi podatkov ali zapisani na papirju. Nekateri podatki so bili zbrani z namenom, da se jih uporabi v raziskavi v zvezi z materničnimi vratovi, ki sicer ni bila povezana z raziskavami električne aktivnosti maternice.

Za udoben, predvsem pa hiter dostop do podatkov smo jih morali nujno preureediti.

Podatki o nosečnostih in nosečnicah, ki so se zbirali v okviru raziskave, so bili sledeči:
Osnovni podatki:

- Priimek (Priimek),
- Ime (Ime),
- CerID (ID podatkov znotraj raziskave v zvezi z materničnimi vratovi),
- StProtokola (Številka protokola znotraj naše raziskave),

- Datum rojstva matere (Datum rojstva matere),
- PDP (Predvideni datum poroda),
- TV (Telesna višina).

Anamneza:

- SpSplavi1 (Spontani splavi v prvem trimesečju),
- SpSplavi2 (Spontani splavi v drugem trimesečju),
- PrezPor1 (Prezgodnji porodi v prvem trimesečju),
- PrezPor2 (Prezgodnji porodi v drugem trimesečju),
- AnMat (Razvojne nepravilnosti maternice),
- AnMatOpis (Opis razvojnih nepravilnosti maternice),
- OpMatK (Operacije na maternici - konizacija),
- OpMatSC (Operacije na maternici - carski rez),
- OpMatKMM (Operacije na maternici - miomektomija),
- OpMatKAsc (Operacije na maternici - Ascherman),
- StevPor (Število porodov),
- StevSplav (Število splavov),
- IVF (Umetna oploditev),
- kajenje (Kajenje),
- Preeklampsija (Preeklampsija),
- Diabetes (Diabetes),
- hipertenzija (Previsok krvni pritisk).

Nosečnost:

- KrvI (Krvavitev v prvem trimesečju),

- Krv2 (Krvavitev v drugem trimesečju),
- DolCerv (Dolžina materničnega vratu),
- FundTest (Fundus test),
- Funel (Lijak - lijakasta oblika prehoda telesa maternice v maternični vrat),
- Posteljica (Položaj posteljice),
- EMG1 (Meritev EMG1),
- EMG2 (Meritev EMG2),
- EMG1d (Meritev EMG1 - datum),
- EMG1u (Meritev EMG1 - ura),
- EMG2d (Meritev EMG2 - datum),
- EMG2u (Meritev EMG2 - ura),
- TT1 (Telesna teža ob prvi meritvi),
- TT2 (Telesna teža ob drugi meritvi),
- DKože11 (Debelina kože zgoraj okrog 22. tedna),
- DKože12 (Debelina kože spodaj okrog 22. tedna),
- DKože21 (Debelina kože zgoraj okrog 30. tedna),
- DKože22 (Debelina kože spodaj okrog 30. tedna),
- RazdPost22 (Razdalja do posteljice okrog 22. tedna),
- RazdPost30 (Razdalja do posteljice okrog 30. tedna),
- DebPost22 (Debelina posteljice okrog 22. tedna),
- DebPost30 (Debelina posteljice okrog 30. tedna),
- cervix2 (Druga meritev materničnega vratu).

Porod:

- PorodDat (Porod - datum),
- PorodUra (Ura poroda),
- Gestacija (Trajanje nosečnosti ob porodu v dnevih),
- NacPor (Način poroda),
- ZacPor (Začetek poroda),
- ZacPorVzrok (Začetek poroda - vzrok),
- TežaNov (Teža novorojenčka),
- StPor (Številka poroda),
- PorodPost (Porod posteljice),
- KolKrva (Količina krvavitve),
- Uteroto (Uterotoniki),
- UteroKaj (Kateri uterotoniki so bili uporabljeni po porodu),
- PoskRup1 (Poskus rupture 1),
- PoskRup2 (Poskus rupture 2),
- PoskRup3 (Poskus rupture 3),
- PoskVag (Poškodbe vagine),
- PoskEpi (Epiziotomija),
- RuptCerv (Ruptura materničnega vrata).

Na osnovi podatkov o datumu poroda, predvidenem datum poroda ter podatkov o časih meritev EMG (EMG1 in EMG2) smo nato izračunali trajanja nosečnosti ob snemanjih ter ob rojstvu. Glede na te čase smo posnetke nato razvrstili v več parov skupin. Ostale spremljajoče podatke smo uporabili za izločanje tistih posnetkov, pri katerih je bil izveden carski rez, ali pa je bil porod sprožen - torej tistih, pri katerih ni moglo priti do spontanega prezgodnjega poroda, ker so pred porodom posredovali zdravniki. Ostale zbrane podatke nameravamo uporabiti v nadaljnjih raziskavah.

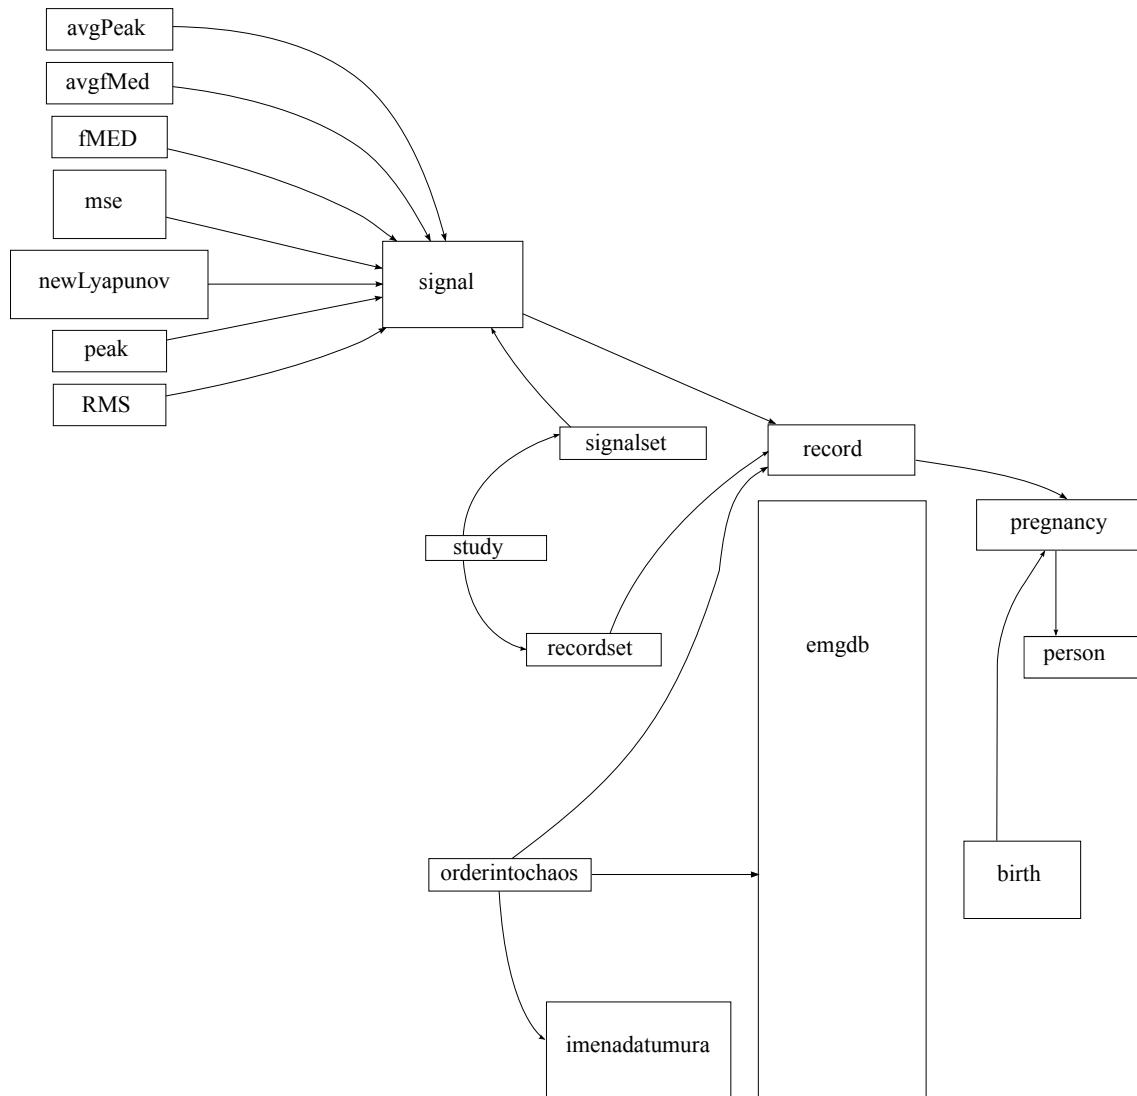
4.7 Organizacija podatkovne baze

Organizacija nove podatkovne baze je prikazana na diagramu 4.4. Podatki o nosečnicah so v novi bazi ločeni od podatkov o samih nosečnostih. Prav tako so podatki o nosečnostih ločeni od podatkov o posnetkih. Posnetki so ločeni od samih signalov.

Rezultati analize signalov so shranjeni v ločenih tabelah. Vsaka tabela vsebuje rezultate ene metode za izračun cenilk na osnovi določene tehnike. Tako so prvi prehod preko ničle koeficientov avtokorelacije, maksimalni eksponent Ljapunova ter korelacijska dimenzija shranjeni v skupni tabeli. Za vsako cenilko, kjer je to smiselno, je tudi zapisano, za kateri odsek signala je bila izračunana. V raziskavi, predstavljeni v tem delu, je bil to odsek od 180 s po začetku posnetka do 180 s pred koncem posnetka. Organizacija cenilk je prikazana na sliki 4.5.

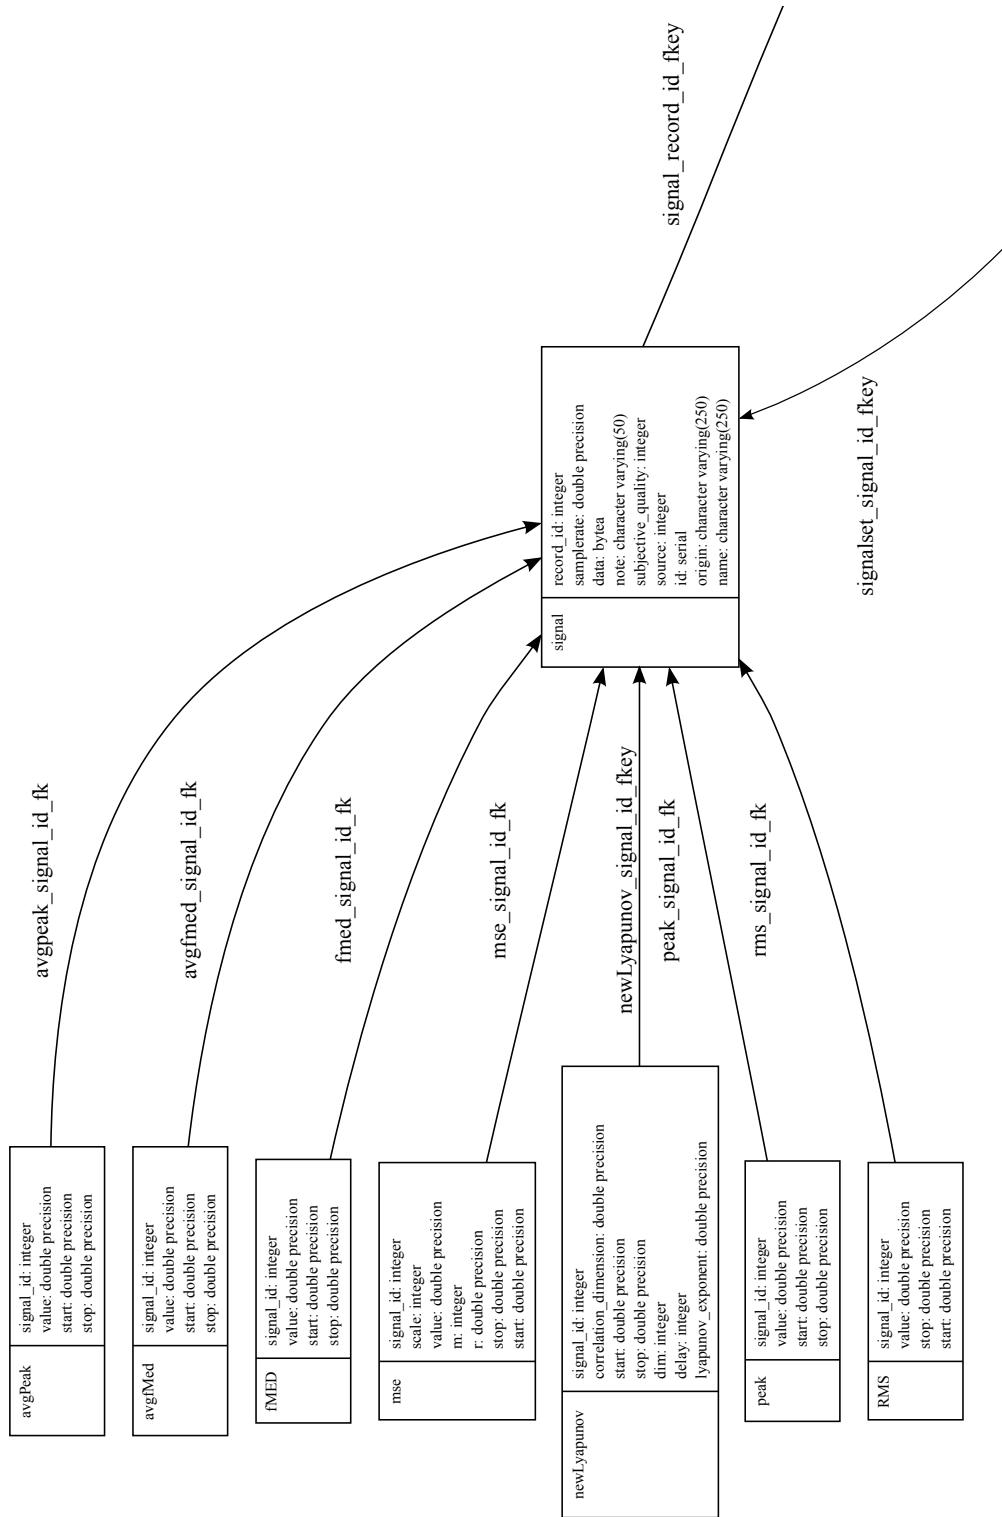
Spremljevalni podatki so sedaj urejeni v več tabel z naslednjimi polji:

- **person** (oseba)
 - id (ključ),
 - name (ime matere ali otroka),
 - surname (priimek matere ali otroka),
 - birthdate (datum rojstva matere),
- **pregnancy** (nosečnost)
 - mother (ključ matere v tabeli person),
 - expected_birthdate (predvideni datum poroda),
 - birthdate (datum dejanskega poroda),
 - birthtime (čas poroda),
- **birth** (porod)
 - pregnancy_id (ključ nosečnosti),
 - spontaneous (ali je bil porod spontan),
 - cesarean (ali je bil izveden carski rez),
 - stillborn (ali je bil otrok mrtvorojen),
 - weight (teža otroka ob rojstvu),

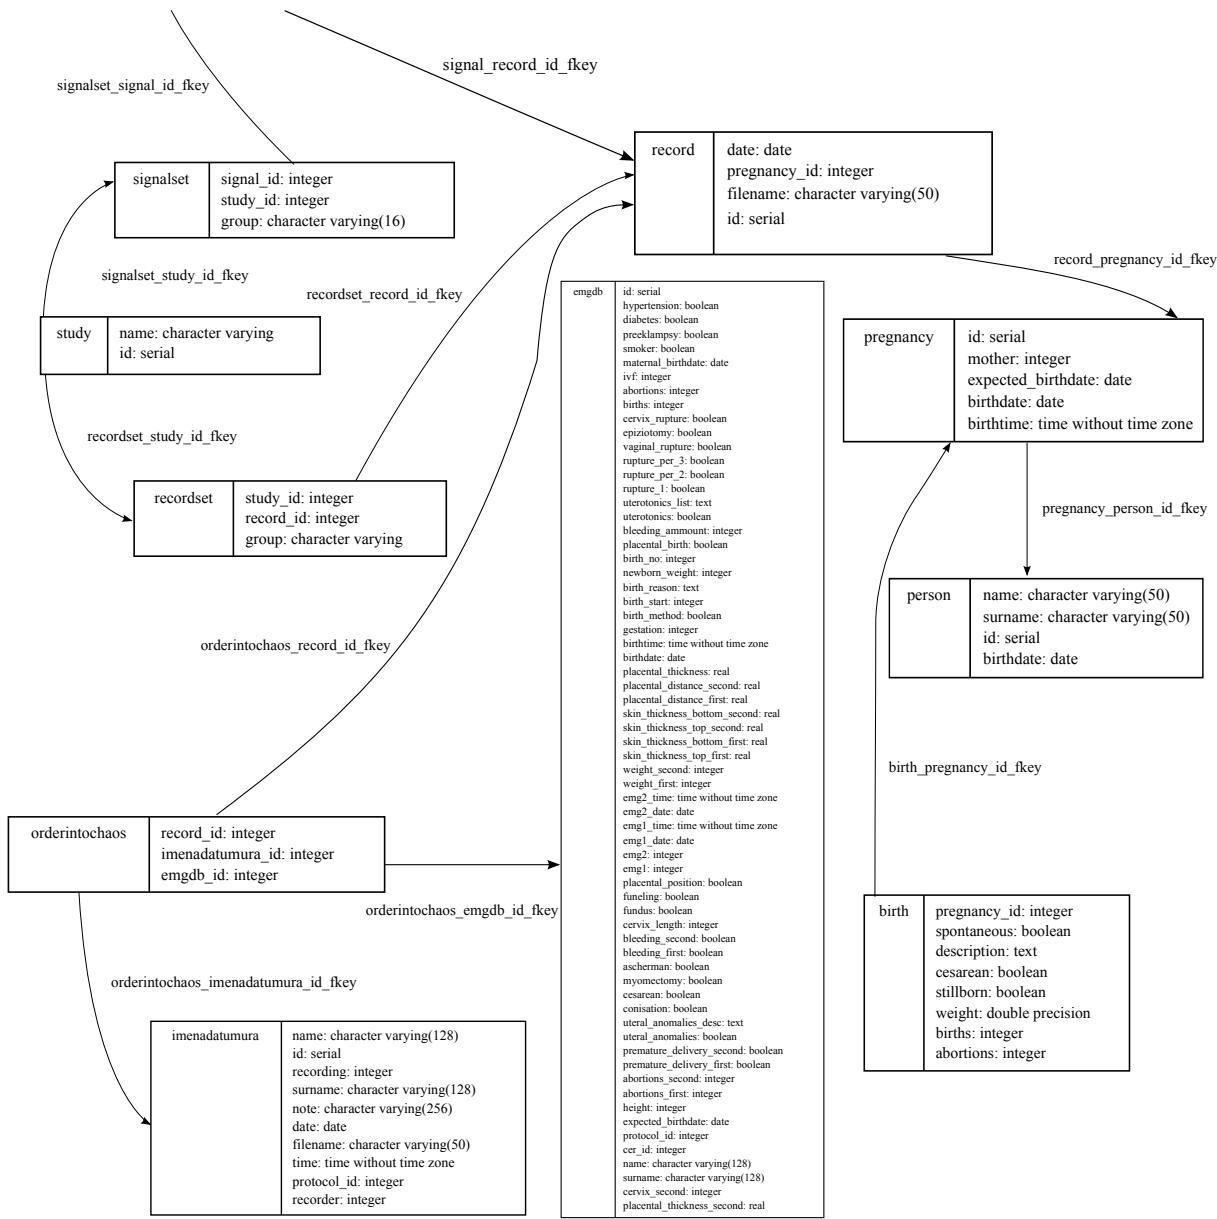


Slika 4.4: Organizacija podatkovne baze - pregled. Natančneje je baza predstavljena na slikah 4.5 in 4.6

- births (število predhodnih porodov),
- abortions (število predhodnih splavov),
- description (opis poroda).



Slika 4.5: Organizacija podatkovne baze - cenilke.



Slika 4.6: Organizacija podatkovne baze - spremljevalni podatki. Tabela s starimi podatki je predstavljena kot manjša, tabele z na novo urejenimi podatki so povečane.

Podatki o posnetkih so spravljeni v tabelah **record** in **signal**:

- **record** (posnetek)
 - id (ključ),
 - date (datum zajema posnetka),
 - pregnancy_id (ključ nosečnosti, med katero je bil zajet posnetek),
 - filename (ime datoteke, v kateri je bil originalni posnetek),
- **signal** (signal)
 - id (ključ),
 - record_id (ključ posnetka, ki mu dani signal pripada),
 - name (ime signala - npr. '1' za neobdelan signal 1. kanala, '1_DOCFILT-4-0.08-2.5' za signal 1. kanala, filtriran z Butterworthovim filtrom 4. stopnje z mejnima frekvencama 0.08 Hz in 2.5 Hz z dvosmerno shemo filtriranja),
 - subjective_quality (ocena kvalitete signala),
 - source (za filtrirane signale ključ signala, iz katerega je bil dani signal ustvarjen),
 - origin (za obdelane signale, kako je bil signal ustvarjen),
 - note (dodatni zaznamki, npr. 'popadki CTG HP-8030A zunanji senzor' v primerih, ko gre za zapis ocene tlaka v maternici),
 - samplerate (frekvenca vzorčenja),
 - data (dejanski signal, zapisan v formatu, ki ga uporablja pythonovski modul CPICKLE).

Pri opravljanju konkretnih raziskav uporabljamo podmnožice celotne baze posnetkov. Testnih posnetkov, ki se sicer tudi nahajajo v podatkovni bazi, na primer, še nismo nikdar uporabili. Za vsako novo raziskavo ustvarimo vnos v tabeli **study**, nakar glede na naravo raziskave dodamo primerne vnose v tabelo **recordset** ali **signalset**, glede na to, ali raziskavo izvajamo nad posnetki ali nad posameznimi signali:

- **study** (raziskava)
 - id (ključ, zaporedna številka raziskave),
 - name (naziv raziskave),

- **recordset** (nabor posnetkov)
 - study_id (ključ oziroma zaporedna številka raziskave),
 - record_id (ključ posnetka),
- **signalset** (nabor signalov)
 - study_id (ključ oziroma zaporedna številka raziskave),
 - record_id (ključ signala).

Poleg urejenih podatkov so v bazi še vedno shranjeni podatki, ki so bili prej shranjeni v tabelah EXCEL in na papirju. Ti podatki se nahajajo v tabelah **emgdb** in **imenadatumsra**. Z ostalimi podatki so povezani preko tabele **orderintochaos**. Na ta način lahko po potrebi še vedno dostopamo do podatkov, ki so bili v preteklosti zbrani, a jih še nismo preuredili. Organizacija spremljajočih podatkov je prikazana na sliki 4.6

POGLAVJE 5

Predobdelava posnetkov

Signali, zajeti s površine trebuha, so zelo šumnati. Čeprav je že dolgo znano, da krče maternice spremljajo salve električne aktivnosti [35], je ta električna aktivnost na žalost vedno prekrita tudi z električno aktivnostjo srca in progastih mišic. Da bi lahko analizirali električno aktivnost maternice, je potrebno signale najprej filtrirati. V glavnem je izbira omejena na dve možnosti - filtre z neskončnim odzivom na enotin impulz (Infinite Impulse Response, IIR) in na filtre s končnim odzivom na enotin impulz (Finite Impulse Response, FIR). Prednost filtrov z neskončnim odzivom na enotin impulz je predvsem njihova nižja računska zahtevnost pri isti kvaliteti. Za enako slabljenje v zapornem pasu ima namreč filter z neskončnim odzivom na enotin impulz lahko bistveno manjšo dolžino. Njihova glavna slabost je ta, da je z njimi nemogoče doseči linearen fazni zamik. Z uporabo Besselovih filtrov bi se sicer lahko približali linearemu faznemu zamiku, vendar le za ceno slabšega amplitudnega odziva. Vseeno je težave s faznim zamikom mogoče zaobiti, če filtriranja ne izvajamo v realnem času. Fazni zamik namreč lahko izničimo tako, da signal filtriramo v eni smeri, ga obrnemo, filtriramo v drugi smeri ter nato obrnemo nazaj.

5.1 Butterworthovi filtri

Butterworthovi filtri so skonstruirani tako, da je njihova prenosna karakteristika monotona tako v prepustnem, kot tudi v zapornem pasu. Enačba, ki opisuje prenosno funkcijo Butterworthovega filtra, je:

$$H^2(s) = \frac{1}{1 + \left(\frac{\omega}{\omega_n}\right)^{2n}} . \quad (5.1)$$

Prenosno funkcijo Butterworthovega filtra lahko zapišemo kot ulomek:

$$H(s) = \frac{B(s)}{A(s)} = \frac{b(1)s^n + b(2)s^{n-1} + \dots + b(n+1)}{s^n + a(2)s^{n-1} + \dots + a(n+1)}. \quad (5.2)$$

Ker imamo v digitalnih sistemih opravka z diskretnimi signali, uporabimo:

$$H(z) = \frac{B(z)}{A(z)} = \frac{b(1) + b(2)z^{-1} + \dots + b(n+1)z^{-n}}{1 + a(2)z^{-1} + \dots + a(n+1)z^{-n}}. \quad (5.3)$$

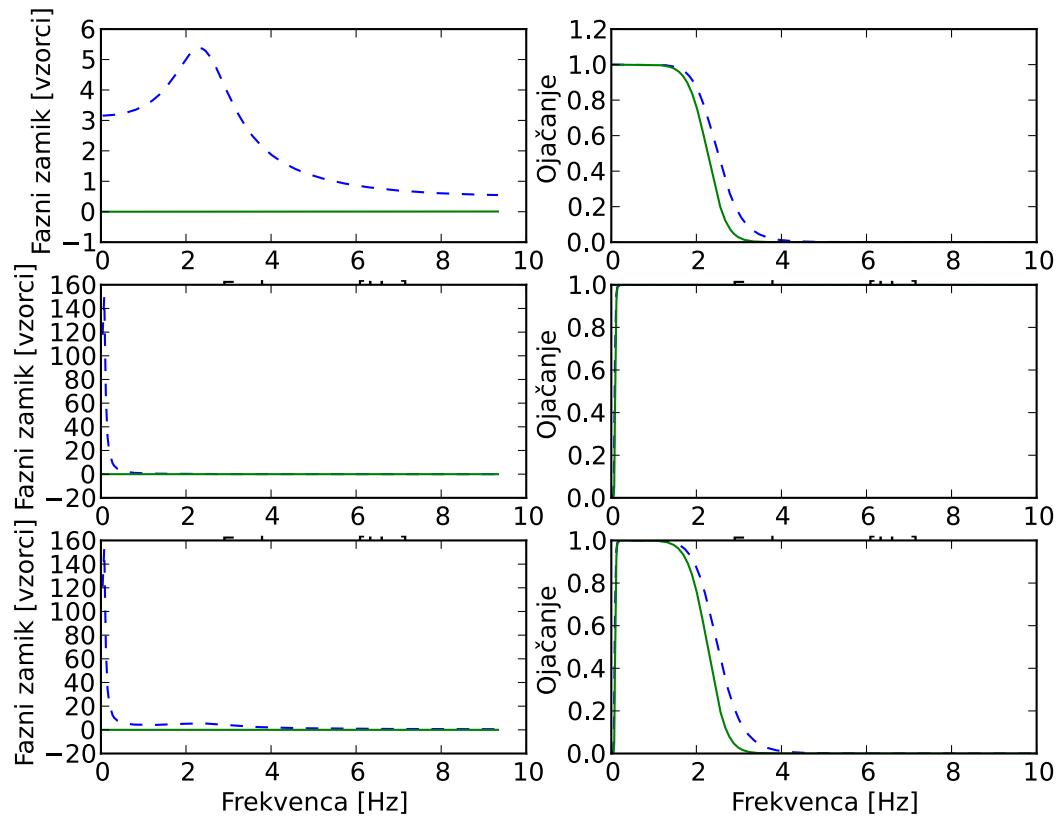
Na žalost je fazni zamik Butterworthovih filtrov nelinearen, kar povzroči popačenje signala; še posebej velik je zamik signalov s frekvenco blizu meje prepustnega pasu.

5.2 Dvosmerna shema filtriranja

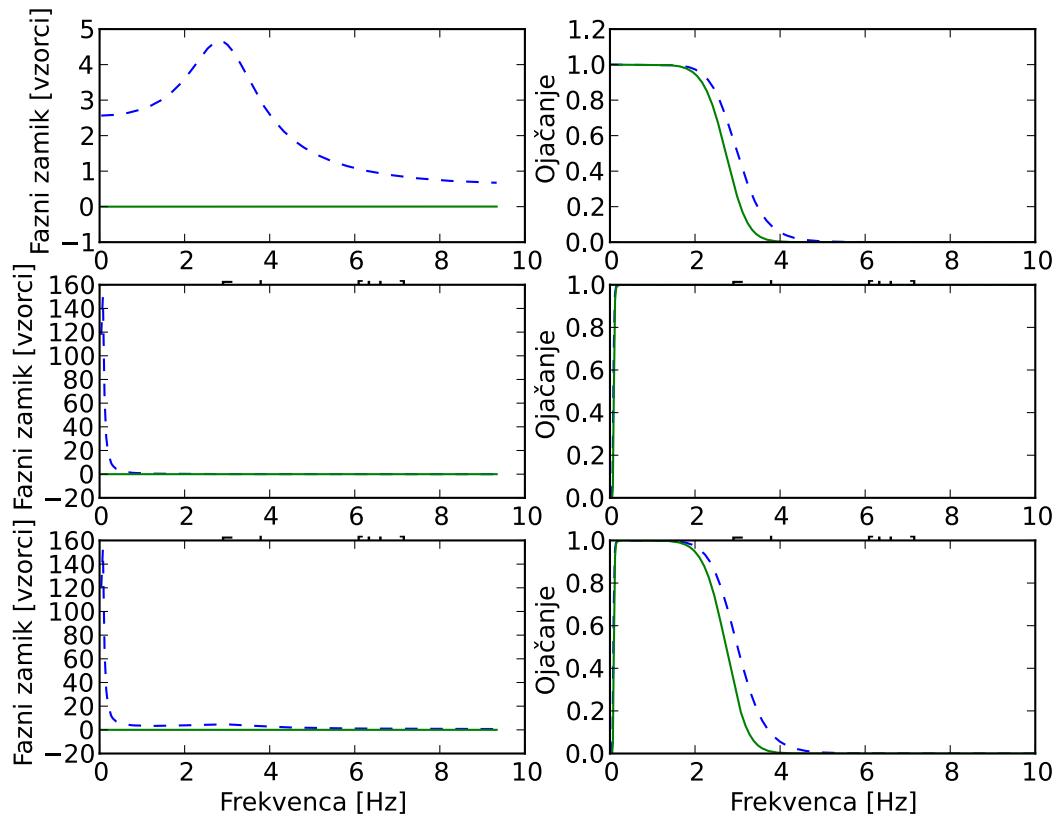
Na srečo se faznemu popačenju pri uporabi filtrov z neskončnim odzivom na enotin impulz pri obdelavi vnaprej zajetih posnetkov lahko brez večjih težav izognemo. Potem, ko smo signal $x(t)$ dolžine N vzorcev filtrirali in dobili filtrirani signal $x_f(t)$, ga obrnemo tako, da dobimo $x_{rf}(t) = x_f(N-t)$, nakar ga še enkrat filtriramo, da dobimo končni signal $y_r(t)$. Dobljeni signal nato obrnemo še enkrat, da dobimo končni filtrirani signal $y(t) = y_r(N-t)$ originalnega signala. Na ta način se fazni zamiki izničijo, tako da je dobljeno popačenje originalnega signala bistveno manjše.

Za implementacijo Butterworthovih filtrov in dvosmerne sheme filtriranja smo uporabili funkcije, dostopne v knjižnicah SCIPY in NUMPY za programski jezik PYTHON. Izbrali smo Butterworthove filtre četrtega reda. Signale smo dvosmerno filtrirali najprej z nizko-prepustnim, nato pa še z visoko-prepustnim filtrom. Prenosne karakteristike so predstavljene na slikah 5.1, 5.2, 5.3, 5.4, 5.5 in 5.6. Na slikah je lepo vidno, da je fazni zamik dobljenega filtra enak nič. Prenosna karakteristika filtrov pri uporabi dvosmerne sheme filtriranja je takšna, kot če bi uporabili filter dvakrat višjega reda, kot je osnovni - v našem primeru torej 8. Izboljšanje prenosne karakteristike se kaže v strmejšem prehodu med prepustnim in zapornim območjem filtra.

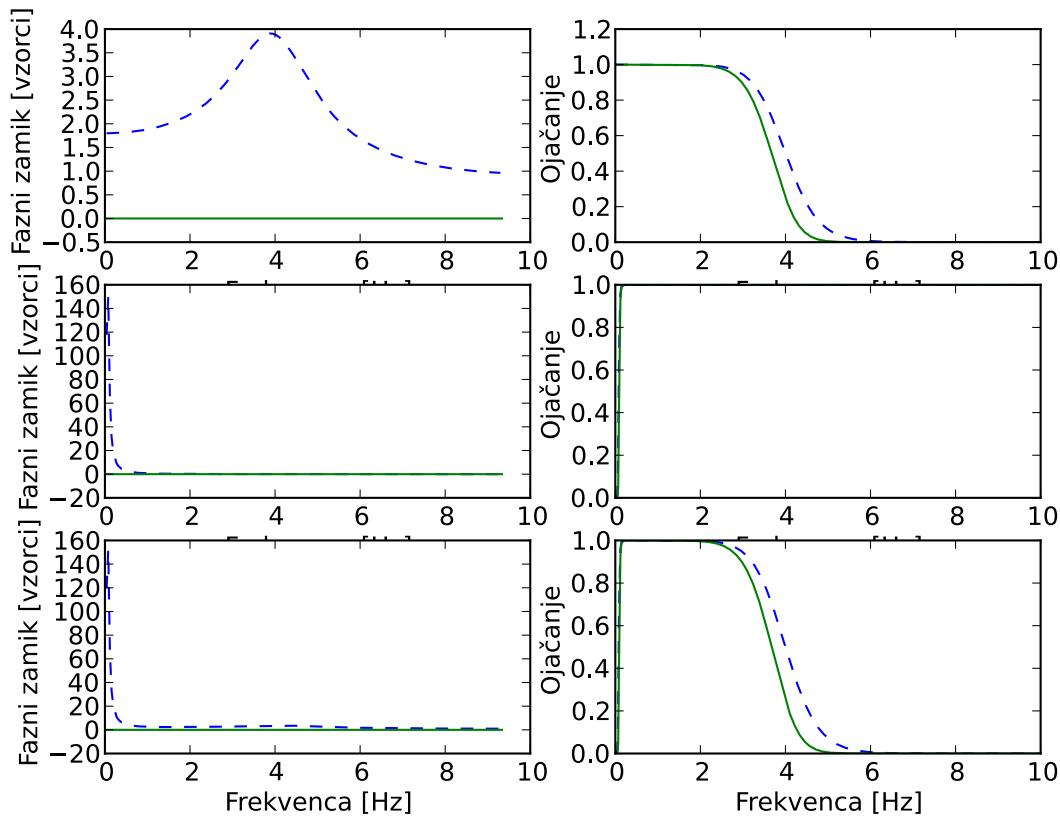
V literaturi nismo nikjer zasledili, da bi katera od ostalih raziskovalnih skupin uporabljala filtre z neskončnim odzivom na enotin impulz z dvosmerno shemo filtriranja. Filtri z neskončnim odzivom na enotin impulz imajo pri enaki dolžini boljši odziv od filtrov končnim odzivom na enotin impulz. Zaradi krajše dolžine so filtri s končnim odzivom na enotin impulz računsko manj zahtevni. Z uporabo dvosmerne sheme filtriranja smo se izognili faznemu popačenju, pri čemer smo vseeno lahko izkoristili prednosti filtrov z neskončnim odzivom na enotin impulz.



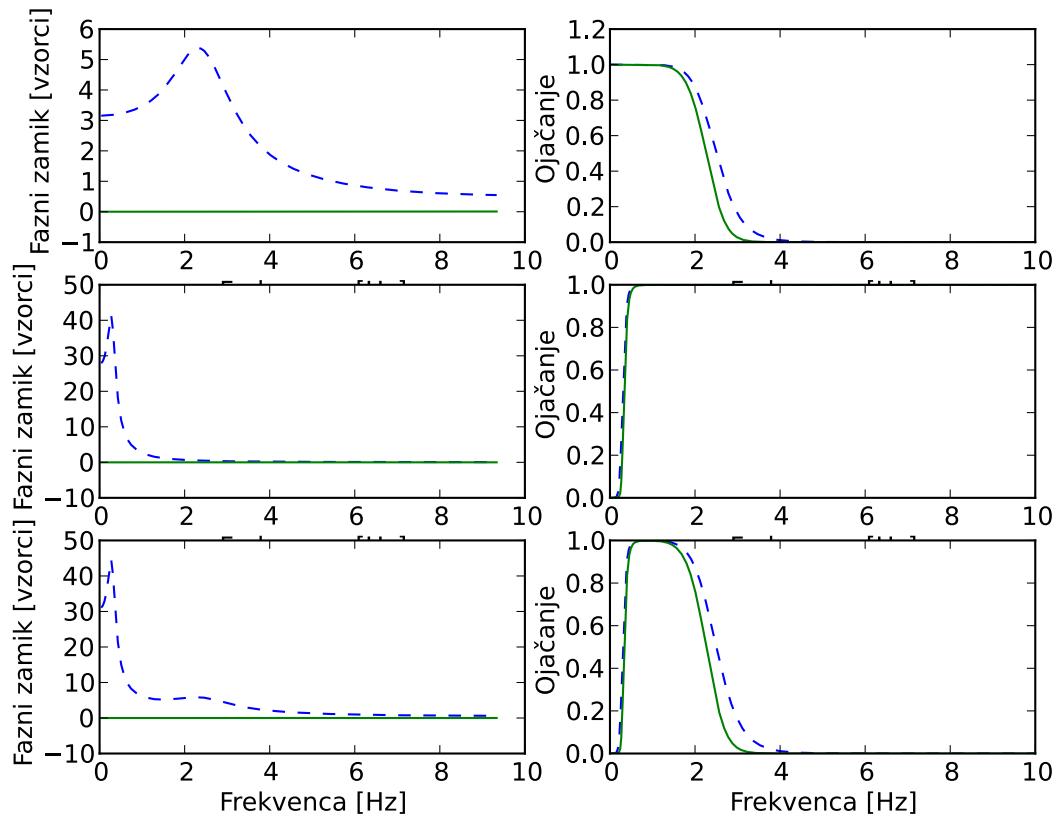
Slika 5.1: Frekvenčni (levo) in fazni (desno) odziv na enotin impulz filtra $0.08 \text{ Hz} - 2.5 \text{ Hz}$ z in brez dvosmerne sheme filtriranja. Črtkana črta predstavlja odziv filtra brez dvosmerne sheme filtriranja, polna z dvosmerno shemo filtriranja. Na sliki so odzivi nizko-prepustnega filtra (zgoraj), visoko-prepustnega filtra (v sredini) in nizko-prepustnega filtra (spodaj)



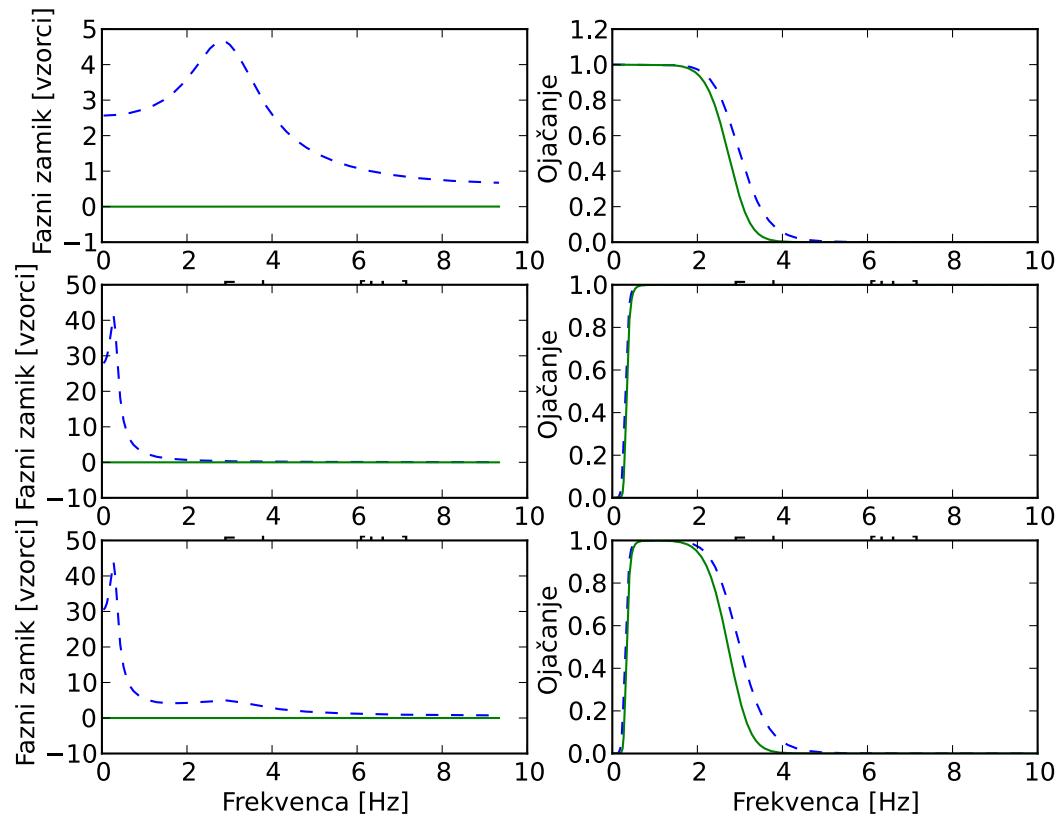
Slika 5.2: Frekvenčni (levo) in fazni (desno) odziv na enotin impulz filtra $0.08 \text{ Hz} - 3 \text{ Hz}$ z in brez dvosmerne sheme filtriranja. Črtkana črta predstavlja odziv filtra brez dvosmerne sheme filtriranja, polna z dvosmerno shemo filtriranja. Na sliki so odzvi nizko-prepustnega filtra (zgoraj), visoko-prepustnega filtra (v sredini) in nizko-prepustnega filtra (spodaj)



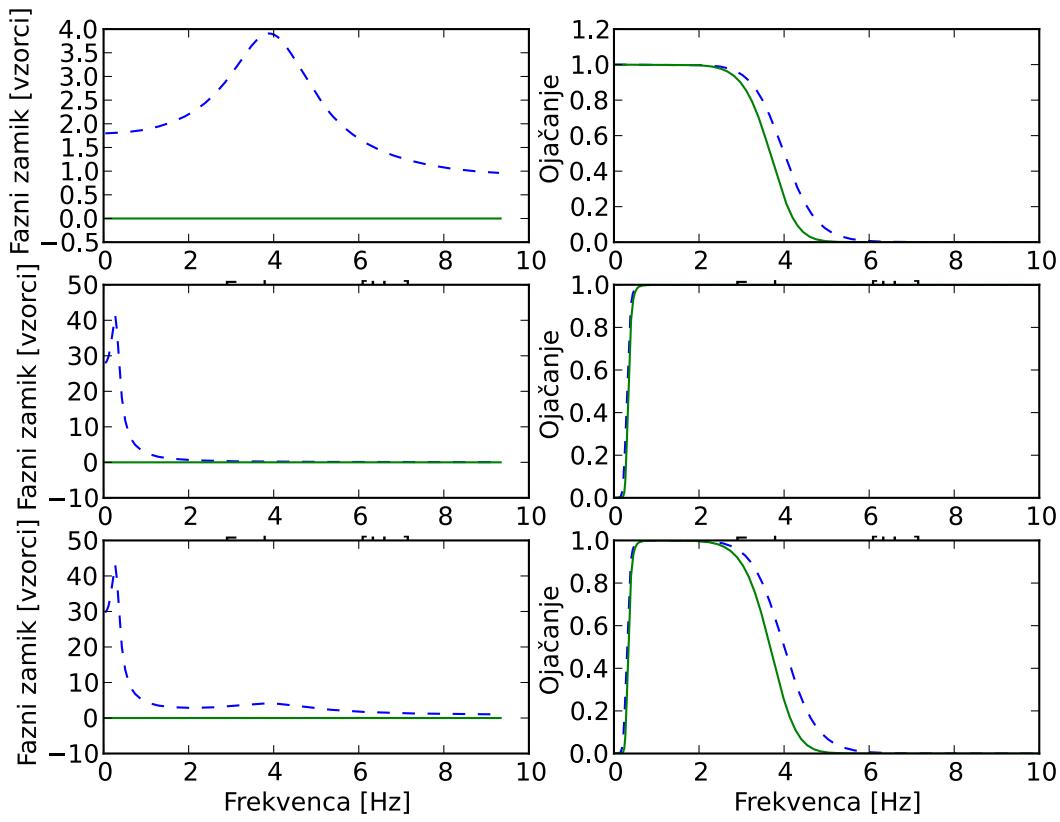
Slika 5.3: Frekvenčni (levo) in fazni (desno) odziv na enotin impulz filtra $0.08 \text{ Hz} - 4 \text{ Hz}$ z in brez dvosmerne sheme filtriranja. Črtkana črta predstavlja odziv filtra brez dvosmerne sheme filtriranja, polna z dvosmerno shemo filtriranja. Na sliki so odzivi nizko-prepustnega filtra (zgoraj), visoko-prepustnega filtra (v sredini) in nizko-prepustnega filtra (spodaj)



Slika 5.4: Frekvenčni (levo) in fazni (desno) odziv na enotin impulz filtra $0.3 \text{ Hz} - 2.5 \text{ Hz}$ z in brez dvosmerne sheme filtriranja. Črtkana črta predstavlja odziv filtra brez dvosmerne sheme filtriranja, polna z dvosmerno shemo filtriranja. Na sliki so odzivi nizko-prepustnega filtra (zgoraj), visoko-prepustnega filtra (v sredini) in nizko-prepustnega filtra (spodaj)



Slika 5.5: Frekvenčni (levo) in fazni (desno) odziv na enotin impulz filtra $0.3 \text{ Hz} - 3 \text{ Hz}$ z in brez dvosmerne sheme filtriranja. Črtkana črta predstavlja odziv filtra brez dvosmerne sheme filtriranja, polna z dvosmerno shemo filtriranjem. Na sliki so odzivi nizko-prepustnega filtra (zgoraj), visoko-prepustnega filtra (v sredini) in nizko-prepustnega filtra (spodaj)



Slika 5.6: Frekvenčni (levo) in fazni (desno) odziv na enotin impulz filtra $0.3 \text{ Hz} - 4 \text{ Hz}$ z in brez dvosmerne sheme filtriranja. Črtkana črta predstavlja odziv filtra brez dvosmerne sheme filtriranja, polna z dvosmerno shemo filtriranja. Na sliki so odzivi nizko-prepustnega filtra (zgoraj), visoko-prepustnega filtra (v sredini) in nizko-prepustnega filtra (spodaj)

5.3 Izbor mejnih frekvenc filtriranja signalov

Največjo težavo pri zajemu in obdelavi EMG maternic predstavlja dejstvo, da električne signale maternice prekrivajo šumi preostalih delov telesa in okolja. Pri višjih frekvencah je tako pomemben šum zaradi aktivnosti skeletnih mišic in srca, pri nižjih pa električno aktivnost maternice prekrivata dihanje in raztezanje kože [36].

Ker aparatura, s katero smo zajemali posnetke, vsebuje analogni nizko-prepustni filter z mejno frekvenco 5 Hz, smo bili pri obdelavi signalov navzgor omejeni na to frekvenco. Sodeč po dosedanjih raziskavah [36] se velika večina električne aktivnosti maternice nahaja pod frekvenco 4 Hz. Zaradi primerljivosti z dosedanjimi raziskavami [11, 12] smo kot možno mejo izbrali še 3 Hz. Vsaj ena izmed vodilnih skupin na področju analize EMG maternice pri delu uporablja aparaturo, ki ima vgrajen nizko-prepustni filter z mejno frekvenco 2.5 Hz. Zaradi primerljivosti z rezultati drugih raziskovalcev, smo se odločili, da kot možno zgornjo mejo frekvenčnega območja preizkusimo tudi to vrednost.

Ker so bili posnetki dolgi 30 minut, smo bili navzdol omejeni na $1.0/(30 \cdot 60\text{s}) = 0.00056$ Hz. Ker je normalna frekvenca dihanja nekje okrog $12/60\text{s} = 0.2$ Hz, bi bilo smiselno izločiti električno aktivnost pod to frekvenco. Kot možno spodnjo mejo frekvenčnega območja smo zato izbrali vrednost 0.3 Hz. Vseeno smo se odločili, da zaradi primerljivosti z že obstoječimi raziskavami [11, 12] preizkusimo tudi spodnjo mejno frekvenco 0.08 Hz. Za zgornjo mejo frekvenčnega področja smo izbrali tri možne frekvence: 4 Hz za primerjavo z dosedanjimi raziskavami [11, 12], 3 Hz kot malce nižjo mejno frekvenco in 2.5 Hz kot frekvenco, ki jo uporabljajo nekateri drugi raziskovalci.

Izbrani filtri so torej naslednji:

1. 0.08 - 2.5 Hz - filter z zgornjo mejo, kakršno uporabljajo nekateri drugi raziskovalci, vendar zajame tudi nizke frekvence.
2. 0.08 - 3 Hz - ožji filter od tega, ki ga je naša raziskovalna ekipa uporabljala v dosedanjih raziskavah.
3. 0.08 - 4 Hz - uporabljen v dosedanjih raziskavah naše raziskovalne skupine.
4. 0.3 - 2.5 Hz - filter z zgornjo mejo, kakršno uporabljajo nekateri drugi raziskovalci, kjer so odrezane motnje pri nizkih frekvencah.
5. 0.3 - 3 Hz - zožen filter, kjer so odrezane motnje pri nizkih frekvencah.

6. 0.3 - 4 Hz - odstranjene motnje pri nizkih frekvencah, zgornja meja kot pri dosedanjih [11, 12] raziskavah.

Koeficienti uporabljenih filtrov so predstavljeni v tabeli 5.1.

Pri vseh obdelavah signalov smo uporabljali 64-bitno predstavitev števil v plavajoči vejici, z enim bitom za predznak, 11 biti za eksponent in 52 biti za mantiso. Pri računanju s premajhno natančnostjo bi lahko naleteli na nestabilnost filtrov [37], ki pa je nismo opazili. Da smo se izognili motnjam zaradi prehodnih pojavov, ki nastanejo ob filtriranju, smo za izračun cenilk uporabili 27 minut vsakega posnetka, z začetkom ob 180 s po začetku in koncem 180 s pred koncem originalnega posnetka.

Tabela 5.1: Koeficienti uporabljenih filtrov

Mejna frekv.[Hz]	$H(z) = \frac{B(z)}{A(z)}$	b(1) a(1)	b(2) a(2)	b(3) a(3)	b(4) a(4)	b(5) a(5)
0.08	B	0.96769481	-3.87077924	5.80616885	-3.87077924	0.96769481
	A	1.0	-3.93432582	5.80512542	-3.80723246	0.93643324
0.3	B	0.88409204	-3.53636817	5.30455226	-3.53636817	0.88409204
	A	1.0	-3.75376276	5.29115258	-3.3189386	0.78161874
2.5	B	0.01020948	0.04083792	0.06125688	0.04083792	0.01020948
	A	1.0	-1.96842779	1.73586071	-0.72447083	0.1203896
3.0	B	0.01856301	0.07425204	0.11137806	0.07425204	0.01856301
	A	1.0	-1.57039885	1.27561332	-0.48440337	0.07619706
4.0	B	0.04658291	0.18633163	0.27949744	0.18633163	0.04658291
	A	1.0	-0.7820952	0.67997853	-0.1826757	0.03011888

POGLAVJE 6

Karakterizacija posnetkov

Človeški možgani so sposobni hitrega odkrivanja in prepoznavanja vzorcev v skoraj poljubnih slikah. V medicini različne posnetke - od rentgenskih do EKG - še vedno pregledujejo specialisti. Upamo lahko, da bomo s pomočjo različnih metod grafične predstavitev signalov EMG maternice ljudem predstavili takšno sliko, na kateri bodo vidni prepoznavni vzorci, na osnovi katerih bi lahko identificirali posnetke, pri katerih je tveganje za nastop prezgodnjega poroda višje. V primeru, da bi takšne vzorce odkrili, bi lahko pridobljeno ekspertno znanje uporabili tudi za kasnejšo izdelavo klasifikatorjev.

6.1 Kratko-intervalni križno-korelacijski koeficienti

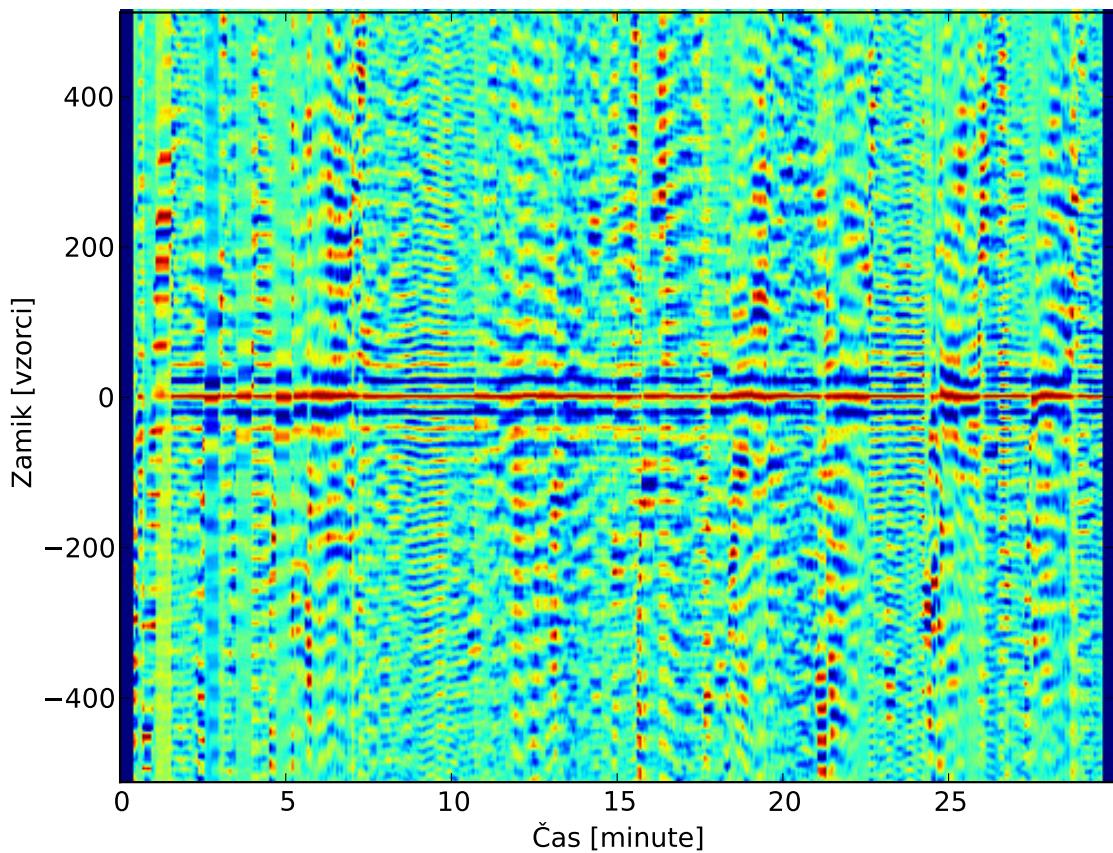
S pomočjo kratko-intervalnih križno-korelacijskih koeficientov lahko ocenimo, kako se skozi čas spreminja podobnost med signali. Križno-korelacijski koeficienti so tako nadvse uporabni pri analizi zvočnih signalov v morju, kjer lahko, če zvok zajemamo na več točkah v prostoru, na njihovem grafičnem prikazu opazimo izvore zvoka in ocenimo njihovo lokacijo ter smer premikanja. Pri danem paru neskončnih signalov $x(t)$ in $y(t)$ so koeficienti križne korelacije definirani kot:

$$R_{xy}(\tau) = \sum_{i=-\infty}^{\infty} x(i) y(\tau + i) . \quad (6.1)$$

Če oba signala pomnožimo z zamknjenim pravokotnim oknom $w(t)$ dolžine N_w vzorcev, dobimo kratko-intervalne korelacijske koeficiente:

$$R_{xy}(t, \tau) = \sum_{i=-\infty}^{\infty} x(i)w(i) y(i + \tau)w(i + \tau) . \quad (6.2)$$

Da bi ocenili, kako se kratko-intervalni križno-korelacijski koeficienti spreminjajo skozi čas, jih lahko predstavimo v sliki. Pri tem za ordinato uporabimo zaporedno številko korelacijskega koeficienta, medtem ko za absciso uporabimo čas. Vrednosti koeficientov predstavimo z barvami. Pri dolžini odseka N_w vzorcev tako dobimo sliko z višino $2N_w$ in dolžino, enako dolžini celotnega posnetka. Primer kratko-intervalnih križno-korelacijskih koeficientov med kanaloma 1 in 2 posnetka EMG maternice je prikazan na sliki 6.1.



Slika 6.1: Primer kratko-intervalnih križnih koeficientov dveh kanalov (signalov) istega posnetka EMG maternice

6.2 Karakterizacija spektrov na osnovi spektrograma

Spektrogram je grafična predstavitev signala. Na spektrogramu lahko hitro vidimo, kako se močnostni spekter signala spreminja v odvisnosti od časa. Spektrogram je osnovan na izračunu kratko-intervalnega močnostnega spektra s pomočjo diskretnje Fourierjeve transformacije:

$$STFT(x(t)) \equiv X(t, \omega) = \sum_{i=-\infty}^{\infty} x(t)w(t-i)e^{-j\omega t} . \quad (6.3)$$

Kot pri kratko-intervalnih korelacijskih koeficientih smo tudi tu uporabili pravokotno okno.

Da bi ocenili, kako se močnostni spekter spreminja skozi čas, vrednosti močnostnega spektra v odvisnosti od frekvence in časa predstavimo na sliki. Za ordinato uporabimo frekvenco, za absciso pa ponovno uporabimo čas.

$$SP(t, \omega) = |STFT(t, \omega)|^2 . \quad (6.4)$$

Zaradi velikega razpona vrednosti bi bilo pregledovanje takšnih spektrogramov težavno. Vrednosti v spektrogramu smo zato najprej logaritmirali, nato pa jih predstavili z barvami. Na dobljenem spektrogramu se vrhovi frekvenčnega spektra med salvami električne aktivnosti odražajo kot grebeni, torej zaporedja vrhov, katerih frekvenca se skozi čas le rahlo spreminja. Opazujemo lahko, kako se močnostni spekter spreminja med salvami in v času mirovanja maternice. Primer spektrograma signala EMG maternice je prikazan na sliki 6.2

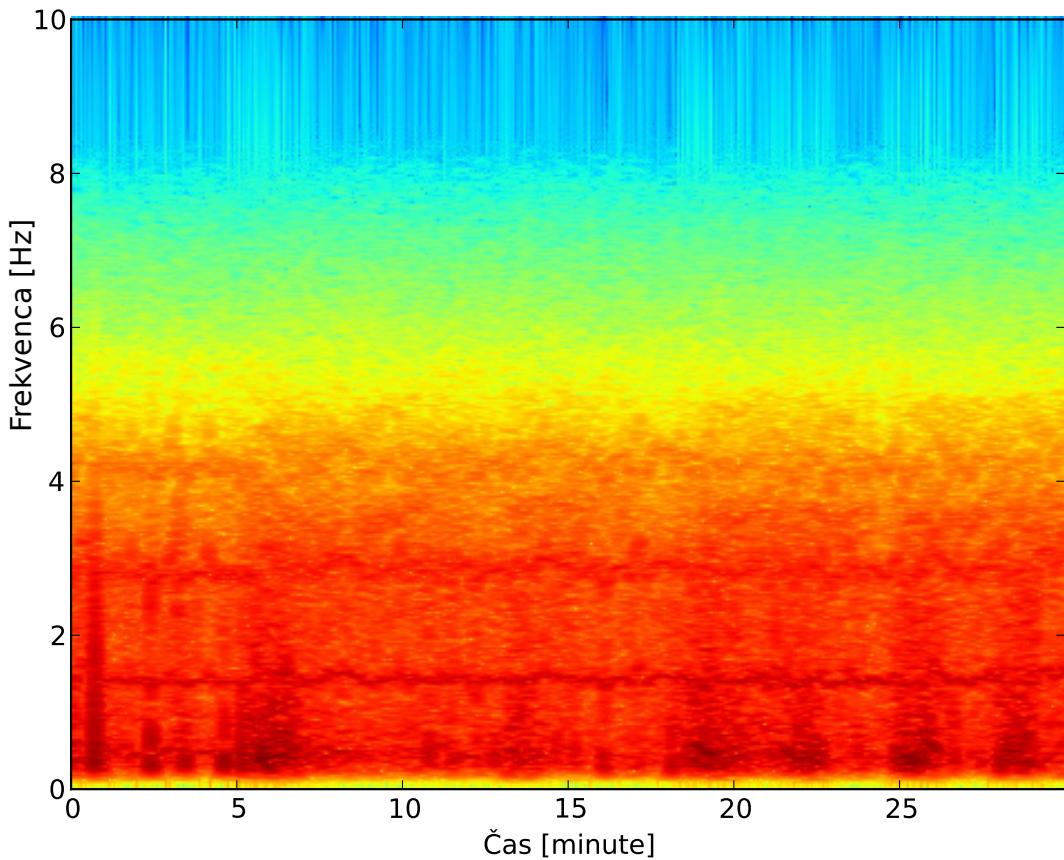
6.3 Časovno-frekvenčna predstavitev Wignerja in Villeja

Slabost spektrograma je, da se zaradi omejene dolžine okna grebeni razmažejo. Frekvenčna ločljivost je torej omejena. Če hočemo opazovati spremembe močnostnega spektra pri signalih, sestavljenih iz večih komponent, ki so si po frekvencah zelo blizu, zato naletimo na težave.

Skoraj poljubno frekvenčno ločljivost lahko dosežemo, če za izračun ocene močnostnega spektra uporabimo celoten signal, namesto da bi močnostni spekter računali le na kratkih odsekih. Ravno to dosežemo z uporabo časovno-frekvenčne predstavitve Wignerja in Villeja.

$$WD(t, \omega) = 2 \sum_{i=-\infty}^{\infty} w_N^2(i)x(t+i)x^*(t-i)e^{-j4\pi\omega i} , \quad (6.5)$$

kjer je w_N pravokotno okno z dolžino, enako dolžini signala. Časovno-frekvenčna predstavitev Wignerja in Villeja ima tudi nekaj slabosti:

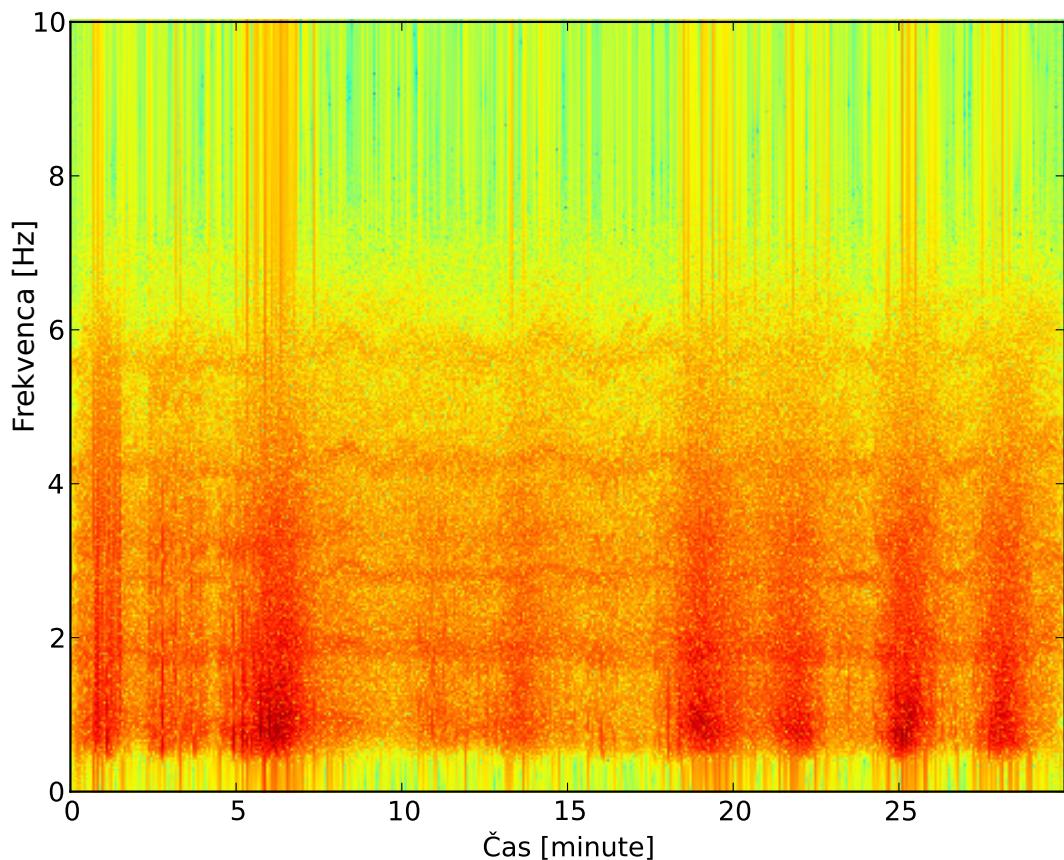


Slika 6.2: Primer spektrograma signala EMG maternice

- Izračunamo jo lahko le za celoten signal. Ni torej primerna v primeru, ko je potrebna obdelava signala v realnem času.
- Poleg signalov se posebej na mestih, kjer pride do spremembe močnostnega spektra, pojavijo artefakti.
- Izračunane vrednosti so lahko ponekod negativne.

Ker smo signale zajemali v celoti pred obdelavo, nas omejitev, da je za izračun časovno-frekvenčne predstavitev Wignerja in Villeja potreben celoten signal, ni motila. Ker smo naračunane slike nameravali pregledovati ročno, nas tudi artefakti niso posebej motili.

Kot pri spektrogramu, smo tudi pri vizualizaciji časovno-frekvenčne predstavitve Wignerja in Villeja dobljene rezultate pred prikazom logaritmirali. Ker lahko točke v časovno-frekvenčni predstavitevi Wignerja in Villeja zavzamejo tudi negativne vrednosti, smo pred logaritmiranjem izračunali njihove absolutne vrednosti. Prikaz časovno-frekvenčne predstavitevi Wignerja in Villeja z logaritmično barvno paletvo se je izkazal za preglednega. Salve aktivnosti so na ta način lepo vidne, podobne tistim, ki jih lahko vidimo na spektrogramu. Na prikazih časovno-frekvenčne predstavitevi Wignerja in Villeja so prisotni artefakti, videti pa je, da je ločljivost v frekvenčnem prostoru bistveno višja kot pri spektrogramu. Primer časovno-frekvenčne predstavitevi Wignerja in Villeja je na sliki 6.3

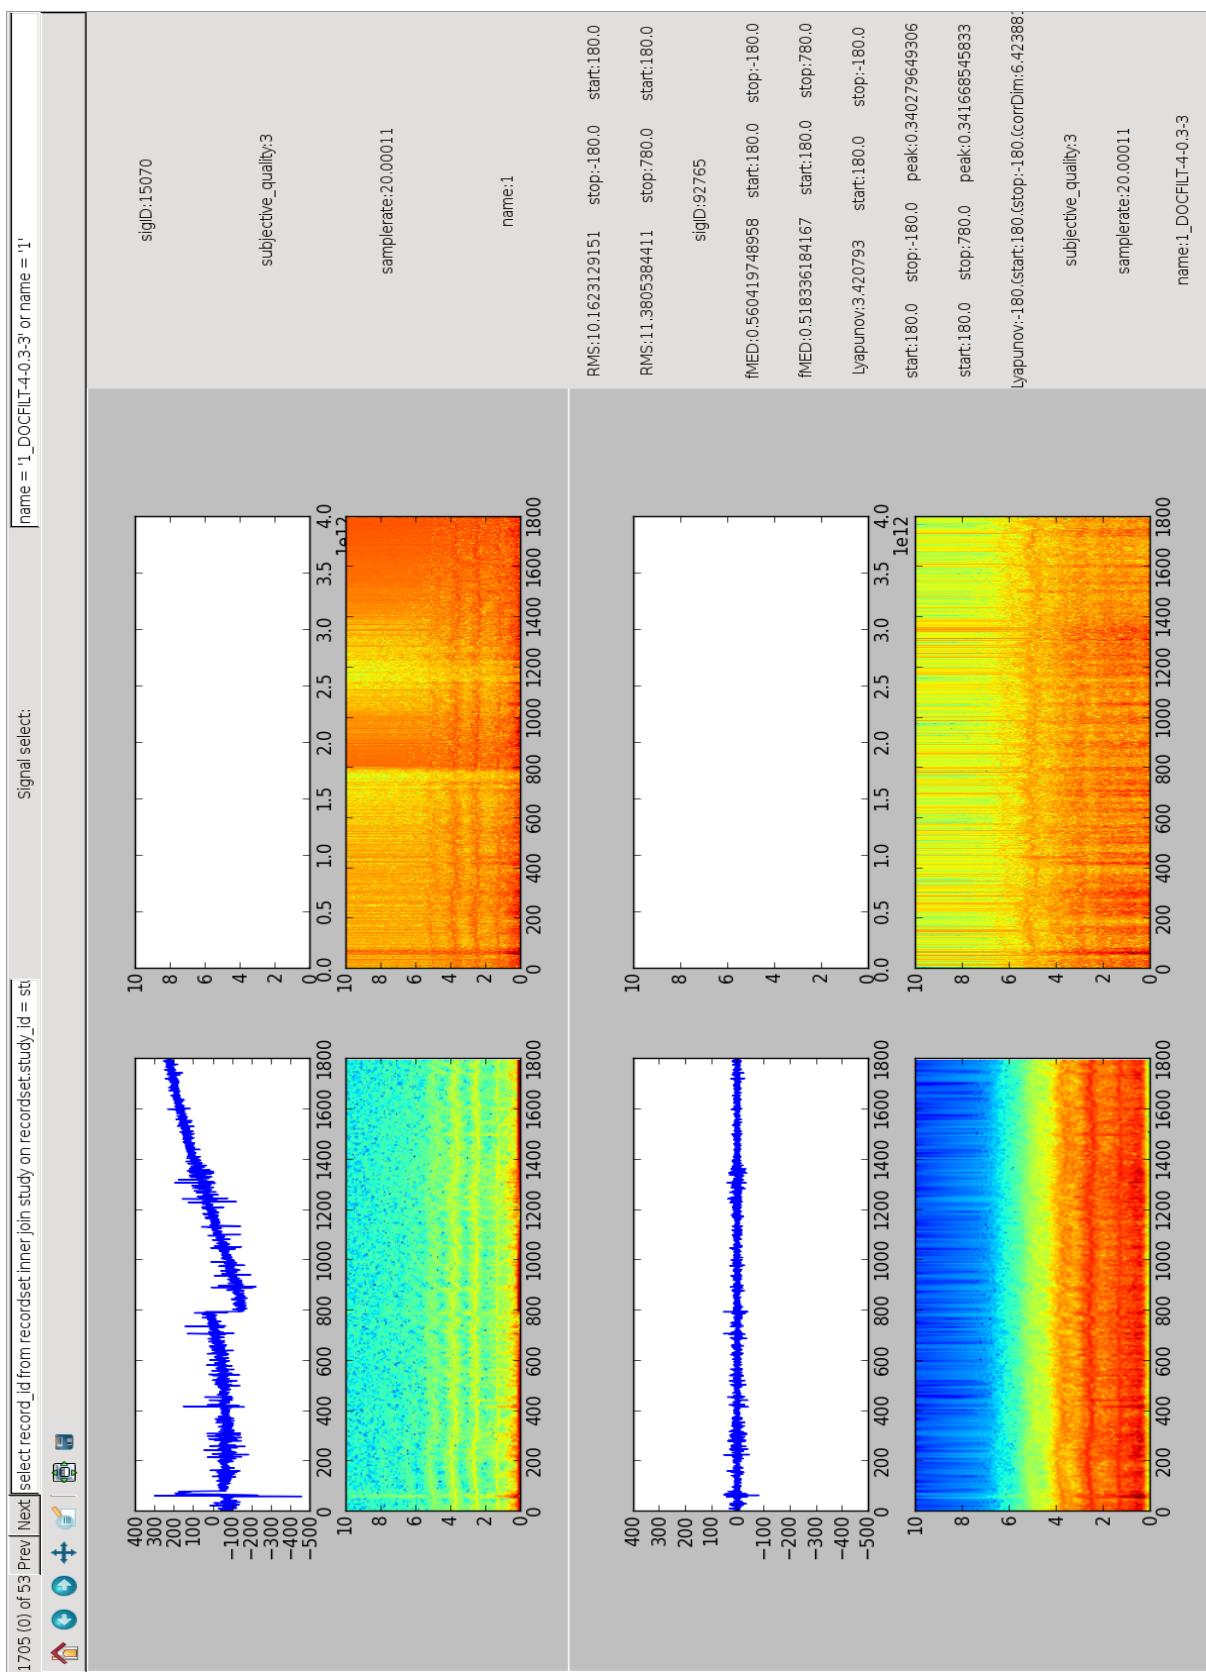


Slika 6.3: Primer časovno-frekvenčne predstavitevi Wignerja in Villeja signala EMG maternice

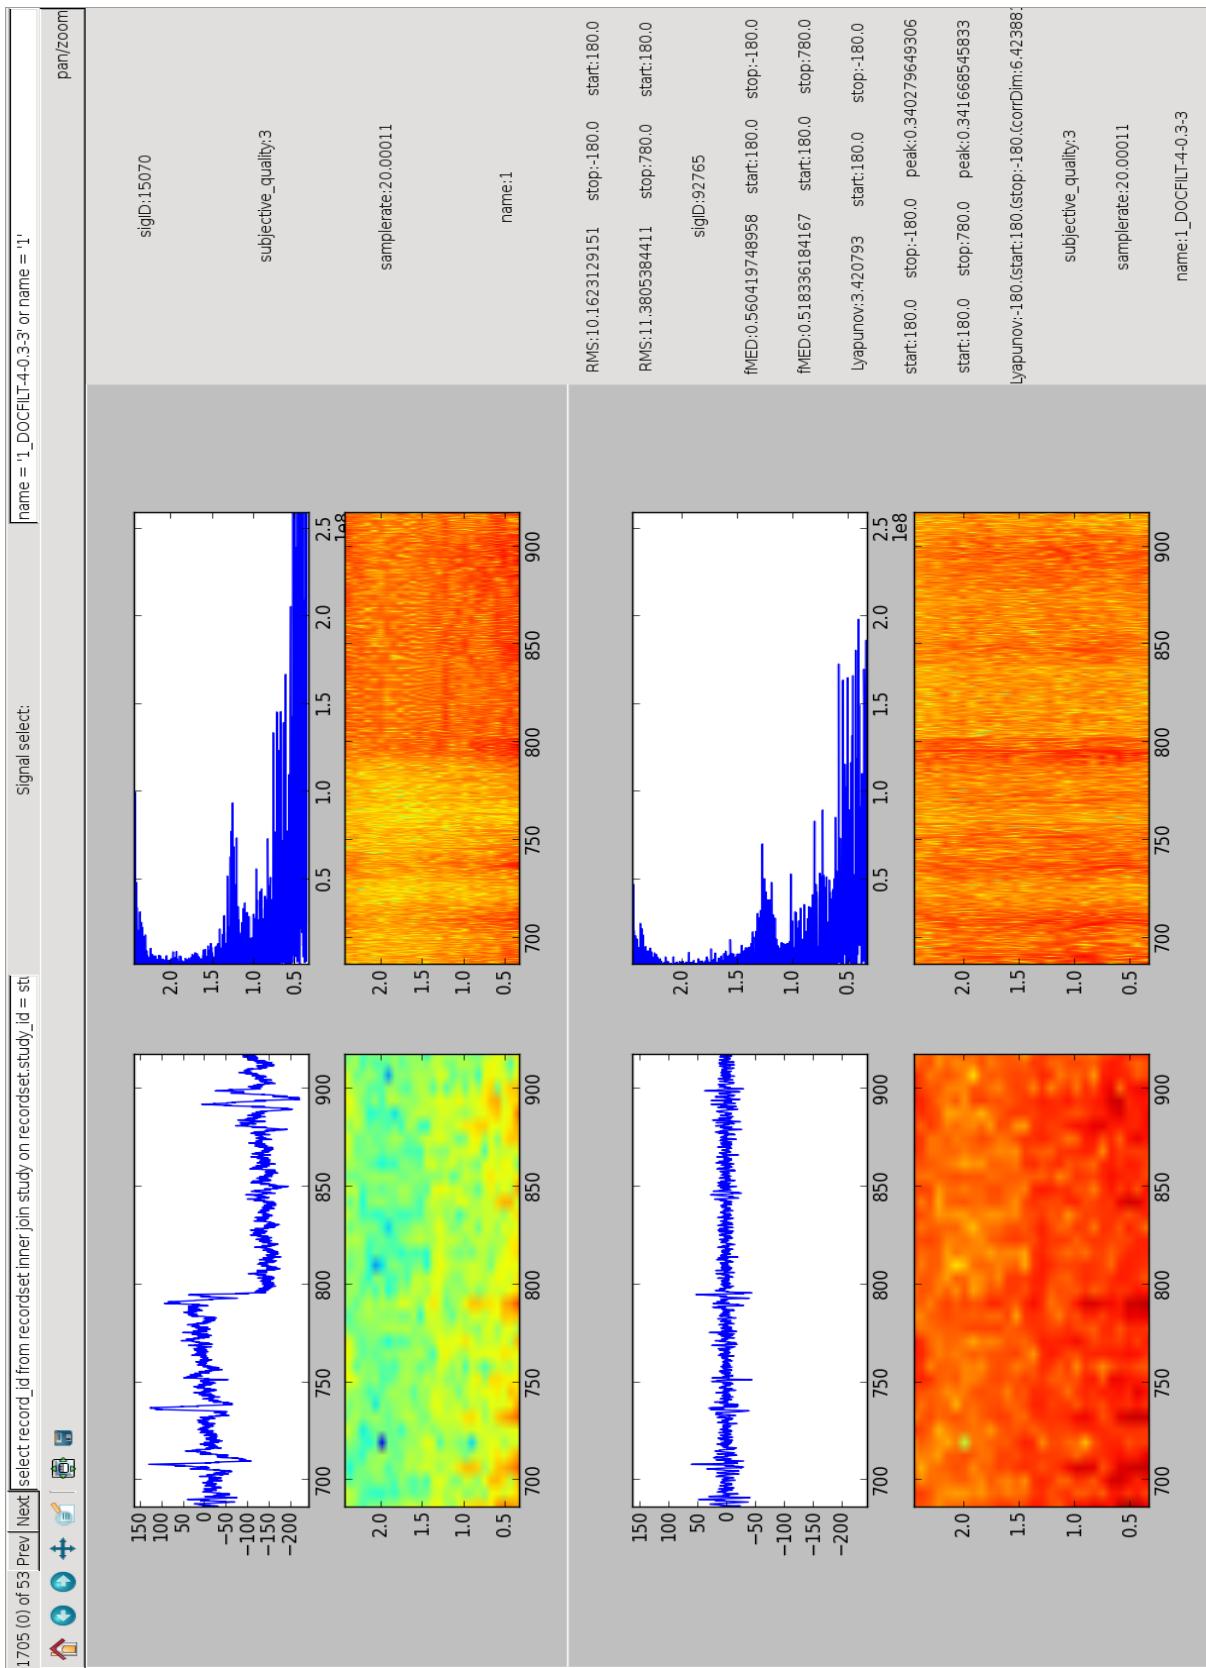
6.4 Pregledovanje signalov

Različne tehnike vizualizacije posnetkov smo uporabili na 53 posnetkih, kjer je bila poleg električne aktivnosti zajeta tudi meritev ocene pritiska znotraj maternice s pomočjo tokograma. V ta namen smo razvili program z grafičnim vmesnikom, ki omogoča hitro pregledovanje posnetkov, shranjenih v relacijski bazi. Program omogoča zaporedno pregledovanje posnetkov, pri čemer lahko za prikaz poljubno izberemo posamezne signale. Izbiro posnetkov uporabnik izvaja s pomočjo vnosnega polja, v katerega lahko vpiše ukaze v jeziku SQL, ki vrnejo identifikacijske številke posnetkov. Za izbiro signalov uporabnik v drugo vnosno polje vnese pogoj, ki mu morajo izbrani signali zadostiti - na primer ime signala. Grafični vmesnik programa za pregledovanje posnetkov je prikazan na sliki 6.4. Poleg različnih prikazov signalov uporabniški vmesnik omogoča tudi prikaz vseh naračunanih cenilk.

Različne tehnike vizualizacije signala pogosto prikazujejo enake količine. Tako je naprimjer pri prikazu signala kot časovne vrste na abscisi čas, na ordinati pa napetost, medtem ko je pri prikazu spektrograma na abscisi čas, na ordinati pa frekvenca, pri prikazu močnostnega spektra pa je v našem programu za pregledovanje na abscisi moč, na ordinati pa frekvenca. Program za pregledovanje omenjene količine v prikazu signala uskladi. Tako se premik po neki količini v enem prikazu odrazi v premikih po isti količini v vseh ostalih prikazih signala. V primeru spektrograma torej premikanje signala v vodoravni smeri povzroči premik v prikazu časovne vrste. Premikanje v navpični smeri povzroči premik v prikazu močnostnega spektra. Prav tako premikanje ali približevanje signala na časovni prikazu časovne vrste ali močnostnega spektra spremeni prikaz spektrograma. Primer uporabe te funkcionalnosti je prikazan na sliki 6.5.



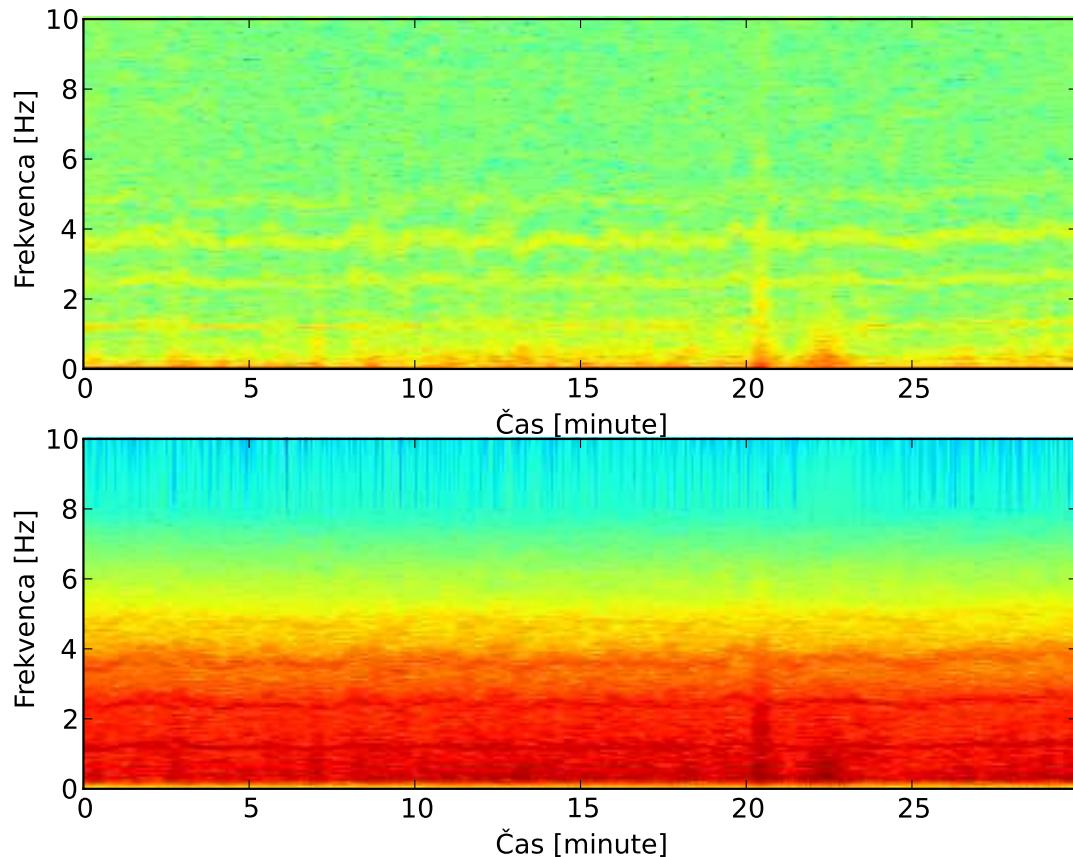
Slika 6.4: Grafični vmesnik programa za pregledovanje posnetkov v podatkovni bazi



Slika 6.5: Prikaz usklajenega približevanja dela posnetka med pregledovanjem

6.5 Lastnosti salv električne aktivnosti maternice

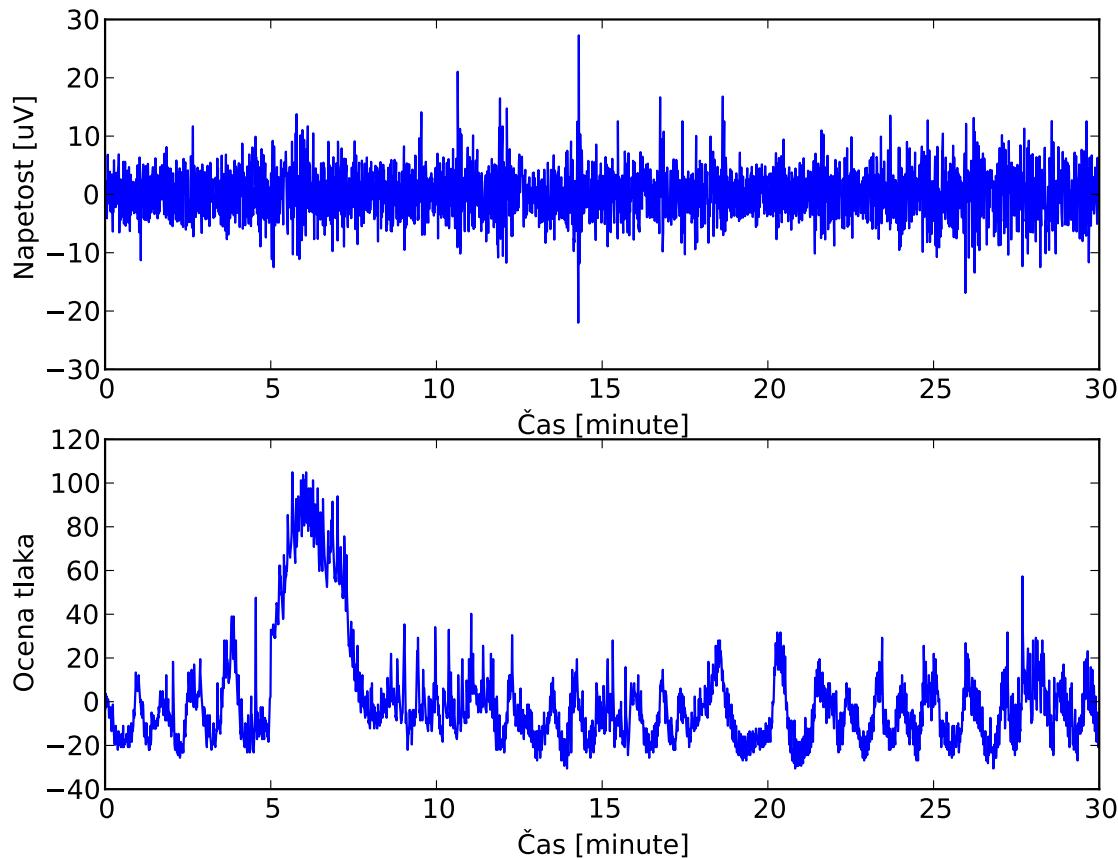
Pri pregledovanju posnetkov električne aktivnosti smo si pomagali predvsem z uporabo spektrogramov in časovno-frekvenčne predstavitev Wignerja in Villeja. Meritev tokografa smo opazovali kot navadno časovno vrsto.



Slika 6.6: Grebeni na spektrogramu pri frekvenci 4 Hz brez filtriranja (zgoraj) in ob uporabljenem filtru 0.3 Hz do 2.5 Hz (spodaj)

Na spektrogramih smo pogosto opazili manjše grebene tudi pri visokih frekvenkah, v zapornem pasu izbranih filtrov. Ti vrhovi so opazni zato, ker smo uporabili logaritmično barvno paletu. Takšna paleta močno poudari tiste dele močnostnega spektra, kjer so moči relativno nizke. Grebeni v spektrogramu so prikazani na sliki 6.6.

Opazili smo, da se salve električne aktivnosti začnejo že prej, preden se tlak v maternici

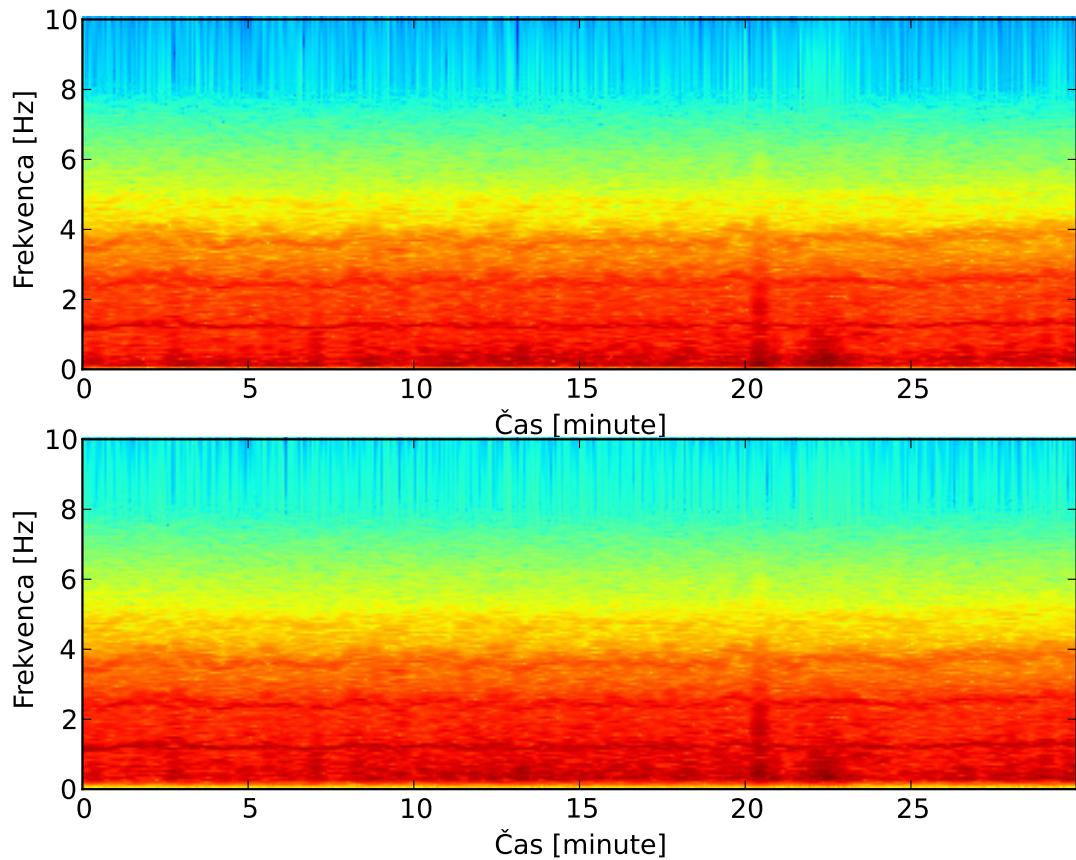


Slika 6.7: Salve električne aktivnosti pred dvigom tlaka v maternici

dejansko dvigne. Primer lahko vidimo na sliki 6.7. Do tega pojava verjetno pride zato, ker se vzburjenje celic razširi po maternici precej hitreje, kot se potem maternica dejansko krči.

Velika večina moči električne aktivnosti maternice je skoncentrirana pri nizkih frekvencah. Izbira spodnje meje pasovno-prepustnega filtra je torej zelo pomembna. Na žalost ne vemo, koliko uporabnih informacij nosijo morebitna valovanja v električni aktivnosti maternice, katerih perioda je daljša od pol minute. Poleg tega bi bilo merjenje signalov s tako nizkimi frekvencami težavno. Primer spektrograma in močnostnega spektra pri različni spodnji meji pasovno-prepustnega filtra je prikazan na sliki 6.8.

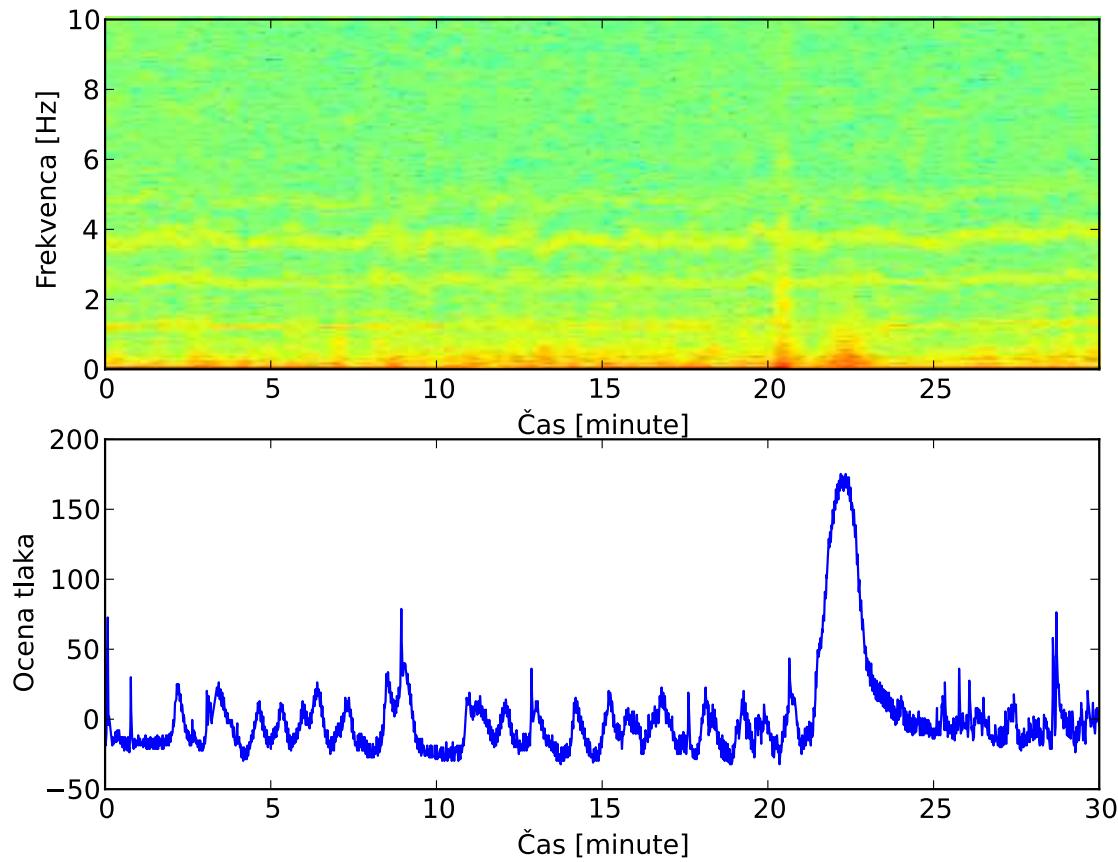
Ob salvah električne aktivnosti smo opazili, da se vrh močnostnega spektra dvigne, a še vedno ostane zelo nizek. Primer dviga močnostnega spektra med salvo električne aktivnosti, povezano s krčem, je prikazan na sliki 6.9.



Slika 6.8: Vpliv izbire spodnje meje frekvenčnega območja na spektrogram. Pri zgornji sliki je bila meja pri 0.08 Hz , pri spodnji 0.3 Hz . Zanimiva je še primerjava s sliko 6.6, na kateri je prikazan spektrogram istega signala, le brez uporabe filtrov. Večina energije signala je zbrana pri nizkih frekvencah.

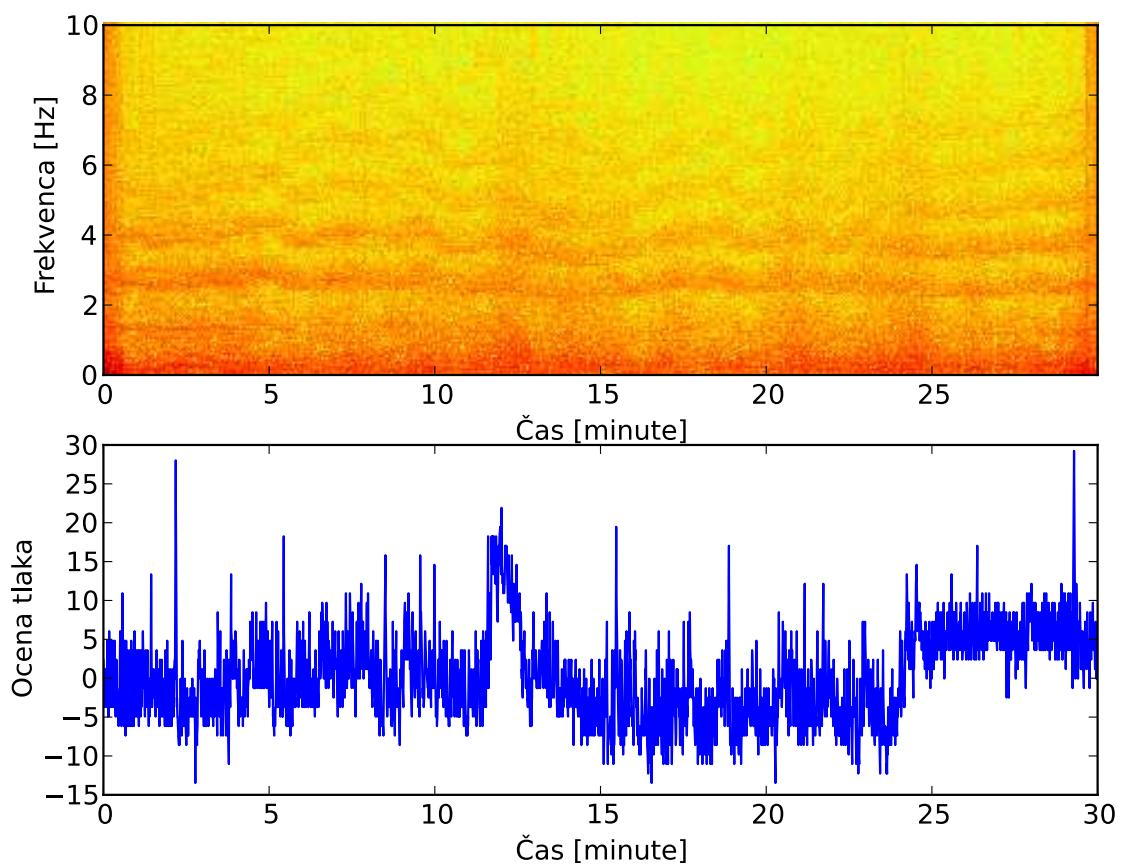
Ob uporabi časovno-frekvenčne predstavitev Wignerja in Villeja smo opazili množico navpičnih artefaktov. Še posebej so bili ti artefakti opazni ob stopnicah v signalu. Primer signalov z artefakti je prikazan na slikah 6.10 in 6.11.

Lastnost časovno-frekvenčne predstavitev Wignerja in Villeja, da se ob spremembah v signalu pojavijo artefakti, se je občasno izkazala celo za obetavno. Artefakti namreč poudarijo spremembe v močnostnem spektru signala, ki bi jih na spektrogramu zlahka spregledali. Tako so bile tudi salve električne aktivnosti, povezane s krči maternice, v nekaterih primerih precej bolje opazne pri uporabi časovno-frekvenčne predstavitev Wignerja in Villeja, kot pa

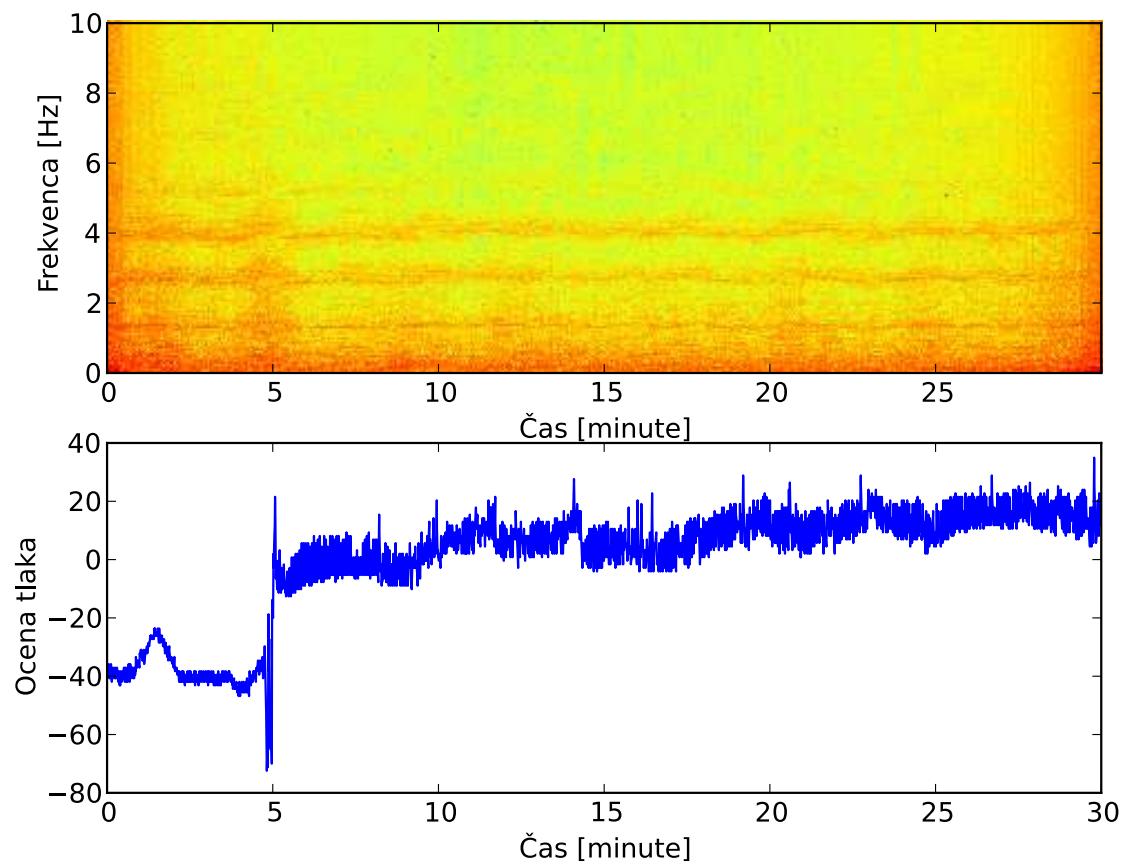


Slika 6.9: Primer dviga vrha močnostnega spektra med salvo električne aktivnosti

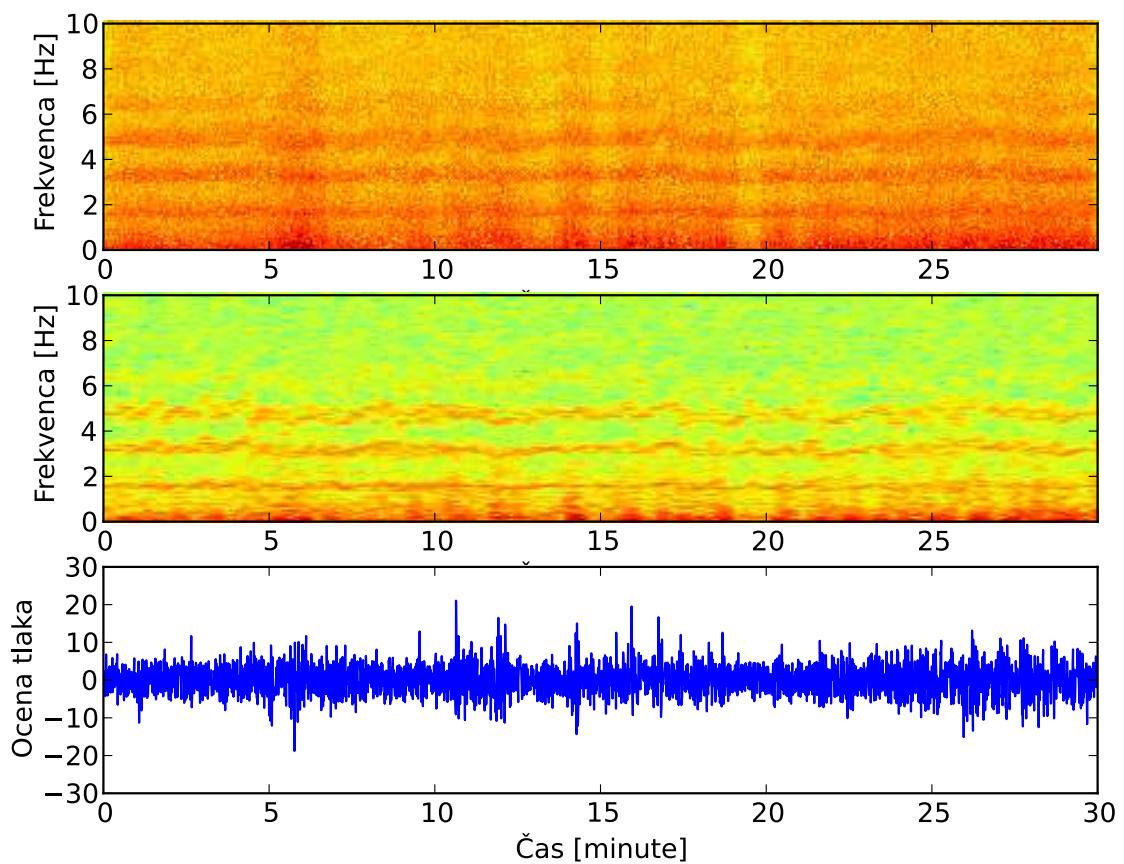
pri uporabi spektrograma. Primer takšnega signala je prikazan na sliki 6.12.



Slika 6.10: Časovno-frekvenčna predstavitev Wignerja in Villeja - posnetek 1721, 2. kanal - artefakti

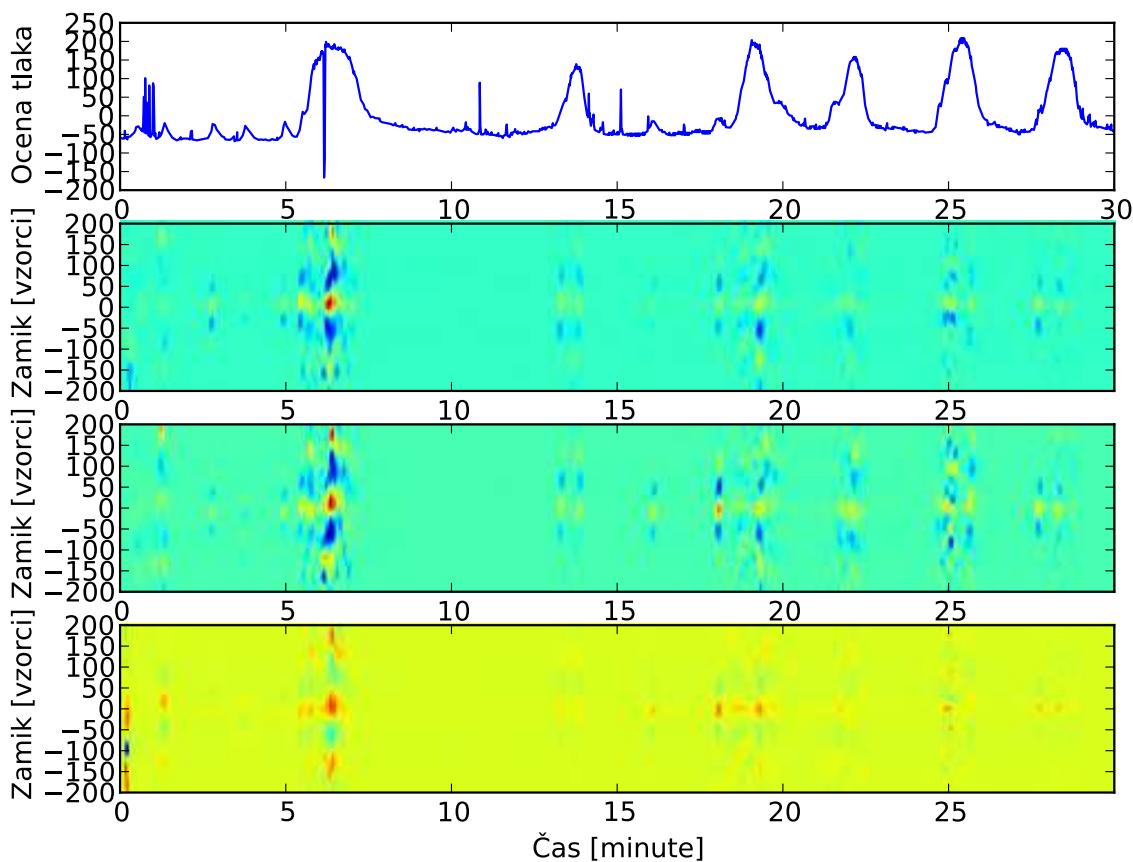


Slika 6.11: Časovno-frekvenčna predstavitev Wignerja in Villeja - posnetek 1718, 1. kanal - artefakti



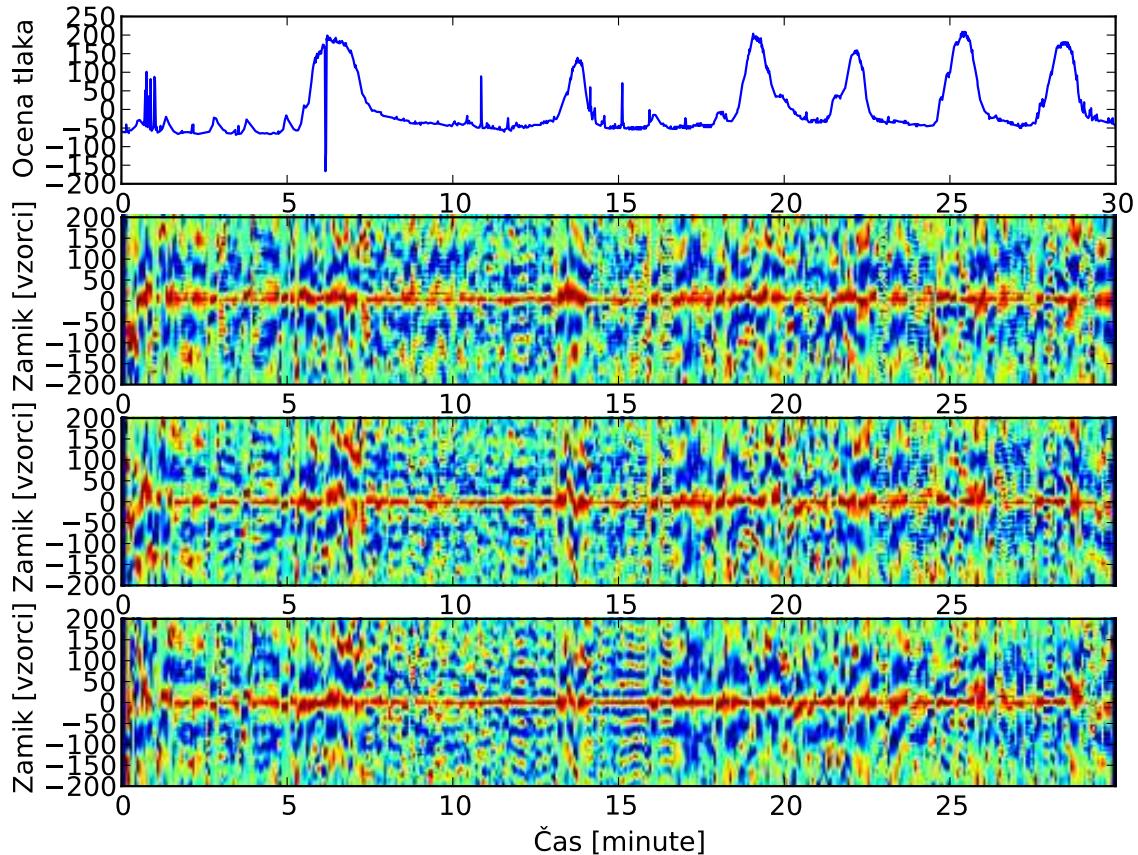
Slika 6.12: Salve električne aktivnosti, poudarjene z uporabo časovno-frekvenčne predstavljive Wignerja in Villeja

Pri vizualizaciji kratko-intervalnih križno-korelacijskih koeficientov smo opazili, da do močnega ujemanja med električno aktivnostjo na vseh treh zajetih kanalih ne pride med vsemi učinkovitimi krči maternice. Primer grafične predstavitev kratko-intervalnih križno-korelacijskih koeficientov je prikazan na sliki 6.13. Pred izračunom kratko-intervalnih križno-korelacijskih koeficientov smo na signalih uporabili pasovno-prepustni filter od 0.08 Hz do 4 Hz.



Slika 6.13: Ocena tlaka (zgoraj), kratko-intervalni križno-korelacijski koeficienti med kanaloma 1 in 2 (v sredini zgoraj), nato 1 in 3 (v sredini spodaj), 2 in 3 (spodaj).

Ker so bili signali večino časa dokaj slabo korelirani, smo poizkusili kratko-intervalne križno-korelacijske koeficiente znotraj vsakega časovnega intervala normalizirati. Rezultat normalizacije je prikazan na sliki 6.14. Na žalost na slikah kratko-intervalnih križno-korelacijskih koeficientov med salvami električne aktivnosti tudi po normalizaciji nismo opazili



Slika 6.14: Ocena tlaka (zgoraj), normalizirani kratko-intervalni križno-korelacijski koeficienti med kanaloma 1 in 2 (v sredini zgoraj), nato 1 in 3 (v sredini spodaj), 2 in 3 (spodaj).

dovolj značilnih grebenov, da bi lahko na njihovi osnovi ocenili hitrost ali kako drugo lastnost širjenja akcijskih potencialov po maternici. Vrh kratko-intevalnih križno-korelacijskih koeficientov je bil običajno pri zamiku 0, kar nas napeljuje na misel, da se akcijski potenciali po maternici verjetno razširijo hitreje, kot je bil čas vzorčenja pri zajemu posnetkov.

Ob pregledovanju posnetkov z različnimi tehnikami vizualizacije na žalost nismo opazili nobenih značilnosti, po katerih bi se posnetki, kjer je bil porod prezgodaj, razlikovali od posnetkov, kjer je bil porod ob roku.

6.6 Ocena močnostnega spektra

Pri določanju močnostnega spektra fizioloških signalov se moramo soočiti z možnostjo, da signal ni stacionaren. Na srečo so 30-minutni posnetki, kakršne smo obdelovali, kratki v primerjavi s trajanjem nosečnosti, zaradi česar lahko pričakujemo, da se močnostni spekter med samim snemanjem ne bo bistveno spreminal. Za izračun močnostnih spektrov signalov smo zato uporabili kar diskretno Fourierjevo transformacijo na celotnih posnetkih - odstranili smo le po 180 sekund po začetku in pred koncem vsakega posnetka, da smo se izognili prehodnim pojavom zaradi filtriranja.

Vseeno smo dobljene rezultate - frekvenco vrha močnostnega in mediano frekvenco močnostnega spektra primerjali tudi s frekvenco vrha močnostnega spektra in mediano frekvenco, ki smo ju izračunali s povprečenim močnostnim spektrom.

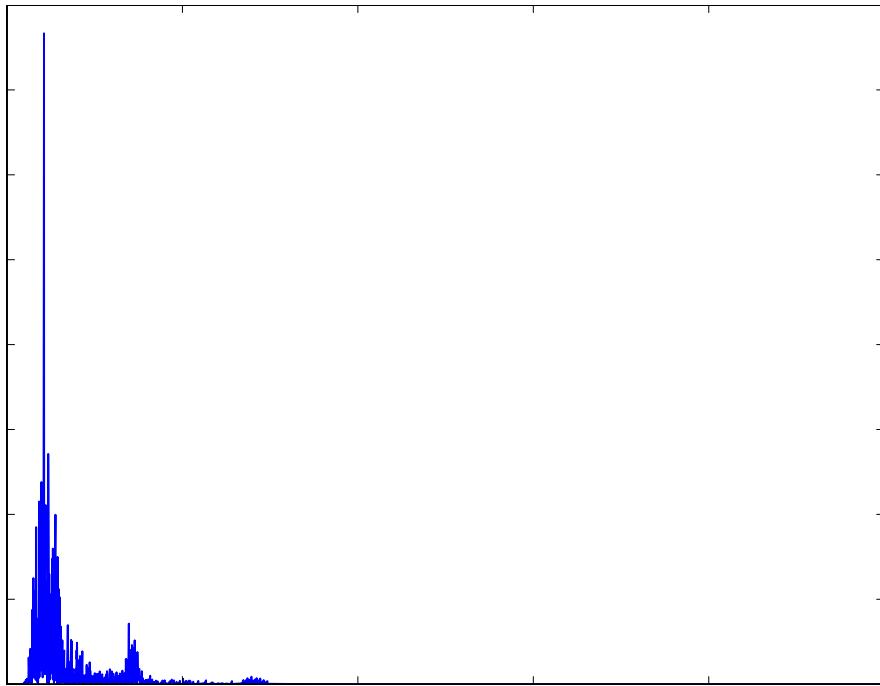
Povprečeni močnostni spekter smo izračunali tako, da smo s pomočjo diskretne Fourierjeve transformacije računali močnostne spektre odsekov signala, dolgih 1024 vzorcev z razmaki po 100 vzorcev - torej z drsečim oknom. Dobljene močnostne spektre smo nato povprečili in tako dobili povprečeni močnostni spekter signala. Tovrstna ocena močnostnega spektra je dobra tudi za nestacionarne signale [38].

Izkazalo se je, da rezultati, dobljeni s povprečenim močnostnim spektrom signala, niso bili bistveno drugačni od rezultatov, ko smo močnostni spekter preprosto naračunali za celoten signal. Rezultati uporabe tehnik obdelave signalov, osnovanih na oceni močnostnega spektra signalov s povprečenjem in brez njega, so predstavljeni v poglavju 10.

6.7 Lastnosti močnostnega spektra 30-minutnih signalov

Med pregledovanjem močnostnih spektrov zajetih signalov EMG maternice smo pogosto opazili več vrhov. Poleg tega so raziskave na nižjih sesalcih [9] pokazale, da električno aktivnost maternice pri teh sesalcih lahko razdelimo na dve ločeni valovanji - hitro in počasno. Zanimalo nas je, kako se močnostni spektri spremenijo med nosečnostjo. V ta namen smo za nekaj nosečnosti, kjer sta bila na voljo dva posnetka, preverili, kako so se spreminali močnostni spektri. Opazovali smo prve kanale posnetkov ob uporabi različnih filtrov. V večini primerov smo v močnostnih spektrih posnetkov opazili vsaj dva vrhova. Primer močnostnega spektra z dvema izrazitima in enim manjšim vrhovom je prikazan na sliki 6.15.

Ob uporabi filtrov s spodnjo mejo 0.08 Hz se je pokazalo, da je večina energije signala

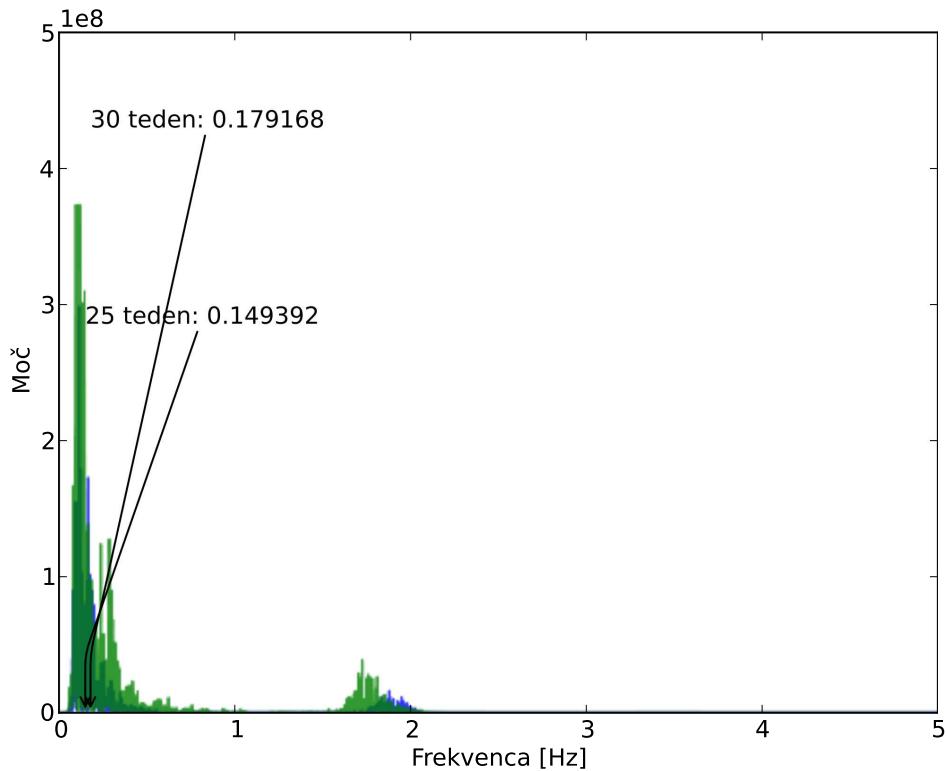


Slika 6.15: Vrhovi močnostnega spektra signala EMG maternice. Uporabljen je bil filter od 0.3 do 3 Hz.

zbrana pri nizkih frekvencah. Spremembe med nosečnostjo zato običajno niso bile močno opazne. Primer sprememb močnostnega spektra signala med nosečnostjo ob uporabi filtra od 0.08 Hz do 3 Hz je prikazan na sliki 6.16

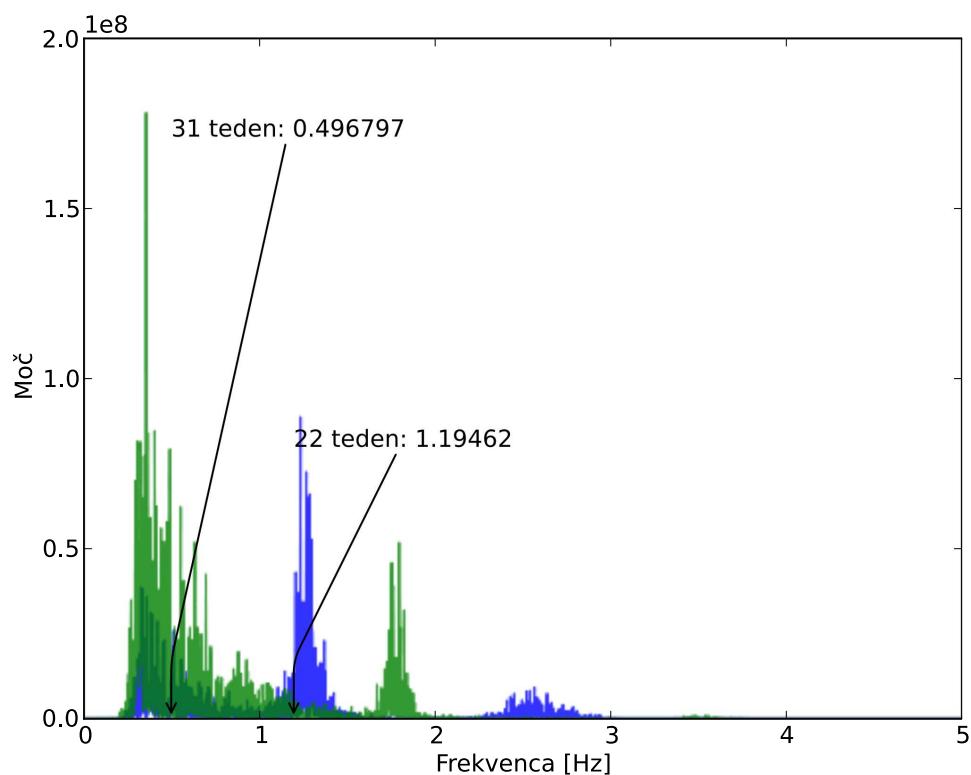
Večje razlike v močnostnih spektrih smo opazili ob uporabi filtrov s spodnjo mejo pri 0.3 Hz. Pri teh posnetkih smo opazili, da so vrhovi pri nižjih frekvencah proti koncu nosečnosti zrasli, medtem ko so se vrhovi pri višjih frekvencah praviloma zmanjšali. Mediana frekvenca je zato med nosečnostjo padala. Prav tako se je proti nižjim frekvencam običajno premaknil tudi vrh močnostnega spektra. Opazovanja teh signalov so nas napeljala na misel, da se električna aktivnost maternice med nosečnostjo premika proti nižjim frekvencam. Primer premika močnostnega spektra in z njim mediane frekvence proti nižjim frekvencam je prikazan na sliki 6.17.

Ker je bil čas zajema posnetkov v splošnem precej pred porodom, nismo mogli preveriti,



Slika 6.16: Spremembe močnostnega spektra signala EMG maternice med nosečnostjo. Uporabljen je bil filter od 0.08 do 3 Hz.

ali se tik pred porodom močnostni spektri električne aktivnosti maternice morda ne začnejo spet premikati proti višjim frekvencam, kar nakazujejo rezultati nekaterih tujih raziskav [6].



Slika 6.17: Spremembe močnostnega spektra in mediane frekvence med nosečnostjo. Uporabljen je bil filter od 0.3 do 3 Hz.

POGLAVJE 7

Utemeljitev izbranih tehnik obdelave signalov

7.1 Linearne tehnike

Dosedanje raziskave EMG maternice so se osredotočale predvsem na linearne tehnike obdelave signalov - torej na različne metode analize močnostnega spektra signala [6, 18, 25]. Močnostni spekter razkriva periodične komponente signala in ga je zato primeren za analizo časovnih vrst, ne glede na to, ali je ta analiza statistična ali dinamična [22]. Da bi lahko nelinearne tehnike z nečim primerjali, smo se odločili implementirati pogosto uporabljene linearne tehnike obdelave signalov in jih primerjati z nekaj izbranimi nelinearnimi tehnikami obdelave signalov.

7.1.1 Koren srednje kvadratne vrednosti signala

Koren srednje kvadratne vrednosti signala (root mean square, *RMS*) predstavlja moč signala. Zaradi pogostejših popadkov in z njimi povezanih salv električne aktivnosti maternice bi lahko pričakovali, da se bo vrednost korena srednje kvadratne vrednosti signala bliže konca nosečnosti v povprečju, gledano čez vse posnetke, dvignila. Poleg tega smo hoteli preveriti, ali se bodo dobljeni rezultati skladali z dosedanjimi raziskavami [11, 12].

7.1.2 Frekvenca vrha močnostnega spektra signala

Dosedanje raziskave so pokazale, da se močnostni spekter električne aktivnosti med popadki tik pred rojstvom spremeni [8, 39]. Mi smo se odločili, da preverimo, kako se frekvenca vrha močnostnega spektra signala spreminja med nosečnostjo, ne glede na oddaljenost poroda.

7.1.3 Mediana frekvenca močnostnega spektra signala

Če upoštevamo le najvišji vrh močnostnega spektra signala, utegnemo zavreči uporabno informacijo, ki se skriva v nižjih vrhovih. Zato smo kot perspektivno cenilko izbrali še mediano frekvenco močnostnega spektra signala.

7.1.4 Prvi prehod preko ničle koeficientov avtokorelacije

Z opazovanjem avtokorelacijskih koeficientov lahko ločimo stohastično obnašanje od periodičnega [22]. Poleg tega smo za izračun cenilk, osnovanih na konceptu faznega prostora, morali med drugim določiti časovno zakasnitev pri rekonstrukciji le-tega. Časovna zakasnitev mora biti namreč dovolj velika, da koordinate točk v rekonstruiranem faznem prostoru niso več odvisne ena od druge. Avtokorelacijski koeficienti povedo, kako podoben je signal samemu sebi z danim zamikom. Prvi prehod preko ničle avtokorelacijskih koeficientov pove, pri kakšnem zamiku signal neha biti podoben sam sebi, zato je njegova vrednost primerna izbira za časovni zamik pri rekonstrukciji faznega prostora [40]. Ko so bile vrednosti prvih prehodov preko ničle koeficientov avtokorelacije izračunane za vse posnetke, smo se odločili, da preverimo še, ali je z njihovo uporabo mogoče ločevati skupine posnetkov EMG maternice.

7.2 Nelinearne tehnike

Glavni cilj, ki smo ga poizkusili doseči z delom, predstavljenim v tej doktorski disertaciji, je bil implementirati nekaj nelinearnih tehnik obdelave signalov in oceniti njihovo primernost za ločevanje skupin posnetkov EMG maternice oziroma za napovedovanje prezgodnjega poroda. Nekatere dosedanje raziskave [13] nelinearnih tehnik so namreč že dale določene vzpodbudne rezultate.

7.2.1 Maksimalni eksponent Ljapunova in korelacijska dimenzija

Maksimalni eksponent Ljapunova in korelacijska dimenzija sta lastnosti signala, ki ju določimo na osnovi rekonstruiranega faznega prostora sistema, ki naj bi signal ustvaril. Sta med prvimi kandidati za dinamično analizo bioloških signalov [22]. Fazni prostor je konstrukt, ki predstavlja spremembe dinamičnih spremenljivk sistema [40, 41]. Točke v faznem prostoru odgovarjajo stanjem, ki jih lahko zavzame sistem. Dimenzijsi rekonstruiranega faznega prostora Q rečemo vložitvena dimenzija. Po Takensovem teoremu [42] mora biti dimenzija rekonstruiranega prostora enaka najmanj $2o + 1$, kjer je o število dejavnikov, ki vplivajo na

sistem. Da bi iz zajetega dvodimenzionalnega signala rekonstruirali Q -dimenzionalni fazni prostor, moramo poleg vložitvene dimenzijs določiti tudi časovno zakasnitev.

Če je primerno časovno zakasnitev še nekako mogoče določiti [43], je določitev števila dejavnikov, ki vplivajo na naš izbrani sistem, težja. Ker ne vemo, koliko mehanizmov dejansko vpliva na krčenje maternice, smo brez kakršnega koli dokaza privzeli, da so takšni mehanizmi trije in temu primerno izbrali vložitveno dimenzijo $Q = 7$.

Eksponent Ljapunova

Na osnovi faznega prostora lahko določimo nekatere lastnosti časovne vrste. Eksponent Ljapunova ocenjuje količino kaosa v sistemu [22]. Pričakovali bi lahko, da se bo kaotičnost sistema pred porodom spremenila - ali se bo povečala, ker bodo prehodi med stanji sistema bolj sunkoviti, ali pa se zmanjšala, ker bo delovanje maternice bolj usklajeno.

Korelacijska dimenzija

Korelacijska dimenzija je ocena kompleksnosti časovne vrste [22], prav tako osnovana na faznem prostoru. Kot pri eksponentu Ljapunova bi lahko pričakovali, da se bo med nosečnostjo spremenila - ali se bo zmanjšala, ker se bo število različnih možnih stanj bolj vzburljive maternice večje, ali pa se bo povečala, ker se bo maternica zaradi usklajenosti delovanja vedno nahajala v enem od manjšega števila stanj.

7.2.2 Vzorčna entropija in večločljivostna vzorčna entropija

Kompleksnost časovne vrste lahko ocenjujemo tudi v časovnem prostoru, ne da bi rekonstruirali fazni prostor. Ena izmed ocen kompleksnosti časovne vrste je tudi vzorčna entropija. Pri računanju vzorčne entropije preverjam, kako predvidljiv je nek signal. Bolj, ko je signal nepredvidljiv, višja je vzorčna entropija. Pričakovali bi lahko, da se bo vzorčna entropija med nosečnostjo spremenila - ali bo zaradi usklajenosti delovanja maternice nižja, ali pa bo zaradi večjega števila aktiviranih mišičnih celic višja.

7.3 Robustna avtomatska analiza

Večina dosedanjih raziskav se je osredotočala na analizo električne aktivnosti maternice med popadki oziroma na analizo salv električne aktivnosti maternice [6, 7, 8, 10]. Težav z analizo posameznih popadkov je več:

1. Določanje popadkov je težavno.

Merjenje tlaka v sami maternici je težavno, saj je merilnik tlaka potrebno vstaviti v samo maternico, kar pomeni, da se plodove membrane poškodujejo, pojavi pa se tudi nevarnost vnosa mikroorganizmov in s tem infekcije.

Tlak znotraj maternice lahko ocenimo tako, da izmerimo, pri kakšnem pritisku se del trebuha, pod katerim se nahaja maternica, splošči. Na tem principu delujejo tokografi. Na žalost je takšna ocena tlaka znotraj maternice dokaj nenatančna. Aparatura za tovrstno merjenje je dokaj okorna, med merjenjem pa lahko zdrsne iz pravilnega položaja.

2. V primeru, da ne merimo tlaka, je potrebno klasificirati salve električne aktivnosti.

Klasifikacija šumnatih salv električne aktivnosti ni povsem zanesljiva. Poleg tega bi bilo za avtomatično analizo potrebno natančno določiti začetke in konci salv aktivnosti. Določiti bi morali tudi vrste salv oziroma razloge za njihov nastanek. Ker je področje raziskav EMG maternice v primerjavi z na primer raziskavami elektrokardiogramov mlado, je naše poznavanje natančnih mehanizmov, ki prožijo salve, slabo. Prav tako še niso določeni splošno sprejeti protokoli, po katerih bi lahko določali vrste in točno trajanje salv aktivnosti.

3. Določanje salv aktivnosti, povezanih s popadki, je subjektivno.

Četudi bi že obstajalo ekspertno znanje, ki bi omogočalo določanje vrst in trajanja salv aktivnosti, bi bilo to določanje nezanesljivo. Da bi vzpostavili zlati standard, po katerem bi potem lahko merili uspešnost klasifikacije, bi moralo posnetke neodvisno pregledati več ljudi, ki bi se glede ocene salv aktivnosti morali med seboj strinjati. Takšne skupine, kolikor vemo, zaenkrat na svetu ni. Tudi če bi strokovnjaki s tovrstnim znanjem obstajali, bi bila vsaka metoda, osnovana na ročnem določanju salv aktivnosti, izpostavljena nenatančnosti človeških ocen. Težavno je torej že samo določanje začetkov in koncov salv električne aktivnosti. Zato je zaželeno, da se subjektivnim ocenam v čim večji meri izognemo.

4. Električna aktivnost izven krčev lahko nosi koristno informacijo.

Zaenkrat še ne vemo, kako točno se med krčenjem uskladi delovanje mišičnih celic miometrija. Prav mogoče je, da tudi električna aktivnost maternice pred začetkom in po koncu krča nosi uporabno informacijo, na osnovi katere bi lahko sklepali, da se

porod bliža. Ta aktivnost je sicer lahko prekrita s šumom, vendar je vseeno ne bi radi zanemarili.

5. Okrog 22. tedna nosečnosti je popadkov malo.

Prvi spontani krči maternice se pojavijo že zelo zgodaj v nosečnosti [19]. Takrat so ti krči in z njimi povezane salve električne aktivnosti dokaj redke. Ker smo v okviru raziskave, opisane v tem delu, hoteli obdelovati tudi posnetke zgodaj v nosečnosti, smo morali najti rešitev tudi za primere, ko v 30 minutah snemanja ne bi bilo nobenega krča.

6. Nekatere nelinearne metode zahtevajo veliko podatkov.

Pri metodah, osnovanih na faznem prostoru, je natančnost ocene iskanih količin, kot sta maksimalni eksponent Ljapunova in korelačnska dimenzija, odvisna od količine dostopnih podatkov. Več ko je podatkov, bolj natančni sta oceni. Za oceno maksimalnega eksponenta Ljapunova in korelačnske dimenzije je torej dobro uporabiti vse vzorce v časovni vrsti, ne pa le kratkih odsekov, kakršne predstavljajo posamezne salve aktivnosti.

Zaradi zgoraj naštetih težav z obdelavo posameznih salv električne aktivnosti smo se, za razliko od drugih raziskovalnih skupin [6, 18, 36, 44], odločili, da posnetke obdelamo v celoti. Posnetke smo tako filtrirali, nato pa cenilke računali na odseku od 180 s po začetku snemanja do 180 s pred koncem snemanja. Pretiranemu šumu v posnetkih smo se izognili s predobdelavo signalov z učinkovitimi pasovno-prepustnimi filterji.

7.4 Utemeljitev analize v 22. tednu nosečnosti

Prvi spontani krči maternice se običajno lahko pojavijo že zgodaj v nosečnosti. Maternica je torej že tudi zgodaj v nosečnosti električno aktivna. Na žalost je le iz pogostosti teh krčev nemogoče sklepati, ali bo prišlo do spontanega prezgodnjega poroda [45]. Vseeno lahko upamo, da bi katera iz naprednejših tehnik obdelave signalov pokazala kakšno razliko med električno aktivnostjo maternic pri nosečnostih, kjer grozi spontan prezgodnji porod in električno aktivnostjo maternic pri nosečnostih, kjer takšne nevarnosti ni. Velika težava pri spontanem prezgodnjem porodu je, da trenutno ne poznamo nobene tehnike, s pomočjo katere bi lahko zanesljivo ocenili verjetnost, da bo do spontanega prezgodnjega poroda prišlo. Napovedni modeli sicer obstajajo [2], vendar temeljijo predvsem na dejavnikih tveganja, na

katere po začetku nosečnosti nimamo več vpliva (edina izjema med temi dejavniki je kajenje). Pozneje v nosečnosti je ocenjevanje nevarnosti lažje, poleg tega pa je tudi verjetnost, da bo v tem primeru nedonošenček porod preživel brez negativnih posledic, večja.

Prav zaradi težavnosti napovedovanja prezgodnjega poroda zgodaj v nosečnosti bi bila kakršna koli metoda, ki bi tovrstno napovedovanje izboljšala, nadvse dobrodošla. Ravno zato smo se odločili, da bomo obdelovali tudi posnetke, zajete okrog 22. tedna nosečnosti, čeprav so salve elektične aktivnosti maternice takrat še redke.

POGLAVJE 8

Linearne tehnike obdelave elektromiogramov maternice

8.1 Koren srednje kvadratne vrednosti signala

Za vsak signal, predstavljen kot časovno vrsto $x(t); t = 0 \dots N - 1$ dolžine N , smo koren srednje kvadratne vrednosti signala, RMS , izračunali kot koren povprečja kvadratov vseh vzorcev v signalu:

$$RMS = \sqrt{\frac{1}{N} \sum_{i=0}^{N-1} x(i)^2} . \quad (8.1)$$

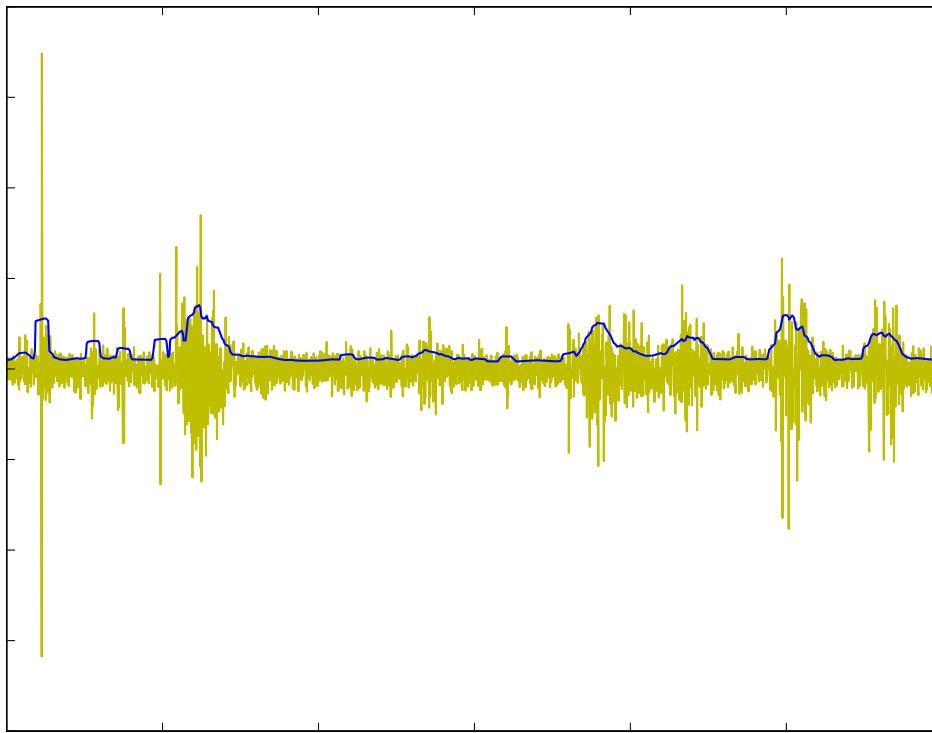
Prikaz izračuna korena srednje kvadratne vrednosti signala EMG maternice z drsečim oknom je prikazan na sliki 8.1.

8.2 Frekvenca vrha močnostnega spektra

Za vsak signal, $x(t)$, smo z uporabo hitre Fourierjeve transformacije izračunali močnostni spekter P . Nato smo frekvenco vrha močnostnega spektra definirali takole:

$$f_{\max} = \arg \left(\frac{f_s}{N} \max_{i=0}^{N-1} P(i) \right) , \quad (8.2)$$

kjer je f_s frekvenca vzorčenja in N št. vzorcev. Primer močnostnega spektra signala EMG maternice z označeno mediano frekvenco je prikazan na sliki 8.2



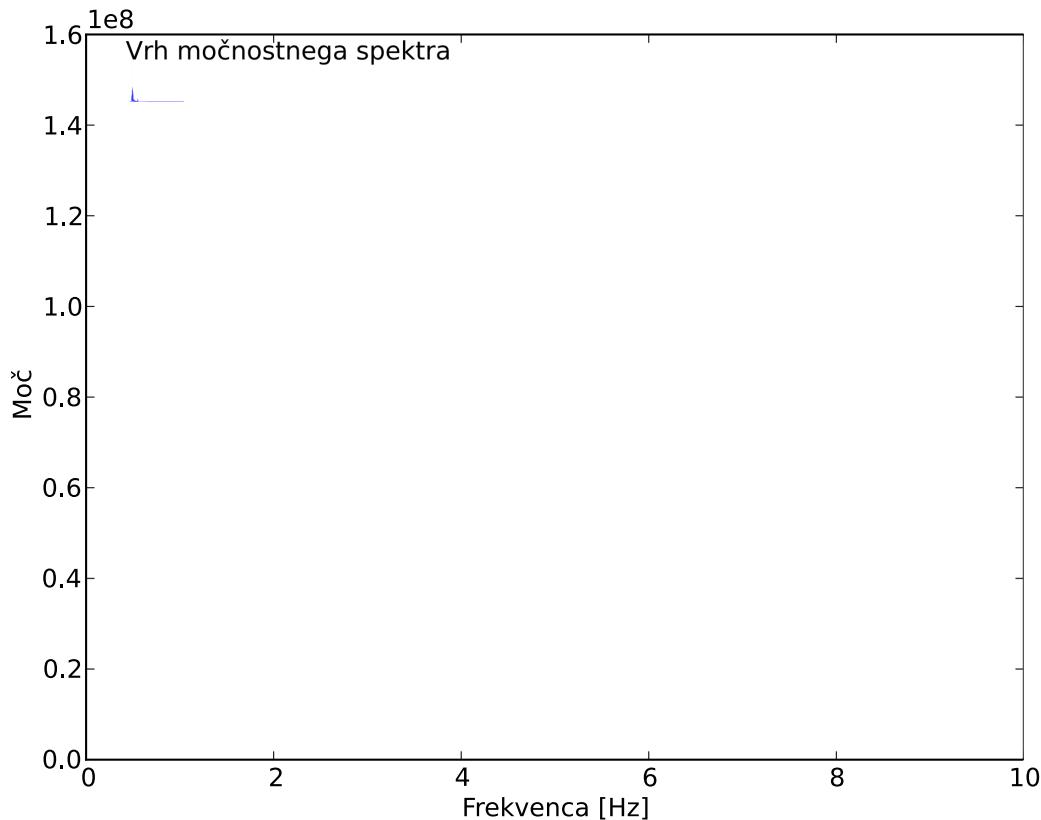
Slika 8.1: Koren srednje kvadratne vrednosti signala EMG maternice z drsečim oknom

8.3 Mediana frekvenca močnostnega spektra signala

Medianu frekvenco, f_{med} , smo definirali kot:

$$f_{\text{med}} = i_m \frac{f_s}{N}, \quad \sum_{i=0}^{i=i_m} P(i) \stackrel{\circ}{=} \sum_{i=i_m}^{i=N-1} P(i) . \quad (8.3)$$

Mediana frekvenca je torej v našem primeru frekvenca tik nad tisto točko, kjer sta vsoti moči v močnostnem spektru P niže in više, enaki. Primer močnostnega spektra signala EMG maternice z označeno mediano frekvenco je prikazan na sliki 8.3.



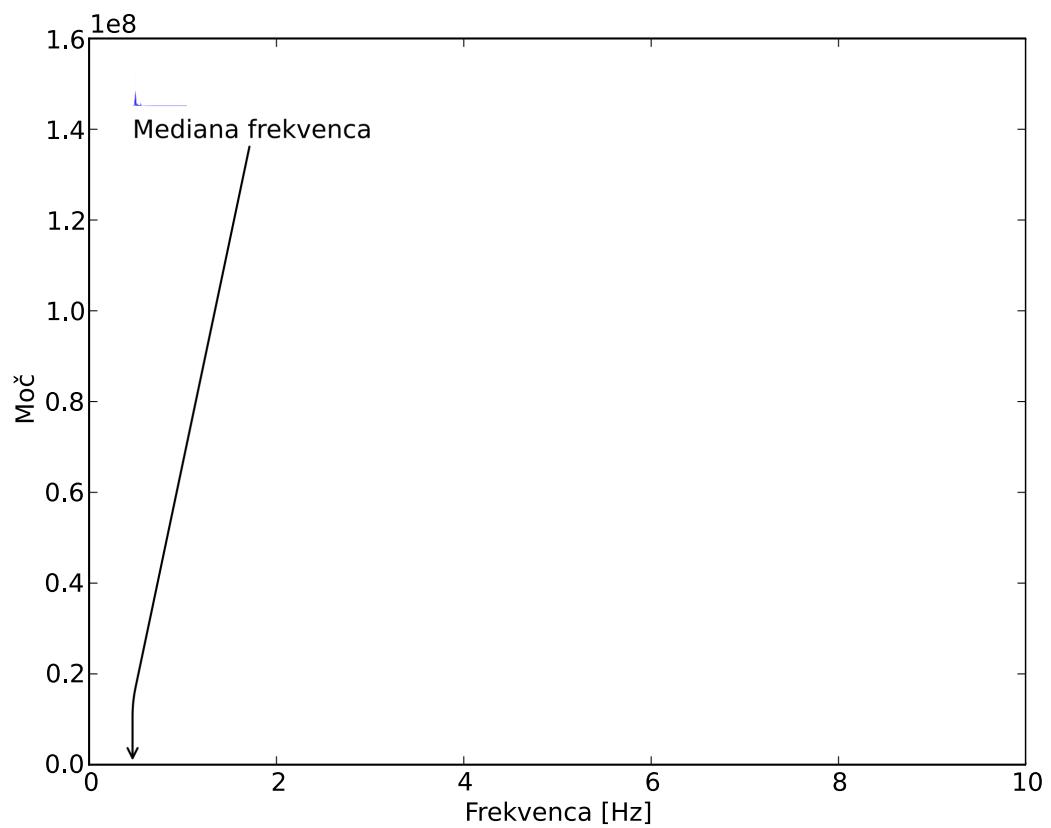
Slika 8.2: Močnostni spekter signala EMG maternice z označenim vrhom

8.4 Prvi prehod preko ničle avtokorelacijske

Prvi prehod preko ničle avtokorelacijskih koeficientov, $\tau_{R_{xx}}$, smo definirali kot prvi prehod preko ničle pri avtokorelacijski, $R_{xx}(\tau)$, začevši pri vrhu avtokorelacijskih koeficientov signala $x(t)$:

$$R_{xx}(\tau_{R_{xx}}) = 0; \quad R_{xx}(\tau) = \sum_{i=0}^{N-1} x(i) x(\tau + i) . \quad (8.4)$$

Primer prikaza koeficientov avtokorelacijske signala EMG maternice v okolici prvega prehoda preko ničle je prikazan na sliki 8.4.



Slika 8.3: Močnostni spekter signala EMG maternice z označeno mediano frekvenco



Slika 8.4: Koeficienti avtokorelacije signala EMG maternice. Prvi prehod preko ničle je pri zamiku 11 vzorcev.

POGLAVJE 9

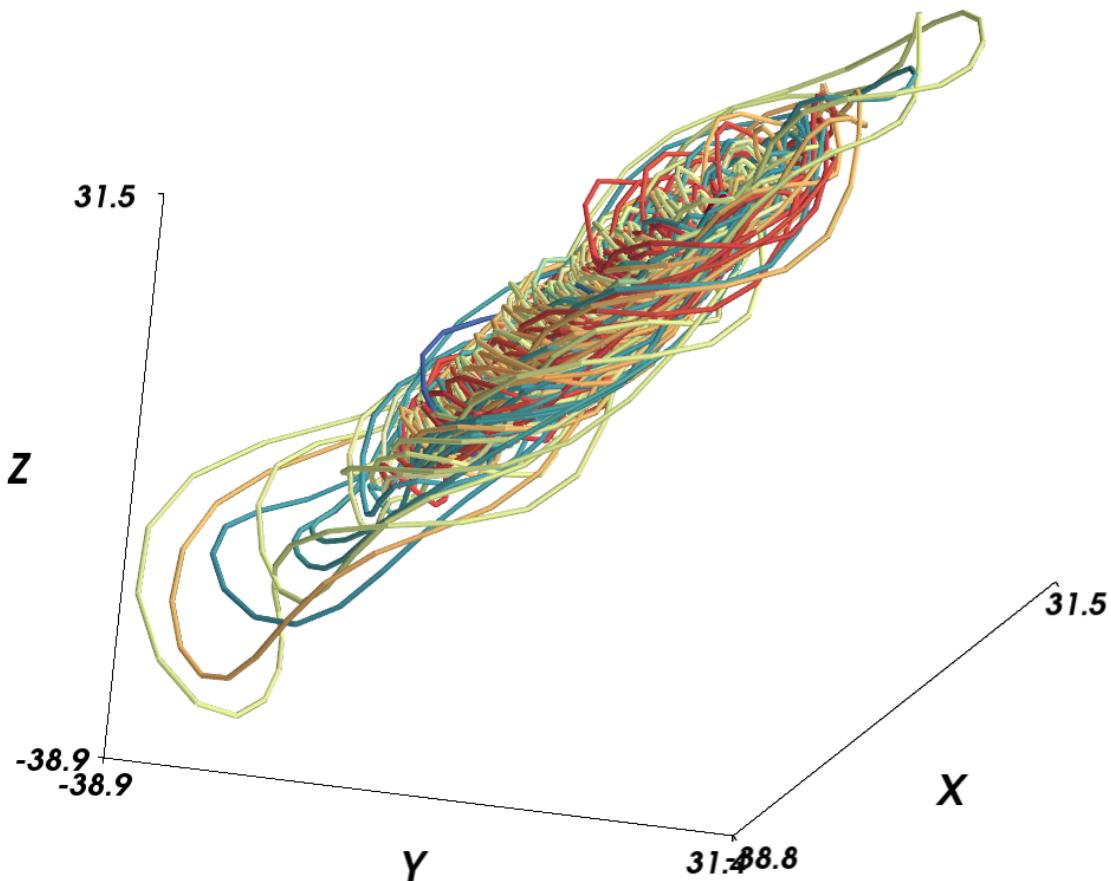
Nelinearne tehnike obdelave elektromiogramov maternice

9.1 Maksimalni eksponent Ljapunova in korelacijska dimenzija

Obe tehniki sta osnovani na predstavitvi vhodnih podatkov kot točk v faznem prostoru. Fazni prostor je konstrukt, ki prikaže oziroma vizualizira spremembe dinamičnih spremenljivk v sistemu [40, 41]. Vsako možno stanje sistema predstavlja natanko ena točka v faznem prostoru. Na posneto časovno vrsto vpliva več dejavnikov, ki predstavljajo komponente stanja danega sistema. Iz posnete časovne vrste rekonstruiramo fazni prostor, ki je „ekvivalenten“ originalnemu faznemu prostoru sistema. To storimo s pomočjo pristopa, imenovanega vložitev s časovno zakasnitvijo. Pri dani časovni vrsti $x(t)$ dolžine N , iz zaporedja vektorjev \mathbf{y} z elementi y_i skonstruiramo Q -dimenzionalni prostor, napet na zaporedje vektorjev $\mathbf{y}(t)$ dolžine $N - Q$:

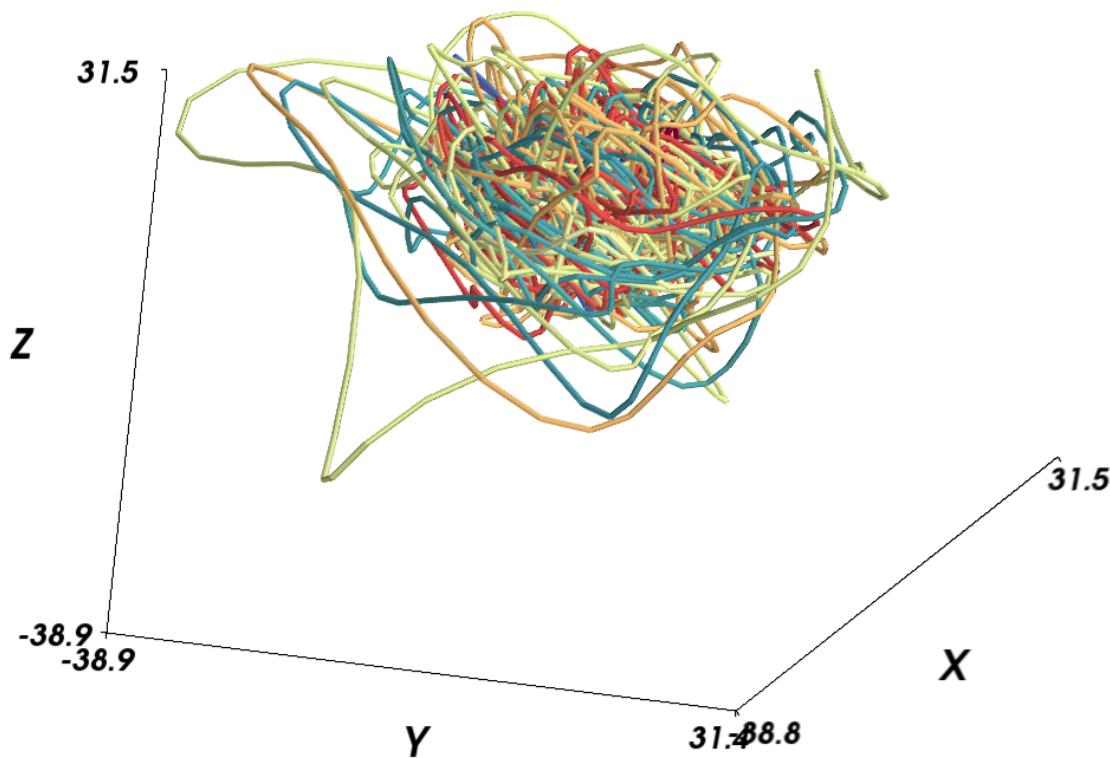
$$\begin{aligned}\mathbf{y}(t) &= \{y_i; i = 0, 1, \dots, Q - 1\} , \\ y_i &= x(t + i \cdot D_{\text{smp}}) ,\end{aligned}\tag{9.1}$$

kjer je D_{smp} časovna zakasnitev, Q pa vložitvena dimenzija. Ko je fazni prostor rekonstruiran, lahko izračunamo ocene koeficientov Ljapunova in korelacijske dimenzijske. Pri rekonstrukciji faznega prostora je potrebno paziti, da je izbrana časovna zakasnitev dovolj



Slika 9.1: Primer rekonstruiranega faznega prostora s premajhno časovno zakasnitvijo

velika. V primeru premajhne zakasnitve se namreč lahko zgodi, da se točke v faznem prostoru dimenzijsi Q ne razporedijo v vseh smereh enakomerno. Pri $Q = 3$ se tako na primer lahko razporedijo okrog neke ravnine ali celo premice. Primer prostora, dobljenega s premajhno časovno zakasnitvijo, je prikazan na sliki 9.1. Do tega pojava pride zato, ker so si zaporedne vrednosti v časovni vrsti običajno precej blizu. To težavo lahko rešimo tako,



Slika 9.2: Primer rekonstruiranega faznega prostora, kjer je časovna zakasnitev enaka prvemu prehodu preko ničel avtokorelacije

da kot zakasnitev pri gradnji faznega prostora uporabimo položaj prvega prehoda preko ničle avtokorelacije [40], torej izberemo tak zamik, da položaj točk v faznem prostoru v eni dimenziji ni koreliran z njihovim položajem v kateri koli drugi dimenziji. Primer takšnega rekonstruiranega faznega prostora je prikazan na sliki 9.2.

9.1.1 Maksimalni eksponent Ljapunova

Z maksimalnim eksponentom Ljapunova lahko ocenimo količino kaosa v sistemu. Maksimalni eksponent Ljapunova predstavlja maksimalno „hitrost“, s katero se različna, a skoraj enaka stanja v sistemu, razhajajo. Maksimalni eksponent Ljapunova, λ , predstavlja hitrost, kako hitro ena trajektorija v dani točki konvergira k drugi, ki ji je poljubno blizu:

$$\lambda = \lim_{t \rightarrow \infty} \lim_{\|\Delta \mathbf{y}_0\| \rightarrow 0} \frac{1}{t} \log \frac{\|\Delta \mathbf{y}_t\|}{\|\Delta \mathbf{y}_0\|} , \quad (9.2)$$

kjer $\|\Delta \mathbf{y}_0\|$ predstavlja evklidsko razdaljo med dvema stanjema sistema ob poljubnem času t_0 , $\|\Delta \mathbf{y}_t\|$ pa predstavlja evklidsko razdaljo med stanjem v nekem kasnejšem času t . Pri vhodnih podatkih končne dolžine z dodanim šumom lahko maksimalni eksponent Ljapunova le ocenimo, pri čemer je natančnost ocene odvisna od števila vzorcev v časovni vrsti ter od vložitvene dimenzije. Za dobro oceno maksimalnega eksponenta Ljapunova, mora biti korelacija zakasnjenih vzorcev majhna. Zato smo za časovno zakasnitev, D_{smp} , vzeli lokacijo prvega prehoda preko ničle koeficientov $\tau_{R_{xx}}$ avtokorelacije $R_{xx}(\tau)$ signala $x(t)$ [40]. Vložitvena dimenzija, Q , mora biti večja od števila pričakovanih dejavnikov, ki vplivajo na obnašanje sistema [40]. Preprosto, brez kakršnih koli dokazov, smo privzeli, da je delovanje maternice mogoče opisati s tremi dejavniki in tako izbrali vložitveno dimenzijo $Q = 7$.

9.1.2 Korelacijska dimenzija

Korelacijska dimenzija, D_{corr} , je ocena kompleksnosti dane časovne vrste. Je prenosorazmerna z verjetnostjo, da je razdalja med dvema točkama na trajektoriji manjša od nekega r ,

$$D_{\text{corr}} = \lim_{r \rightarrow 0} \frac{\log(C(r))}{\log(r)} , \quad (9.3)$$

kjer je

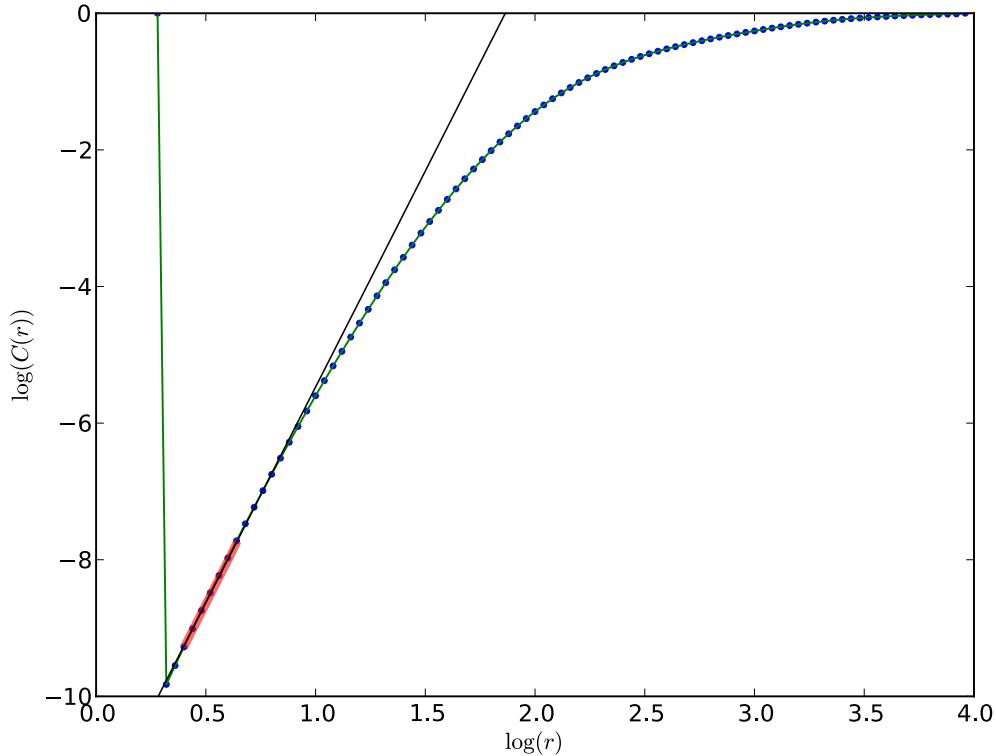
$$C(r) = \lim_{k \rightarrow \infty} \frac{1}{k^2} \sum_{i=1}^k \sum_{j=i+1}^k \Theta(r - |\mathbf{y}(i) - \mathbf{y}(j)|) , \quad (9.4)$$

in

$$\Theta(r - |\mathbf{y}(i) - \mathbf{y}(j)|) = \begin{cases} 1 & : (r - |\mathbf{y}(i) - \mathbf{y}(j)|) \geq 0 \\ 0 & : (r - |\mathbf{y}(i) - \mathbf{y}(j)|) < 0 \end{cases} . \quad (9.5)$$

Za izračun λ_{\max} in D_{corr} , smo uporabili metodo, opisano v [40]. Ker metoda vrne zaporedje parov vrednosti $\log(r)$ in $\log(C(\log(r)))$, prava vrednost pa bi se nahajala v točki, kjer gre r proti 0, smo za oceno korelacijske dimenzije uporabili vrednost naklona premice

na grafu $\log(C(\log(r)))$ tako, da so bili kvadrati odstopanj premice od izračunanih točk na grafu od 10. do 4. najmanjše vrednosti $\log(r)$ čim manjši. Graf $\log(C(\log(r)))$ je prikazan na sliki 9.3



Slika 9.3: Prikaz ocene korelacijske dimenzije signala EMG maternice pri $Q = 7$, zamik $D_{\text{smp}} = 11$ je enak prvemu prehodu preko ničle koeficientov avtokorelacije signala. Za oceno korelacijske dimenzije uporabimo naklon premice, potegnjene med označenimi točkami.

9.2 Vzorčna entropija

Vzorčna entropija je tehnika za oceno naključnosti časovnih vrst. Doslej je bila uporabljena na srčnih medutripnih časih, pri katerih je z uporabo vzorčne entropije mogoče ločiti med posnetki EKG bolnikov in zdravih ljudi [14]. Vzorčna entropija predstavlja nasprotno vrednost logaritma verjetnosti, da će se je znotraj časovne vrste že pojavilo dano podzaporedje te časovne vrste dolžine $m - 1$, potem se je pojavilo tudi podzaporedje te časovne vrste

dolžine m . Pri tem se smatra, da se je podzaporedje ponovilo, če so vsi elementi v ponovljenem podzaporedju dovolj podobni elementom v začetnem podzaporedju. En vzorec je dovolj podoben drugemu, če je absolutna razlika med njima manjša od r .

9.2.1 Klasični pristop

Običajni algoritem za štetje ponovitev ima časovno zahtevnost $O(N^2)$, kjer je N dolžina časovne vrste. Algoritem 9.2.1 deluje tako, da postopoma označuje ujemajoča se podzaporedja znotraj časovne vrste. V vsaki iteraciji išče podzaporedja, ki se končajo z vzorcem, dovolj podobnim trenutnemu. Najprej s sprehodom čez časovno vrsto poišče vse vzorce, ki se od prvega vzorca razlikujejo za manj kot r . Tako se ustvarijo ujemajoča se podzaporedja dolžine 1. Nato trenutni vzorec postane drugi; algoritem se sprehodi od drugega elementa časovne vrste do konca in spet poišče vse elemente, ki so dovolj podobni trenutnemu. V primerih, kjer so bila že najdena krajsa podzaporedja, se le-ta podaljšajo. V ostalih primerih se začnejo nova podzaporedja dolžine ena. Pri tistih elementih, ki trenutnemu niso dovolj podobni, se dolžine podzaporedij nastavijo nazaj na 0. Nato se kot trenutni element izbere tretji vzorec v časovni vrsti in postopek se ponovi. Število podzaporedij dane dolžine m se potem shrani v števca $J(m)$ in $K(m)$. Števca se razlikujeta le v tem, da se v $K(m)$ ne upoštevajo podzaporedja, ki se končajo z zadnjim vzorcem v časovni vrsti. Vzorčna entropija se na koncu izračuna kot:

$$\text{sampEn}(x, m, r) = -\log \left(\frac{J(m)}{K(m-1)} \right) . \quad (9.6)$$

9.2.2 Novi pristop

Včasih je zaželeno, da bi se vzorčna entropija računala še med snemanjem. Nekatere raziskave namreč kažejo, da se utegne vzorčna entropija EMG maternice ob umetnem sproženju poroda spremeniti [46]. Na žalost je drseče računanje vzorčne entropije časovno precej potratno, še posebej, če se poslužimo naivne rešitve s premikajočim se oknom in uporabo algoritma s časovno zahtevnostjo $O(N^2)$. Namesto, da bi za vsak vzorec izvedli sprehod čez celotno časovno vrsto, si lahko pomagamo s seznamom indeksov vseh vzorcev v časovni vrsti, urejenih po velikosti vzorca. Iskanje po tem seznamu in dodajanje vzorcev v seznam imata oba časovno zahtevnost $O(\log(N))$. Tako lahko dovolj hitro najdemo množico vzorcev, ki se od danega vzorca razlikujejo za manj kot r . Če ustvarimo seznam takšnih množic za zadnjih m vzorcev, lahko ujemajoča se podzaporedja poiščemo z iskanjem presekov med

množicami. Nato samo še preštejemo elemente v preseku vseh m množic vzorcev. V primeru, da je število ujemajočih se vzorcev v časovni vrsti v primerjavi s samo dolžino vrste majhno, bo tipična časovna zahtevnost novega algoritma za računanje vzorčne entropije $O(N \cdot \log(N))$. Seveda je algoritem 9.2.2 bolj zapleten od starega, saj je pri štetju ujemanj potrebno držati seznam prejšnjih vzorcev, da lahko za nazaj pobrišemo le tista ujemanja, kjer je to potrebno. Poleg tega je pametno, da razliko med J in K izračunamo posebej tako, da šele na koncu preštejemo podvzorce, ki se končajo z elementom, dovolj podobnim zadnjemu vzorcu.

Constants:

M ▷ Maksimalna dolžina iskanih podzaporedij

Variables:

$J(1 \dots M) = [0, \dots, 0]$ ▷ Števec ujemanj podzaporedij dolžine m

$K(1 \dots M) = [0, \dots, 0]$ ▷ Števec ujemanj, brez upoštevanja zadnjega vzorca $x(N - 1)$

$runs(0 \dots N - 1) = [0, \dots, 0]$ ▷ Tabela z dolžinami ujemanj za vsak vzorec

$runs_{old}(0 \dots N - 1) = [0, \dots, 0]$ ▷ Ujemanja prejšnje iteracije

Input:

$x(0 \dots N - 1)$ ▷ Časovna vrsta dolžine N

m ▷ Dolžina iskanih podzaporedij

r ▷ Dovoljeno odstopanje pri ujemanjih

Output:

$sampEn$ ▷ Vzorčna entropija signala x za parametra m in r

procedure SAMPEN($x(0 \dots N - 1), m, r$)

for $i = 0$ **to** $N - 2$ **do** ▷ Za vsak vzorec

for $j = i$ **to** $N - 1$ **do** ▷ se sprehodimo po kasnejših vzorcih

$jj = j - i$ ▷ in ko najdemo ujemanja

if $|x(j) - x(i)| < r$ **then** ▷ podaljšamo podzaporedja

$runs(jj) = runs_{old}(jj) + 1$ ▷ do nekega maksimalnega m .

for $m = 1$ **to** $\min(M, ujemanja(jj))$ **do** ▷ Povečamo števca J

$J(m) = J(m) + 1$ ▷ in K , če ne gre za zadnji vzorec.

$K(m) = K(m) + 1$

endif

endfor

else

$runs(jj) = 0$ ▷ Če ni ujemanj, se podzaporedja končajo.

endif

endfor

$runs_{old} = ujemanja$ ▷ Dolžine podzaporedij si med iteracijami zapomnimo

endfor

$K = [N \cdot (N - 1)/2, K(1 \dots M - 1)]$ ▷ K zamaknemo za 1 in dodamo vrednost pri $m = 0$

$e) = \log(J/K)$ ▷ $e(m) = J(m)/K(m - 1)$

$sampEn = e(m)$

endprocedure

Algoritem 9.2.1: Stari algoritem za izračun vzorčne entropije

```

1: Constants:
2:    $M$                                      ▷ Maksimalna dolžina iskanih podzaporedij
3: Variables:
4:    $S = \text{SkipList}(x, i)$                 ▷ Preskakajoči seznam
5:    $J(1 \dots M) = [0, \dots, 0]$              ▷ Števec ujemanj podzaporedij dolžine  $m$ 
6:    $K_d(1 \dots M) = [0, \dots, 0]$             ▷ Števec ujemanj z zadnjim vzorcem  $x(N - 1)$ 
7:    $\text{runs}(0 \dots N - 1) = [0, \dots, 0]$     ▷ Tabela z dolžinami ujemanj za vsak vzorec
8:    $\text{runs}_{\text{old}}(0 \dots N - 1) = [0, \dots, 0]$  ▷ Ujemanja prejšnje iteracije

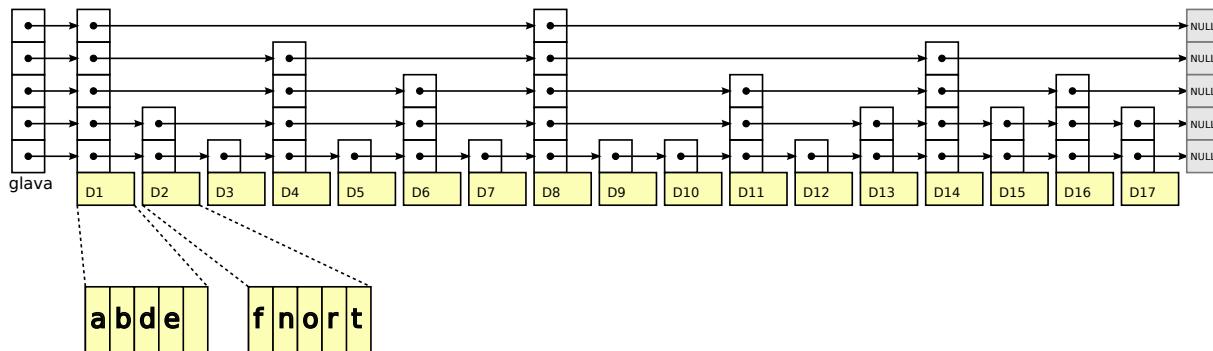
9: Input:
10:   $x(0 \dots N - 1)$                       ▷ Časovna vrsta dolžine  $N$ 
11:   $m$                                      ▷ Dolžina iskanih podzaporedij
12:   $r$                                      ▷ Dovoljeno odstopanje pri ujemanjih

13: Output:
14:   $\text{sampEn}$                            ▷ Vzorčna entropija signala  $x$  za parametra  $m$  in  $r$ 
15: procedure SAMPEN( $x(0 \dots N - 1), m, r$ );
16:   for  $i = 0$  to  $N - 1$  do           ▷ Za vsak vzorec
17:     for  $j = 1$  to  $M$  do           ▷ pobrišemo ujemanja za stare vzorce
18:       if  $i \geq j$  then
19:         for  $pos$  in  $S(x(i - m) - r \dots x(i - m) + r)$  do
20:            $\text{runs}(pos) \leftarrow 0$ 
21:         endfor
22:       endif
23:     endfor
24:      $S.\text{insert}(x(i), i)$           ▷ Trenutni vzorec vstavimo v preskakajoči seznam
25:     for  $pos$  in  $S((x(i) - r) \dots (x(i) + r))$  do ▷ Za vzorce v  $S$ , ki so blizu trenutnemu
26:       if  $pos \neq i$  then           ▷ in niso trenutni vzorec
27:          $\text{runs}(pos) = \text{runs}_{\text{old}}(pos - 1) + 1$  ▷ povečamo dolžine podzaporedij
28:         for  $k = 1$  to  $\min(M, \text{runs}(pos))$  do
29:            $J(k) = J(k) + 1$ 
30:         endfor
31:       endif
32:     endfor
33:     if  $i = N - 1$  then           ▷ Za zadnji vzorec
34:       for  $pos$  to  $S((x(i) - r) \dots (x(i) + r))$  do ▷ Prestejemo ujemanja
35:         if  $pos \neq i$  then
36:           for  $k = 1$  to  $\min(M, \text{runs}(pos))$  do
37:              $K_d(k) = K_d(k) + 1$           ▷ In jih spravimo v  $K_d$ 
38:           endfor
39:         endif
40:       endfor
41:     endif
42:      $\text{runs}_{\text{old}} = \text{runs}$ 
43:   endfor
44:    $K = [N \cdot (N - 1)/2, J(1 \dots M - 1) - K_d(1 \dots M - 1)]$ 
45:    $e = -\log(J/K)$                   ▷  $K$  je že za eno zamaknjen
46:    $\text{sampEn} = e(m)$ 
47: endprocedure

```

9.2.3 Preskakajoči sezname

Da bi bil čas izvajanja novega algoritma krajši od tistega, ki ga za izračun vzorčne entropije porabi stari algoritem, mora biti iskanje množice vzorcev M čim hitrejše. Pri hitrosti izvajanja je dobro upoštevati tudi vpliv zgrešitev v predpomnilniku. Poleg tega mora biti hiter tudi dostop do zaporednih, po velikosti urejenih vzorcev. Izkaže se, da so splošnonamenske implementacije različnih uravnoveženih dreves dovolj počasne, da se uporaba novega algoritma ne izplača. Za prikaz hitrosti delovanja je bilo torej nujno implementirati podatkovno strukturo, v kateri je časovna zahtevnost iskanja poljubnega elementa $O(\log(N))$, časovna zahtevnost iskanja naslednjega elementa od nekega znanega elementa pa je $O(1)$. Primer takšne strukture so preskakajoči sezname [47]. Shema preskakajočega signala je prikazana na sliki 9.4.



Slika 9.4: Ilustracija vozlišč v preskakajočem seznamu, prilagojenem procesorjem s hitrim predpomnilnikom. V vsakem vozlišču je spravljena urejena tabela elementov. Vsa vozlišča niso nujno povsem zapolnjena.

Preskakajoči sezname so razširitev urejenih povezanih seznamov, kjer so v nekaterih vozliščih poleg povezave do naslednjega vozlišča v seznamu prisotne tudi povezave nekaj vozlišč naprej. Lahko si predstavljamo, da je preskakajoči seznam sestavljen iz več nivojev navadnih povezanih seznamov. V najvišjem nivoju je le prvo vozlišče. En nivo nižje sta v povprečju dve vozlišči - prvo in neko vozlišče, ki je blizu sredine seznama. Še en nivo nižje so vozlišča že štiri, enakovrno razporejena po seznamu, in tako naprej do prvega nivoja, na katerem so povezana vsa zaporedna vozlišča. Preskoki v seznamu se gradijo tako, da se ob vstavljanju vsakega novega elementa najprej izračuna njegova višina. Višina se določi kot logaritem naključnega števila med 1 in N , kjer je N število elementov v seznamu. Nato se element vstavi v povezane sezname na vseh nivojih do svoje višine, po potrebi se popravi tudi višina oz. prvega elementa povezanega seznama. Odstranjevanje elementa je

prav tako podobno odstranjevanju iz več povezanih seznamov. Časovna zahtevnost obeh operacij je $O(\log(N))$, pri čemer je konstantni faktor zelo nizek. Iskanje poljubnega elementa oz. mesta, kamor je treba vstaviti novi element se v preskakajočem seznamu izvaja tako, da najprej v najvišjem nivoju poiščemo prvo vozlišče z elementom, ki je večji od iskanega. Nato se premaknemo za eno vozlišče nazaj, spustimo za en nivo in spet iščemo vozlišče, ki vsebuje element, ravno večji od iskanega. Ta postopek ponavljamo, dokler nismo dosegli najnižjega nivoja. Če so preskakajoče povezave v vsakem nivoju razporejene enakomerno, je časovna zahtevnost iskanja elementa v seznamu $O(\log(N))$. Da bi se preskakajoči seznam izrodil, bi bilo iz njega potrebno odstraniti vsa vozlišča z večjimi višinami, ali pa izbrati zelo slabo funkcijo za naključno izbiranje višine vstavljanega vozlišča. V resničnih razmerah je takšen scenarij malo verjeten in ga lahko zanemarimo. Na sodobnih mikroprocesorjih pomembno vlogo pri hitrosti izvajanja programov igra predpomnilnik. Zgrešitve v predpomnilniku so namreč dovolj drage, da se za shranjevanje urejene množice števil pri majhnih naborih podatkov (na primer manj kot 5000 števil) bolj izplača uporabiti navadno urejeno tabelo, kot pa urejen povezani seznam. Pri večjih naborih podatkov in pogostem vstavljanju se seveda uporaba urejenih tabel izkaže za neupravičeno. Za dober kompromis se izkaže uporaba povezanih seznamov, kjer vsako vozlišče v seznamu vsebuje urejeno tabelo. Ta pristop je seveda mogoče uporabiti tudi pri preskakajočih seznamih. V takšnem seznamu se novo vozlišče ustvari takrat, ko v neko že obstoječe in povsem polno vozlišče dodamo nov element - takrat namreč polno vozlišče razbijemo tako, da ustvarimo novo vozlišče in iz originalnega vanj skopiramo vse elemente, ki so večji od vstavljanega. Preskakajoči sezname z urejenimi tabelami v vozliščih so se izkazali za zelo uporabno podatkovno strukturo, ki omogoča hitro iskanje, vstavljanje in odstranjevanje po velikosti urejenih podatkov. Prav zahvaljujoč njihovim lastnostim je novi algoritem za izračun vzorčne entropije lahko hitrejši od starega na vseh uporabljenih naborih podatkov.

9.2.4 Primerjava hitrosti izvajanja algoritmov za izračun vzorčne entropije

Čas izvajanja novega algoritma je, za razliko od starega, močno odvisen ne samo od količine vhodnih podatkov, temveč tudi od tega, kako pogosto se vrednosti v vhodnih podatkih ponavljajo. Da bi ocenili meje hitrosti izvajanja novega algoritma, smo ga pognali na različnih vhodnih podatkih:

- Na podatkih, priloženih implementaciji starega algoritma za izračun vzorčne entropije;

- na naključno izbranih posnetkih EMG maternice iz naše baze;
- na najdaljšem dostopnem posnetku EMG maternice, dobljenem iz drugega vira [46];
- na umetno ustvarjenem vhodu, pri katerem je pričakovani čas izvajanja novega algoritma čim krajsi;
- na umetno ustvarjenem vhodu, pri katerem je pričakovani čas izvajanja novega algoritma čim daljši.

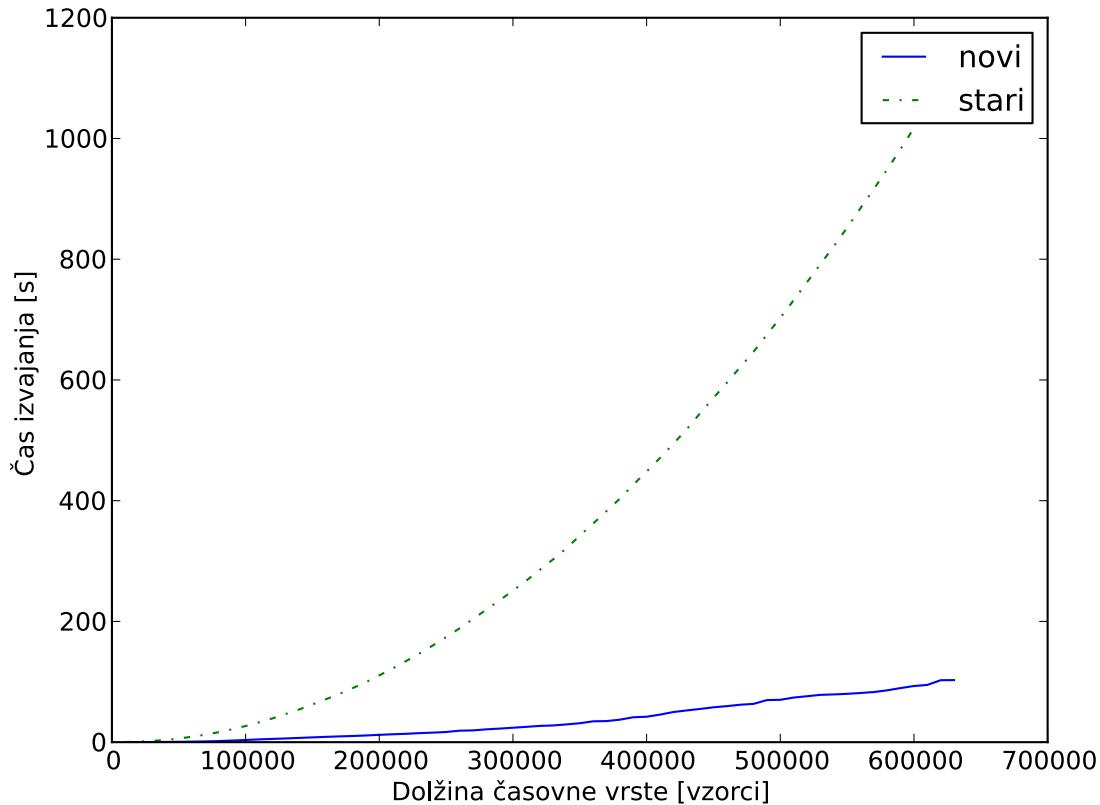
Hitrost novega algoritma na majhnih naborih vhodnih podatkov

Pri preizkušanju novega algoritma na relativno majhnih naborih vhodnih podatkov, kakršni so na primer priloženi implementaciji starega algoritma za izračun vzorčne entropije ali tipični 30-minutni posnetki EMG maternice, smo se soočili z manjšo težavo. Algoritem namreč tovrstne vhodne podatke obdela tako hitro, da je čas izvajanja algoritma kratek v primerjavi s časom branja podatkov z diska in s časom, potrebnim za nalaganje in zagon programa. Stari algoritem se izvaja precej počasneje, tako da tovrstnih problemov z oceno časa, potrebnega za njegovo izvajanje, ni.

Hitrost novega algoritma na večjih naborih vhodnih podatkov

Za test hitrosti izračuna vzorčne entropije na tipičnih vhodnih podatkih, smo novi in stari algoritem uporabili na različno dolgih odsekih najdaljšega nam dostopnega signala EMG maternice. Signal vsebuje 635386 vzorcev.

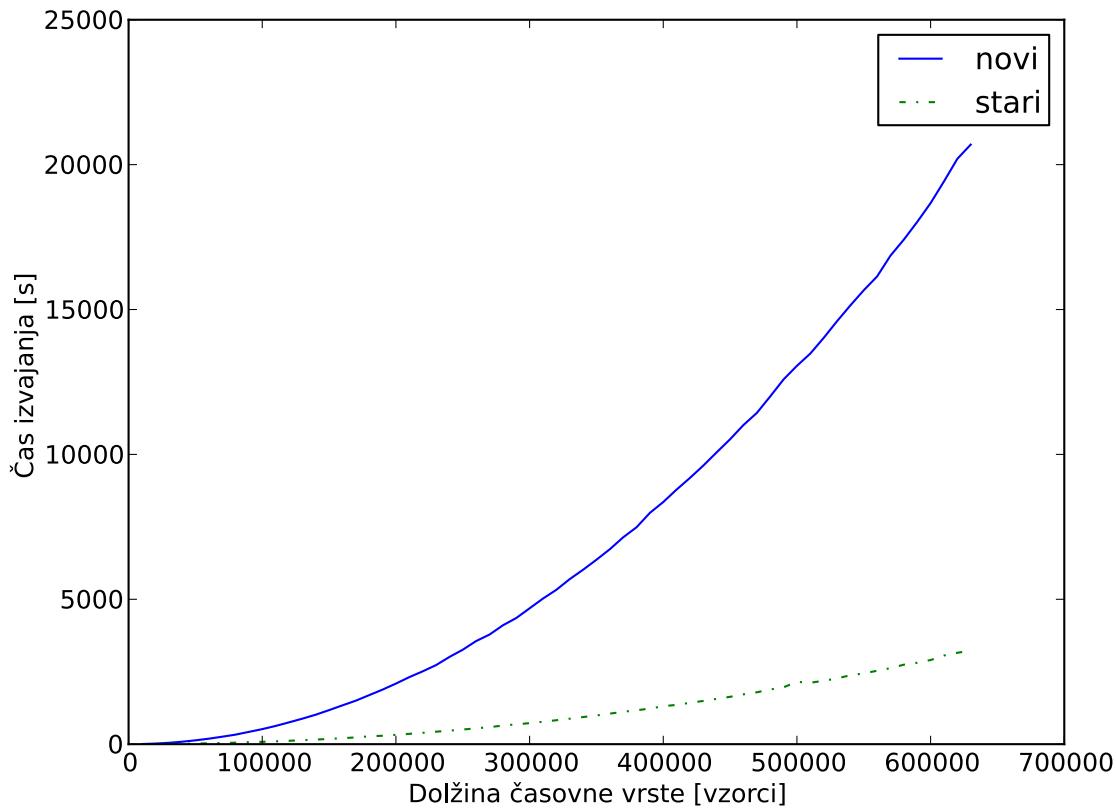
Primerjava hitrosti izvajanja starega in novega programa na odsekih različnih dolžin je prikazana na sliki 9.5 Naša predvidevanja o časovni zahtevnosti novega algoritma so se izkazala za pravilna. Krivulja časa izvajanja novega algoritma v odvisnosti od količine vhodnih podatkov je podobna premici oz. krivulji, ki jo opiše funkcija $N \cdot \log(N)$. Krivulja časa izvajanja starega algoritma je podobna kvadratni funkciji. Očitno je novi algoritem hitrejši od starega, pri izračunu vzorčne entropije za celoten posnetek je pohitritev več kot desetkratna. Krivulja časa izvajanja novega algoritma v odvisnosti od količine podatkov ni gladka. Do neravnin pride deloma zaradi uporabe preskakajočih signalov, deloma pa tudi zaradi narave algoritma samega. V primeru, da je več vzorcev v časovni vrsti podobnih (in se razlikujejo za manj kot r), se bo namreč novi algoritem izvajal dlje časa. Vseeno je pri danem naboru podatkov očitno, da je krivulja časa izvajanja bolj podobna premici kot kvadratni funkciji.



Slika 9.5: Primerjava hitrosti izvajanja algoritmov za izračun vzorčne entropije na različno dolgih odsekih daljšega signala EMG maternice.

Hitrost novega algoritma v najslabšem primeru

V primeru, ko imajo vsi vzorci signala isto vrednost, je zahtevnost novega algoritma $O(N^2)$, saj je potrebno za vsak nov vzorec pregledati vse prejšnje. Ker je sprehod po preskakajočem seznamu precej počasnejši od sprehoda po navadni tabeli, je tudi čas izvajanja novega algoritma v tem primeru precej daljši od časa izvajanja starega, kar se lepo vidi na sliki 9.6. Vseeno so na srečo tovrstni podatki v naravi dovolj redki. Poleg tega je bil čas izvajanja novega algoritma le nekaj manj kot sedemkrat daljši od časa izvajanja originalnega algoritma.

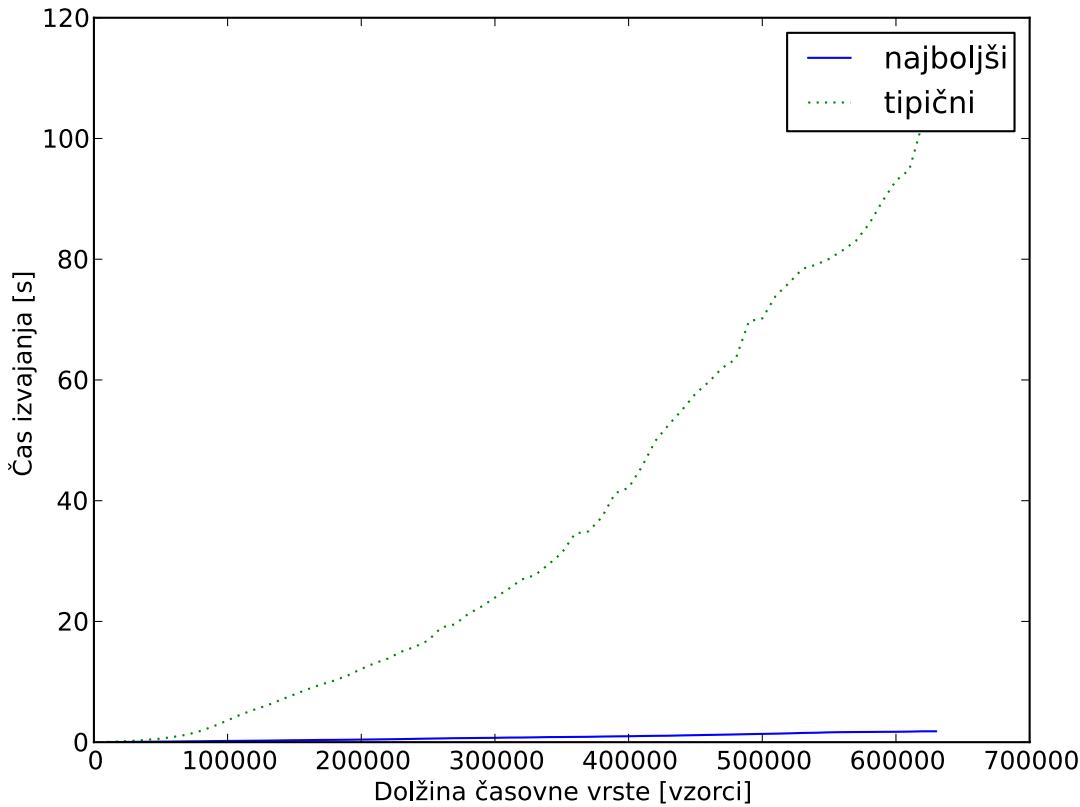


Slika 9.6: Primerjava hitrosti izvajanja novega in starega algoritma za izračun vzorčne entropije na umetnih podatkih, ki vsebujejo signal s konstantno vrednostjo (najslabših za novi algoritmom).

Hitrost novega algoritma v najboljšem primeru

V primeru, ko so vrednosti vseh vzorcev signala različne, je časovna zahtevnost novega algoritma $O(N \cdot \log(N))$, saj je časovna zahtevnost iskanja vzorcev v preskakajočem seznamu $O(\log(N))$. Kadar so vse vrednosti enake, je časovna zahtevnost novega algoritma $O(N^2)$, saj se algoritom pri štetju ujemanj za vsak vzorec sprehodi čez vse podatke, ki so prišli pred njim. V ostalih primerih je časovna zahtevnost algoritma nekje med tem dvojnim skrajnjima vrednostima.

Primerjava z originalnim algoritmom bi bila zaradi prevelike izboljšave v tem primeru brez smisla, zato sta na sliki 9.7 izrisani krivulji časov izvajanja novega algoritma na tipičnih vhodnih podatkih ter na vhodnih podatkih iste dolžine, kjer so bili vsi vzorci različni. Na



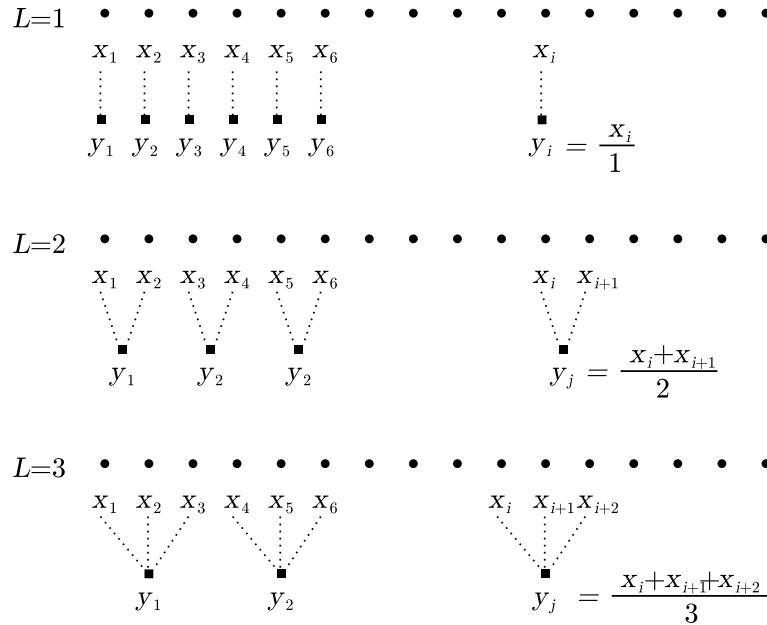
Slika 9.7: Primerjava hitrosti izvajanja novega algoritma za izračun vzorčne entropije na različno dolgih odsekih signalov EMG maternice ter na umetnih podatkih, ki vsebujejo signal, kjer se noben vzorec ne ponovi (najboljših za novi algoritem).

sliki 9.7 je lepo vidno, da je čas izvajanja novega algoritma res odvisen tudi od narave vhodnih podatkov.

9.2.5 Večločljivostna vzorčna entropija

Večločljivostna vzorčna entropija je razširitev običajne vzorčne entropije. S pomočjo večločljivostne vzorčne entropije je mogoče oceniti, kako kompleksna je časovna vrsta. V ta namen se najprej izračuna vzorčna entropija časovne vrste. Nato se iz dane časovne vrste ustvari nova, L -krat krajsa tako, da se izračuna povprečna vrednost vseh L vzorcev v originalni časovni vrsti, nakar se povprečja uporabi kot novo časovno vrsto, kot je prikazano na sliki 9.8. Iz sprememb vzorčne entropije glede na razmerje L lahko sklepamo o kompleksnosti

časovne vrste [15]. Vzorčno entropijo torej lahko smatramo za poseben primer večločljivostne vzorčne entropije pri $L = 1$.



Slika 9.8: Prikaz povprečenja pri izračunu večločljivostne vzorčne entropije

POGLAVJE 10

Statistična analiza pridobljenih cenilk

Da bi bila neka lastnost uporabna za klasifikacijo vzorcev, se morajo vzorci iz različnih razredov po dani lastnosti razlikovati. V primeru, da je lastnost predstavljena kot številčna vrednost, mora biti le-ta za vzorce, ki pripadajo različnim razredom, različna. Za oceno, ali se povprečna vrednost dane lastnosti za neko skupino vzorcev razlikuje od povprečne vrednosti iste lastnosti za drugo skupino vzorcev, lahko uporabimo statistične metode.

10.1 Studentov t-test

V primeru, da vrednosti neke cenilke za eno skupino vzorcev niso drugačne kot za drugo, bo matematično upanje razlik povprečnih vrednosti cenilk enako nič. Verjetnost, da je povprečna vrednost cenilke za dve skupini enaka nič lahko torej uporabimo kot oceno primernosti cenilke za ločevanje skupin. Če je verjetnost, da je razlika povprečnih vrednosti različna od nič, majhna, je cenilka bržkone uporabna za ločevanje med skupinama. Za oceno verjetnosti, da se povprečni vrednosti poljubne cenilke za izbrani skupini posnetkov razlikujeta, smo uporabili Studentov t-test.

Pri Studentovem t-testu za ničelno hipotezo privzamemo, da je razlika povprečnih vrednosti cenilke za dane vzorce enaka nič. Za neodvisni skupini A z N_A vzorci in B z N_B vzorci smo najprej ocenili matematični upanji izbranih vzorcev

$$E_A = \frac{1}{N_A} \sum_{i=1}^N A_i \quad (10.1)$$

in

$$E_B = \frac{1}{N_B} \sum_{i=1}^N B_i , \quad (10.2)$$

varianci V_A in V_B ter stopnje prostosti $\nu = N_A + N_B - 2$. Nato smo ocenili skupno varianco

$$V_s = \frac{(N_A - 1)V_A + (N_B - 1)V_B}{\nu} , \quad (10.3)$$

Nato smo določili statistiko

$$t = \frac{|E_A - E_B|}{\sqrt{V_s(\frac{1}{N_A} + \frac{1}{N_B})}} . \quad (10.4)$$

V primeru, kjer sta bila med nosečnostjo zajeta dva posnetka, smo uporabili Studentov t-test za vezane vzorce. Za vsako nosečnost smo izračunali razliko v vrednosti cenilk pri prvem in drugem posnetku, D in varianco razlik, V_D . Nato smo določili statistiko

$$t = \frac{E_D}{\sqrt{\frac{V_D}{N}}} . \quad (10.5)$$

Na koncu smo določili verjetnost, da je razlika povprečnih vrednosti enaka nič,

$$p = \frac{\Gamma(\frac{\nu+1}{2})}{\sqrt{\pi\nu}\Gamma(\frac{\nu}{2})(1 + \frac{x^2}{\nu})^{\frac{\nu+1}{2}}} , \quad (10.6)$$

kjer je Γ gama funkcija,

$$\Gamma(z) = \int_0^\infty t^{z-1} e^{-t} dt . \quad (10.7)$$

Cenilko smo označili kot obetavno, če dobljena verjetnost p ni presegla 0.05.

10.1.1 Analiza variance

Za primerjavo več kot dveh skupin vzorcev Studentov t-test ni primeren. V teh primerih običajno uporabimo analizo variance (ANOVA). Podobno kot pri Studentovem t-testu je potrebno testirati ničelno hipotezo, da so povprečne vrednosti izbrane cenilke za vse skupine vzorcev enake. Izkaže se, da je analiza variance za dve skupini matematično ekvivalentna Studentovemu t-testu [48]. Zato smo za oceno primernosti tehnik povsod uporabili Studentov t-test.

10.2 Strategija evaluacije uporabljenih tehnik

Eden izmed namenov raziskave, opisane v tem delu, je bil preveriti primernost čim večjega števila različnih metod obdelave signalov EMG maternice za napovedovanje prezgodnjega poroda. Zaradi velikega števila različnih tehnik se je pojavilo vprašanje, ali se sploh izplača graditi in preverjati klasifikatorje na osnovi vseh pridobljenih cenilk. Poleg tega nekatere

tehnike zahtevajo tudi izbiro dodatnih parametrov, ki jih ne poznamo vnaprej. Takšne so vse nelinearne tehnike, opisane v tem delu. Zaradi dodatnih parametrov se je število dobljenih cenilk precej povečalo.

Namesto, da bi zgradili kup različnih klasifikatorjev in ocenili njihovo uspešnost, smo raje najprej poiskali tiste tehnike, pri katerih so se pri uporabi Studentovega t-testa pokazale statistične razlike med skupinami posnetkov, v katere bi posnetke radi razvrščali. Ročno smo tudi pregledali dobljene razporeditve cenilk glede na trajanje nosečnosti ob zajemu posnetka in glede na celotno trajanje nosečnosti.

Šele nato smo na osnovi najbolj perspektivnih cenilk zgradili klasifikatorje in ocenili njihovo uspešnost.

10.3 Skupine posnetkov

Posnetke, uporabljene v raziskavi, smo zajemali na splošni populaciji nosečnic. Ker do prezgodnjega poroda pride v manj kot 8% primerov [1], je tudi posnetkov, povezanih s prezgodnjimi porodi, manj kot desetina vseh. Vseh nosečnosti v bazi podatkov je 760. Različnih nosečnosti, med katerimi so bili zajeti posnetki, je bilo 692. Ker je bilo zbiranje posnetkov dolgotrajno, sta bili dve nosečnici v raziskavo vključeni dvakrat - različnih nosečnic je bilo torej 690. Pri nekaterih nosečnostih niso bili zbrani vsi potrebni podatki. Tako ponekod na primer ni znan predvideni datum poroda ali datum poroda, ali pa je eden od teh podatkov očitno napačen. Nosečnosti, kjer so bili zbrani vsi potrebni podatki, je v bazi 741. Na žalost pri nekaterih nosečnostih ni bil zajet noben posnetek, ali pa je bil posnetek sicer zajet, vendar se je izgubil podatek, na katero nosečnost se nanaša. Pri nekaterih posnetkih je bil zapisan napačen datum zajema posnetka.

V bazi se nahaja 1211 posnetkov, vendar jih je le 1187 povezanih z nosečnostmi. Posnetkov, kjer so zbrani vsi potrebni spremmljajoči podatki - se pravi podatki o nosečnosti in smiseln datum zajema posnetka, je 1165. Nosečnosti, na katere se nanaša teh 1165 posnetkov, je 677. Med temi nosečnostmi so tudi nosečnosti obeh mater, ki sta bili v raziskavo vključeni dvakrat - različnih nosečnic, za katere smo zbrali potrebne spremmljajoče podatke, je bilo torej 675.

Vse posnetke smo ročno pregledali, pri čemer med pregledovanjem nismo vedeli, na katero nosečnost se kateri posnetek nanaša. Pri pregledu smo vsakega od kanalov ocenili z oceno od 1 do 4. Zagotovo slabe kanale smo ocenili z 1, verjetno slabe z 2, verjetno dobre s 3 in zagotovo dobre s 4.

Med vsemi posnetki jih je le 695 takšnih, da so bili za povsem dobre ocenjeni vsi kanali. Devet je takšnih, da so povsem dobri le prvi trije kanali, na kanalih, na katere bi bil lahko priklopljen tokograf, pa so prisotne motnje.

Med 695 povsem dobrimi posnetki jih je 678 takšnih, da so bili zajeti med nosečnostmi, kjer so bili zbrani vsi potrebni spremljajoči podatki. Posnetkov, zajetih med nosečnostmi z zbranimi spremljajočimi podatki, kjer so dobri prvi trije kanali, je 687.

Med vsemi posnetki je bilo 760 takšnih, da so bili prvi trije kanali ocenjeni kot verjetno dobri in so bili zajeti med 532 nosečnostmi, za katere so bili tudi zbrani potrebni spremjevalni podatki. Med temi posnetki je tudi 53 posnetkov, pri katerih je bila s pomočjo tokografa zajeta tudi ocena tlaka v maternici.

Eden izmed namenov raziskave je bil oceniti primernost cenilk za ločevanje skupin posnetkov glede na trajanje nosečnosti. Nekateri posnetki so bili zajeti med nosečnostmi, kjer je bil porod prezgoden. Drugi posnetki so bili zajeti med nosečnostmi, kjer je bil porod ob roku. Glede na trajanje nosečnosti smo torej dobili dve skupini. Iz obeh smo izločili posnetke, zajete med nosečnostmi, kjer je bil porod sprožen ali pa je bil izveden carski rez. Tako nam je ostalo 547 posnetkov iz 382 nosečnosti. Med temi posnetki je ostalo vseh 53 posnetkov, kjer je bila zajeta tudi ocena tlaka v maternici.

Za oceno primernosti izbranih cenilk za ločevanje med skupinami posnetkov smo nažrebali množico posnetkov, v kateri se na vsako nosečnost nanaša natanko en posnetek. Pri tem smo posnetke žrebali tako, da bi bilo število tistih, zajetih pred 26. tednom nosečnosti čim bolj podobno številu tistih, zajetih po 26. tednu nosečnosti. Nato smo sestavili še skupino parov posnetkov za tiste nosečnosti, kjer sta bila med nosečnostjo narejena dva posnetka - eden pred in eden po 26. tednu nosečnosti.

Vsak posnetek smo uvrstili v eno izmed dveh skupin glede na trajanje nosečnosti in v eno izmed dveh skupin glede na čas zajema posnetka. Vsak posnetek tako spada v eno izmed štirih skupin:

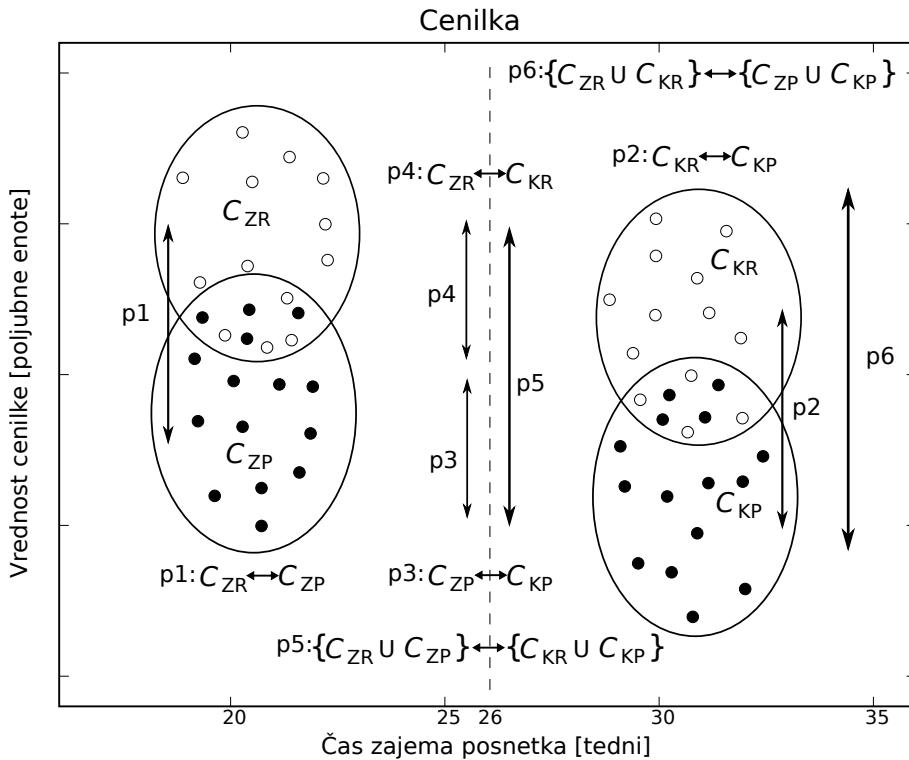
1. <26-PRE (ZP, zgodaj, prezgodnji) - posnetki, zajeti pred 26. tednom nosečnosti, kjer je bil porod prezgoden - torej pred 37. tednom nosečnosti.
2. >=26-PRE (KP, kasneje, prezgodnji) - posnetki, zajeti v 26. tednu nosečnosti ali kasneje, kjer je bil porod pred 37. tednom nosečnosti.
3. <26-TERM (ZR, zgodaj, ob roku) - posnetki, zajeti pred 26. tednom nosečnosti, kjer je bil porod v 37. tednu nosečnosti ali kasneje.

Tabela 10.1: Števila posnetkov v izžrebanih skupinah

Raziskava	Skupina	Št. nosečnosti	Št. posnetkov
Posnetki z verjetno dobrimi prvimi tremi kanali	<26-PRE (ZP)	38	38
	>=26-PRE (KP)	33	40
	<26-TERM (ZR)	357	357
	>=26-TERM (KR)	307	325
Posnetki z verjetno dobrimi prvimi tremi kanali in s po dvema posnetkoma na nosečnost	<26-PRE (ZP)	16	16
	>=26-PRE (KP)	16	16
	<26-TERM (ZR)	187	187
	>=26-TERM (KR)	187	187
Posnetki z verjetno dobrimi prvimi tremi kanali in s po natanko enim posnetkom na nosečnost	<26-PRE (ZP)	25	25
	>=26-PRE (KP)	30	30
	<26-TERM (ZR)	233	233
	>=26-TERM (KR)	244	244
Posnetki z verjetno dobrimi prvimi tremi kanali brez carskih rezov ali induciranih porodov	<26-PRE (ZP)	27	27
	>=26-PRE (KP)	30	37
	<26-TERM (ZR)	244	244
	>=26-TERM (KR)	221	239
Posnetki z verjetno dobrimi prvimi tremi kanali, brez carskih rezov ali induciranih porodov z 1 posnetkom/nosečnost	<26-PRE (ZP)	19	19
	>=26-PRE (KP)	24	24
	<26-TERM (ZR)	163	163
	>=26-TERM (KR)	176	176
Posnetki z verjetno dobrimi prvimi tremi kanali, brez carskih rezov ali induciranih porodov z 2 posnetkoma/nosečnost	<26-PRE (ZP)	14	14
	>=26-PRE (KP)	14	14
	<26-TERM (ZR)	126	126
	>=26-TERM (KR)	126	126

4. ≥ 26 -TERM (KR, kasneje, ob roku) - posnetki, zajeti v 26. tednu nosečnosti ali kasneje, kjer je bil porod v 37. tednu nosečnosti ali kasneje.

Števila različnih posnetkov in nosečnosti za izžrebane skupine so povzeta v tabeli 10.1.



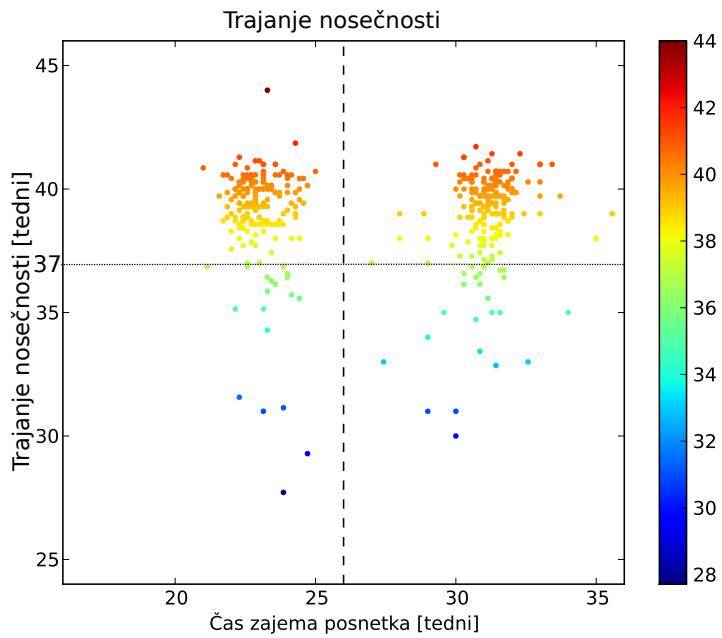
Slika 10.1: Simbolična predstavitev podskupin posnetkov z izračunanimi verjetnostmi. Označene so vrednosti poljubne cenilke za različne skupine - C_{ZP} za <26 -PRE, C_{KP} za ≥ 26 -PRE, C_{ZR} za <26 -TERM in C_{KR} za skupino ≥ 26 -TERM.

10.3.1 Skupina s po enim posnetkom na nosečnost

Za posnetke iz skupine, kjer je bil izžreban po en posnetek na nosečnost, smo potem naračunali verjetnosti, da so povprečne vrednosti cenilk za pare skupin enake. Izračunane verjetnosti so shematično predstavljene na sliki 10.1. Dejanska trajanja nosečnosti in časi zajema posnetkov za to skupino so predstavljeni na sliki 10.2.

Tako smo za vsako cenilko dobili 6 različnih verjetnosti:

1. p_1 - Verjetnost, da sta srednji vrednosti cenilke pri skupinah <26 -PRE in <26 -TERM enaki. Nizka vrednost p_1 pomeni, da sta že zgodaj v nosečnosti vrednosti cenilk za skupini posnetkov, ki se razlikujejo glede na to, ali je bil porod ob roku ali prezgoden, statistično različni.
2. p_2 - Verjetnost, da sta srednji vrednosti cenilke pri skupinah ≥ 26 -PRE in ≥ 26 -TERM enaki. Nizka vrednost p_2 pomeni, da sta pozno v nosečnosti vrednosti cenilk za skupini posnetkov, ki se razlikujejo glede na to, ali je bil porod ob roku ali prezgoden,



Slika 10.2: Časi snemanj in trajanja nosečnosti za skupino posnetkov s po enim posnetkom na nosečnost. Označena je meja med prezgodnjimi porodi in porodi ob roku. Vidne so skupine posnetkov: <26 -PRE (spodaj levo), ≥ 26 -PRE (spodaj desno), <26 -TERM (zgoraj levo) in ≥ 26 -TERM (zgoraj desno).

statistično različni.

3. p_3 - Verjetnost, da sta srednji vrednosti cenilke pri skupinah <26 -PRE in ≥ 26 -PRE enaki. Nizka vrednost p_3 pomeni, da se je povprečna vrednost cenilke med nosečnostjo spremenila pri posnetkih, kjer je bil porod pred rokom.
4. p_4 - Verjetnost, da sta srednji vrednosti cenilke pri skupinah <26 -PRE in ≥ 26 -PRE enaki. Nizka vrednost p_4 pomeni, da se je povprečna vrednost cenilke med nosečnostjo spremenila pri posnetkih, kjer je bil porod ob roku.
5. p_5 - Verjetnost, da sta srednji vrednosti cenilke pri skupini posnetkov, ki se razlikujejo glede na to, ali so bili zajeti pred 26. tednom ali kasneje, enaki. Nizka vrednost p_5 pomeni, da se je vrednost cenilke med nosečnostjo v povprečju pri vseh posnetkih spremenila.
6. p_6 - Verjetnost, da je srednja vrednost cenilke, izračunana skupaj za skupini <26 -PRE in ≥ 26 -PRE, enaka kot povprečna vrednost, naračunana skupaj za skupini

$<26\text{-TERM}$ in $\geq 26\text{-TERM}$. Nizka vrednost p_6 pomeni, da je povprečna vrednost cenilke pri posnetkih, kjer je bil porod prezgoden, drugačna kot pri posnetkih, kjer je bil porod ob roku.

Ker so raziskave drugih avtorjev [8] pokazale, da se lastnosti EMG maternice spremenijo, ko se približa čas poroda, smo posnetke nato razbili še na dve skupini glede na to, ali so bili zajeti manj ali več kot 9 tednov pred porodom. Tako smo za vse cenilke naračunali še verjetnost p_7 - se pravi verjetnost, da je povprečna vrednost cenilke za posnetke, zajete manj kot devet tednov pred porodom, enaka kot za posnetke, zajete več kot 9 tednov pred porodom.

Vse vrednosti cenilk in verjetnosti od p_1 do p_7 smo nato naračunali za vse izbrane pasovno-prepustne filtre. Skupaj smo torej za posnetke iz skupine, kjer je bil iz vsake nosečnosti izžreban po en posnetek, naračunali $N_{\text{cenilk}} \cdot N_{\text{verjetnosti}} \cdot N_{\text{filtrov}} = 8 \cdot 7 \cdot 6 = 336$ verjetnosti.

10.3.2 Skupina z dvema posnetkoma na nosečnost

Raziskava, med katero je bila pridobljena večina posnetkov, je bila v osnovi zastavljena tako, da naj bi bila med vsako nosečnostjo zajeta dva posnetka električne aktivnosti maternice - prvi okrog 22. tedna nosečnosti in drugi okrog 31. tedna nosečnosti. Na žalost je bil med več nosečnostmi zajet le po en posnetek, ali pa so bili nekateri zajeti kanali ocenjeni kot slabi. Pri nekaterih nosečnostih je bil porod sprožen ali pa je bila nosečnost zaključena s carskim rezom. Pri nekaterih so tudi manjkali spremljajoči podatki. Tako je s po dvema posnetkoma ostalo le 14 nosečnosti, kjer je bil porod prezgoden. Nosečnosti, kjer je bil porod ob roku, je ostalo 126. Ker so si nosečnice različne, je mogoče pričakovati, da je tudi električna aktivnost pri različnih nosečnicah različna. Prav mogoče je, da bi bilo za napovedovanje prezognjega ali bližajočega se poroda bolje opazovati spremembe vrednosti cenilk med nosečnostjo, kot pa same vrednosti cenilk. V ta namen smo za vse nosečnosti, kjer so bili zbrani potrebni spremljajoči podatki in kjer je bil zajet po en posnetek z gotovo dobrimi prvimi tremi kanali pred 26. tednom in en posnetek z gotovo dobrimi prvimi tremi kanali po 26. tednu nosečnosti, izračunali verjetnosti.

Nato smo za vsak par posnetkov izračunali še razlike v vrednostih cenilk, razlike v časih posnetkov ter količnik razlike vrednosti cenilk deljeno z razliko v časih snemanja posnetkov. Tako smo dobili podatke o spremembah dane cenilke skozi čas in oceno hitrosti teh sprememb. S tem smo dobili štiri verjetnosti, ki smo jih poimenovali podobno, kot pri skupini z enim

samim posnetkom na nosečnost:

- p_3 - Verjetnost, da se povprečna vrednost cenilke pri posnetkih, kjer je bil porod prezgoden, med nosečnostjo ni spremenila. Nizka vrednost p_2 pomeni, da se vrednost cenilke pri prezgodnjih porodih med nosečnostjo spreminja.
- p_4 - Verjetnost, da se povprečna vrednost cenilke pri posnetkih, kjer je bil porod ob roku, med nosečnostjo ni spremenila. Nizka vrednost p_3 pomeni, da se vrednost cenilke pri terminskih porodih med nosečnostjo spreminja.
- p_5 - Verjetnost, da se povprečna vrednost cenilke pri vseh posnetkih ni spremenila. Nizka vrednost pomeni, da se vrednost cenilke med nosečnostjo spreminja.
- p_6 - Verjetnost, da je povprečna vrednost odvoda cenilke po času pri posnetkih, kjer je bil porod ob roku, enaka povprečni vrednosti odvoda cenilke po času pri posnetkih, kjer je bil porod prezgoden. Nizka vrednost p_6 pomeni, da bi iz različne hitrosti sprememb v vrednosti cenilke med nosečnostjo morda lahko sklepali o tem, ali bo prišlo do prezgodnjega poroda.

Tabela 10.2: Števila posnetkov v skupinah z enim posnetkom na nosečnost

Skupina	Št. nosečnosti	Št. posnetkov
<26-PRE (ZP)	19	19
≥26-PRE (KP)	24	24
<26-TERM (ZR)	163	163
≥26-TERM (KR)	176	176

10.4 Rezultati

Delovanje različnih cenilk smo preverili med posnetki, kjer so bili prvi trije kanali ocenjeni kot verjetno dobri, kjer je bil iz vsake nosečnosti izbran največ en posnetek in v kateri ni bilo carskih rezov ali umetno sproženih porodov. Te posnetke smo razdelili na štiri skupine glede na trajanje nosečnosti in glede na čas zajema posnetka. Števila posnetkov v skupinah so prikazana v tabeli 10.2. Vsak 3-kanalni posnetek smo filtrirali s šestimi različnimi filtri. Pri tem smo preverili delovanje 7 cenilk, za vsako cenilko pa smo obravnavali 7 različnih delitev na podskupine. Če ne upoštevamo večločljivostne vzorčne entropije, smo tako dobili $3 \cdot 6 \cdot (7 - 1) \cdot 7 = 756$ naborov statističnih rezultatov. Ker smo mediano frekvenco in frekvenco vrha močnostnega spektra računali dvakrat (enkrat za celoten posnetek in enkrat s povprečenjem močnostnega spektra z uporabo drsečega okna), smo skupaj izračunali $3 \cdot 6 \cdot ((7 - 1) + 2) \cdot 7 = 1008$ naborov statističnih rezultatov za vse cenilke, razen za večločljivostno vzorčno entropijo.

Tem rezultatom je potrebno dodati še statistične rezultate za večločljivostno vzorčno entropijo, kjer smo preverili več različnih vrednosti za parametre L , m in r . Preverili smo štiri različne vrednosti za L , pet različnih vrednosti za r in tri za m , s čimer smo dobili še nadalnjih $3 \cdot 6 \cdot (4 \cdot 5 \cdot 3) \cdot 7 = 7560$ naborov rezultatov. Skupaj je bilo naborov rezultatov torej 8568.

V vsakem naboru smo izračunali povprečne vrednosti, standardne deviacije, minimalne in maksimalne vrednosti ter opravili Studentov t-test.

Zaradi velike količine podatkov so v glavnem delu pričajoče doktorske disertacije predstavljeni le povzetki rezultatov.

10.4.1 Posnetki s prezgodnjimi porodi in porodi ob roku

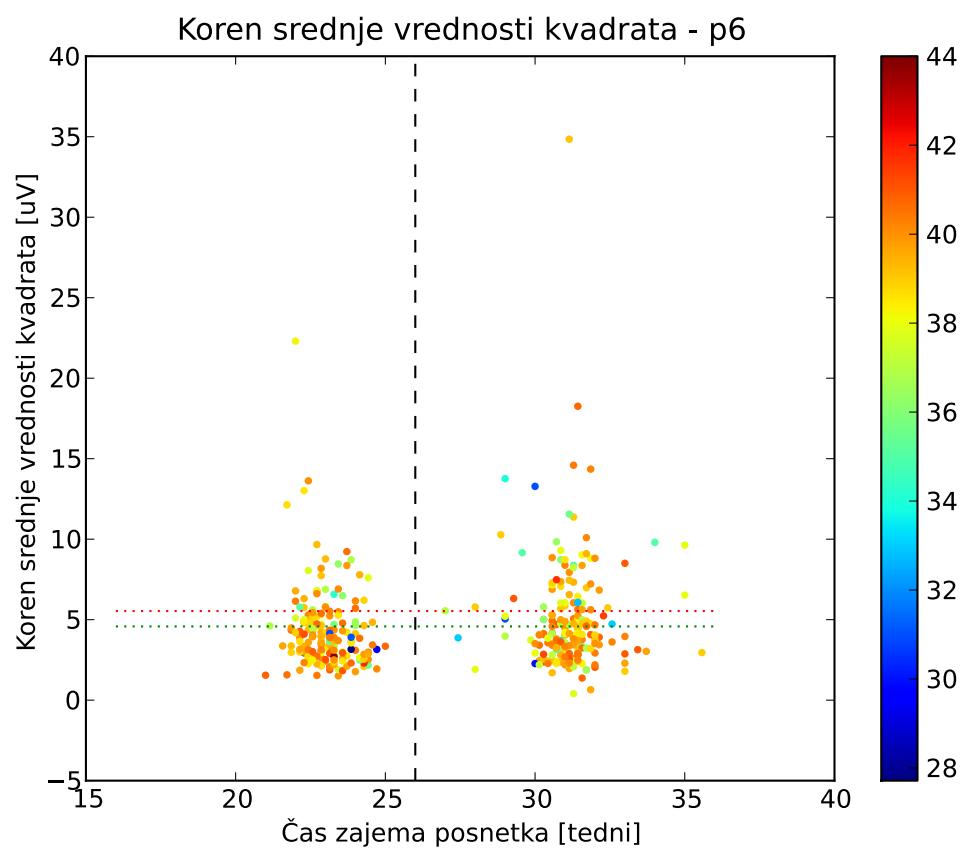
Dolgoročni cilj raziskave, katere del je tudi to delo, je izboljšanje napovedovanja prezgodnjega poroda. V ta namen smo najprej preverili, kakšna je verjetnost, da je srednja vrednost cenilke pri skupini posnetkov, zajetih zgodaj med nosečnostjo, kjer je bil porod ob roku, enaka srednji vrednosti cenilke pri posnetkih, zajetih zgodaj med nosečnostjo, kjer je bil porod prezgoden (p_1). Nato smo enako preverili za skupino posnetkov, zajetih pozno med nosečnostjo (p_2), nato pa še za vse posnetke (p_6).

Tabela 10.3: Koren srednje vrednosti kvadrata - povzetek rezultatov

Filter	Kanal	p_1	p_2	p_3	p_4	p_5	p_6	p_7
0.08Hz - 2.5Hz	1	0.987	0.504	0.650	0.763	0.882	0.623	0.992
	2	0.477	0.142	0.022	0.361	0.124	0.503	0.136
	3	0.329	0.527	0.507	0.216	0.166	0.293	0.319
0.08Hz - 3Hz	1	0.983	0.505	0.652	0.752	0.870	0.627	0.997
	2	0.477	0.145	0.022	0.354	0.121	0.507	0.138
	3	0.331	0.528	0.507	0.218	0.167	0.294	0.321
0.08Hz - 4Hz	1	0.974	0.505	0.655	0.726	0.842	0.632	0.971
	2	0.476	0.149	0.022	0.348	0.118	0.512	0.144
	3	0.335	0.528	0.505	0.221	0.170	0.296	0.326
0.3Hz - 2.5Hz	1	0.945	0.248	0.366	0.947	0.707	0.324	0.722
	2	0.456	0.003	0.004	0.147	0.014	0.059	0.017
	3	0.472	0.073	0.105	0.089	0.029	0.049	0.080
0.3Hz - 3Hz	1	0.971	0.258	0.384	0.970	0.790	0.343	0.792
	2	0.457	0.004	0.004	0.142	0.014	0.065	0.020
	3	0.486	0.075	0.109	0.099	0.033	0.052	0.088
0.3Hz - 4Hz	1	0.987	0.266	0.419	0.788	0.978	0.369	0.956
	2	0.462	0.007	0.004	0.146	0.015	0.074	0.028
	3	0.514	0.076	0.110	0.116	0.040	0.056	0.101

Koren srednje kvadratne vrednosti signala

Ker na jakost električnega signala, zajetega na površju trebuha, lahko močno vpliva debelina podkožnega maščevja in ker so tudi razlike med maternicami lahko velike, nismo pričakovali bistvenih razlik med skupinama, kjer so bili porodi prezgodnji oziroma ob roku. Vseeno so se razlike med skupinama pokazale pozno v nosečnosti na drugem kanalu pri uporabi filtrov, kjer je bila spodnja mejna frekvenca 0.3 Hz, zgornja pa 2.5 Hz, 3 Hz ali 4 Hz. Prav tako je bila povprečna vrednost RMS na tretjem kanalu pri posnetkih, kjer je bil porod ob roku, statistično pomembno različna od povprečne vrednosti pri posnetkih, kjer je bil porod prezgoden. Rezultati uporabe korena srednje kvadratne vrednosti signala so predstavljeni v tabeli 10.3 in na sliki 10.3.



Slika 10.3: Koren srednje kvadratne vrednosti signalov za skupino z enim posnetkom na nosečnost ob uporabljenem filtru od 0.3 Hz do 2.5 Hz na kanalu 3

Frekvenca vrha močnostnega spektra signala

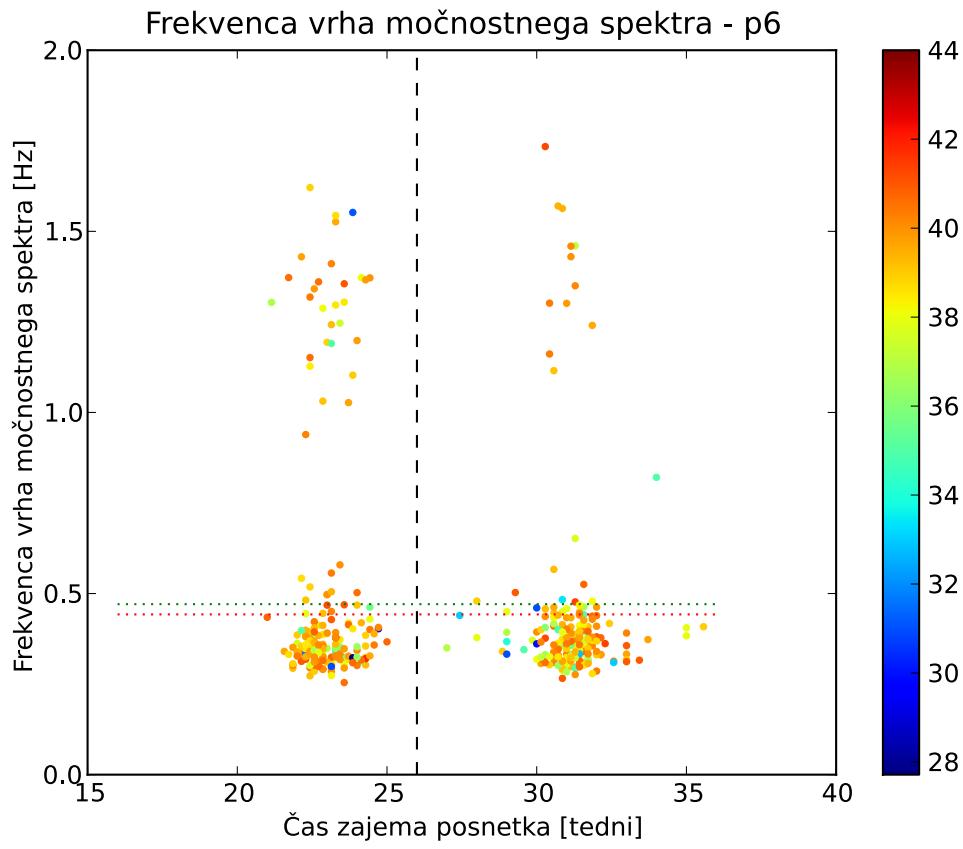
Glede na rezultate drugih raziskovalcev [6] smo pričakovali, da se bo frekvenca vrha močnostnega spektra pred porodom premaknila proti višjim frekvencam in da bo torej pri posnetkih, kjer je bil porod prezgoden, frekvenca vrha močnostnega spektra opazno višja. Zato smo bili presenečeni, ko se med skupino, kjer je bil porod prezgoden in skupino, kjer je bil porod ob roku, ni pokazala nobena statistična razlika. Rezultati uporabe frekvence vrha močnostnega spektra brez in z uporabo drsečega okna in povprečenja močnostnega spektra so predstavljeni v tabelah 10.4 in 10.5 ter na sliki 10.4.

Tabela 10.4: Frekvenca vrha močnostnega spektra - povzetek rezultatov

Filter	Kanal	<i>p</i> ₁	<i>p</i> ₂	<i>p</i> ₃	<i>p</i> ₄	<i>p</i> ₅	<i>p</i> ₆	<i>p</i> ₇
0.08Hz - 2.5Hz	1	0.621	0.388	0.203	0.592	0.779	0.957	0.892
	2	0.410	0.098	0.087	0.632	0.886	0.298	0.558
	3	0.831	0.773	0.249	0.081	0.048	0.688	0.015
0.08Hz - 3Hz	1	0.621	0.388	0.203	0.592	0.779	0.957	0.892
	2	0.410	0.098	0.087	0.632	0.886	0.298	0.558
	3	0.831	0.773	0.249	0.081	0.048	0.688	0.015
0.08Hz - 4Hz	1	0.654	0.965	0.203	0.890	0.809	0.769	0.539
	2	0.410	0.960	0.087	0.371	0.286	0.957	0.151
	3	0.831	0.860	0.249	0.139	0.113	0.916	0.051
0.3Hz - 2.5Hz	1	0.641	0.084	0.014	0.052	0.009	0.377	0.014
	2	0.770	0.455	0.657	0.721	0.908	0.802	0.724
	3	0.995	0.406	0.157	0.038	0.016	0.572	0.086
0.3Hz - 3Hz	1	0.641	0.084	0.014	0.052	0.009	0.377	0.014
	2	0.770	0.675	0.657	0.976	0.833	0.913	0.548
	3	0.960	0.406	0.157	0.027	0.011	0.542	0.069
0.3Hz - 4Hz	1	0.783	0.103	0.014	0.104	0.026	0.320	0.049
	2	0.211	0.902	0.424	0.913	0.794	0.404	0.663
	3	0.266	0.395	0.095	0.066	0.017	0.756	0.105

Tabela 10.5: Frekv. vrha močnostnega spektra z drsečim oknom - povzetek rezultatov

Filter	Kanal	<i>p</i> ₁	<i>p</i> ₂	<i>p</i> ₃	<i>p</i> ₄	<i>p</i> ₅	<i>p</i> ₆	<i>p</i> ₇
0.08Hz - 2.5Hz	1	0.591	0.689	0.306	0.887	0.936	0.929	0.626
	2	0.265	0.310	0.036	0.244	0.083	0.530	0.180
	3	0.086	0.490	0.008	0.093	0.023	0.890	0.028
0.08Hz - 3Hz	1	0.706	0.771	0.447	0.916	0.958	0.949	0.637
	2	0.263	0.471	0.035	0.194	0.075	0.671	0.278
	3	0.094	0.585	0.009	0.094	0.027	0.945	0.033
0.08Hz - 4Hz	1	0.594	0.838	0.621	0.653	0.678	0.595	0.955
	2	0.260	0.970	0.035	0.166	0.111	0.892	0.173
	3	0.115	0.902	0.010	0.169	0.115	0.771	0.082
0.3Hz - 2.5Hz	1	0.925	0.262	0.080	0.020	0.006	0.361	0.033
	2	0.852	0.591	0.428	0.149	0.103	0.588	0.074
	3	0.848	0.204	0.125	0.143	0.064	0.275	0.145
0.3Hz - 3Hz	1	0.937	0.258	0.073	0.019	0.005	0.364	0.032
	2	0.869	0.583	0.463	0.245	0.179	0.589	0.097
	3	0.842	0.212	0.138	0.163	0.076	0.280	0.157
0.3Hz - 4Hz	1	0.610	0.345	0.111	0.015	0.006	0.283	0.052
	2	0.834	0.514	0.477	0.863	0.732	0.494	0.562
	3	0.602	0.298	0.261	0.345	0.231	0.240	0.459



Slika 10.4: Frekvence vrha močnostnega spektra za skupino z enim posnetkom na nosečnost ob uporabljenem filtru od 0.3 Hz do 2.5 Hz na kanalu 3

Mediana frekvenca močnostnega spektra signala

Podobno kot pri frekvenci vrha močnostnega spektra smo tudi za mediano frekvenco pričakovali, da se bodo pokazale razlike med skupinami. V tem primeru so se pričakovana izpolnila - pri uporabi filtrov od 0.3 Hz do 3 Hz in od 0.3 Hz do 3 Hz so se na prvem kanalu pozno med nosečnostjo pokazale statistične razlike med skupinama posnetkov $\geq 26\text{-PRE}$ in $\geq 26\text{-TERM}$. Prav tako je bila statistično pomembna razlika med povprečnimi vrednostmi $fMED$, izračunanimi. Prav tako je bila povprečna vrednost $fMED$ na tretjem kanalu ob uporabi filtrov s spodnjo mejo pri 0.3 Hz in zgornjo mejo pri 2.5 Hz, 3 Hz ali 4 Hz, statistično pomembno različna od povprečne vrednosti pri posnetkih, kjer je bil porod prezgoden. Podobne razlike med skupinama s porodi ob roku in prezgodnjimi porodi smo opazili pri uporabi filtra od 0.3 Hz do 4 Hz na prvem kanalu. Rezultati uporabe mediane frekvence močnostnega spektra signala so predstavljeni v tabeli 10.6 in na sliki 10.5.

Ob uporabi drsečega okna in povprečenja za oceno mediane frekvence je bila srednja vrednost $fMED$ pri skupini posnetkov, kjer je bil porod prezgoden, statistično pomembno različna od srednje vrednosti $fMED$ pri skupini posnetkov, kjer je bil porod ob roku, ko smo na tretjem kanalu uporabili filtre s spodnjo mejo pri 0.3 Hz in zgornjo mejo pri 2.5 Hz, 3 Hz ali 4 Hz. Rezultati uporabe mediane frekvence močnostnega spektra ob uporabi drsečega okna in povprečenja so predstavljeni v tabeli 10.7.

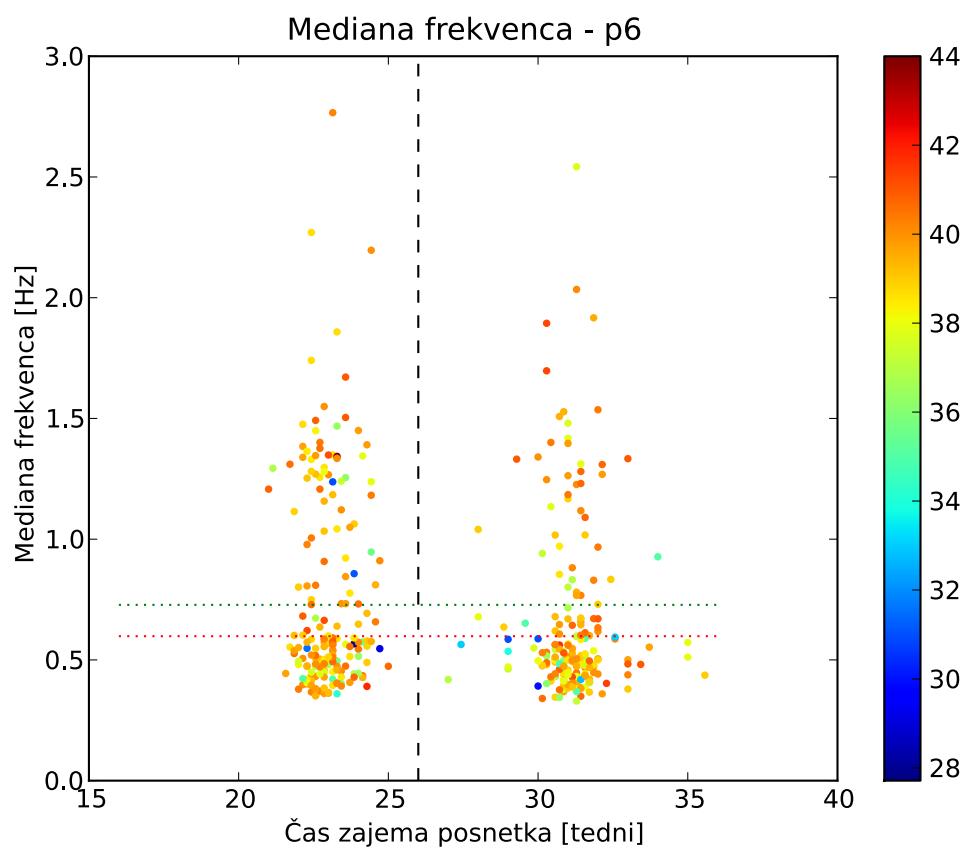
Boljše rezultate kot pri merjenju frekvence vrha močnostnega spektra smo verjetno dobili, ker pri mediani frekvenci upoštevamo tudi močnostni spekter pri višjih frekvenkah, kjer so pogosto prisotni vrhovi, ki so nižji od najvišjega.

Tabela 10.6: Mediana frekvenca - povzetek rezultatov

Filter	Kanal	p_1	p_2	p_3	p_4	p_5	p_6	p_7
0.08Hz - 2.5Hz	1	0.406	0.795	0.060	0.955	0.832	0.708	0.702
	2	0.376	0.623	0.032	0.173	0.079	0.758	0.293
	3	0.338	0.520	0.022	0.298	0.132	0.851	0.174
0.08Hz - 3Hz	1	0.414	0.997	0.068	0.995	0.837	0.590	0.724
	2	0.376	0.786	0.033	0.152	0.079	0.897	0.335
	3	0.382	0.681	0.023	0.360	0.194	0.985	0.250
0.08Hz - 4Hz	1	0.391	0.815	0.082	0.925	0.818	0.485	0.697
	2	0.361	0.996	0.033	0.139	0.088	0.918	0.330
	3	0.401	0.983	0.026	0.376	0.259	0.761	0.278
0.3Hz - 2.5Hz	1	0.456	0.066	0.062	0.016	0.005	0.070	0.001
	2	0.467	0.558	0.997	0.570	0.563	0.346	0.468
	3	0.087	0.215	0.827	0.081	0.072	0.034	0.073
0.3Hz - 3Hz	1	0.477	0.046	0.035	0.014	0.003	0.056	0.001
	2	0.530	0.491	0.778	0.586	0.539	0.343	0.368
	3	0.081	0.152	0.571	0.065	0.050	0.023	0.057
0.3Hz - 4Hz	1	0.480	0.034	0.015	0.018	0.004	0.045	0.005
	2	0.665	0.483	0.496	0.435	0.351	0.403	0.204
	3	0.237	0.084	0.096	0.027	0.011	0.035	0.036

Tabela 10.7: Mediana frekvenca z drsečim oknom - povzetek rezultatov

Filter	Kanal	p_1	p_2	p_3	p_4	p_5	p_6	p_7
0.08Hz - 2.5Hz	1	0.652	0.785	0.411	0.959	0.811	0.914	0.623
	2	0.112	0.672	0.021	0.071	0.023	0.933	0.121
	3	0.077	0.569	0.014	0.076	0.020	0.949	0.038
0.08Hz - 3Hz	1	0.645	0.932	0.516	0.941	0.954	0.796	0.742
	2	0.111	0.840	0.021	0.070	0.028	0.933	0.157
	3	0.067	0.719	0.013	0.099	0.033	0.912	0.050
0.08Hz - 4Hz	1	0.589	0.847	0.685	0.730	0.773	0.599	0.998
	2	0.141	0.921	0.023	0.078	0.042	0.757	0.198
	3	0.069	0.974	0.012	0.144	0.076	0.680	0.079
0.3Hz - 2.5Hz	1	0.498	0.182	0.169	0.025	0.010	0.145	0.014
	2	0.708	0.408	0.530	0.581	0.472	0.376	0.299
	3	0.120	0.159	0.770	0.391	0.344	0.035	0.347
0.3Hz - 3Hz	1	0.455	0.172	0.137	0.014	0.005	0.124	0.012
	2	0.857	0.405	0.401	0.565	0.424	0.440	0.266
	3	0.118	0.128	0.576	0.228	0.179	0.027	0.207
0.3Hz - 4Hz	1	0.452	0.276	0.139	0.007	0.003	0.177	0.013
	2	0.863	0.401	0.227	0.463	0.289	0.567	0.231
	3	0.157	0.153	0.493	0.136	0.099	0.040	0.141



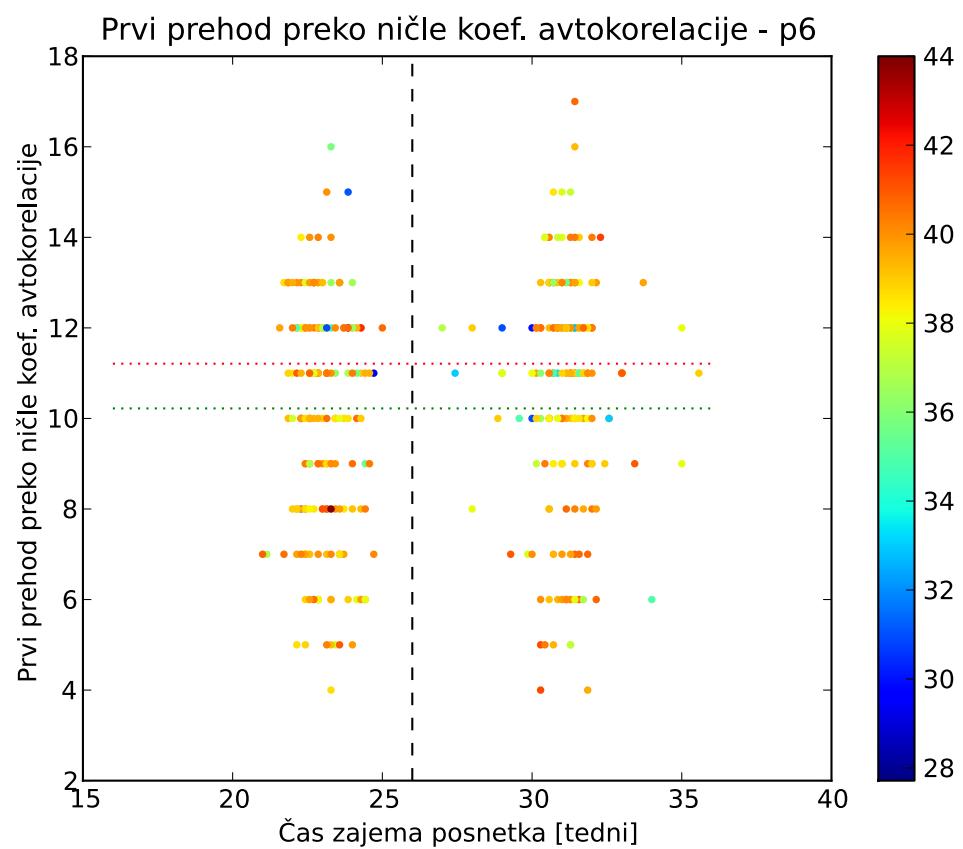
Slika 10.5: Mediane frekvence za skupino z enim posnetkom na nosečnost ob uporabljenem filtru od 0.3 Hz do 4 Hz na kanalu 1

Tabela 10.8: Prvi prehod preko ničle koef. avtokorelacijske - povzetek rezultatov

Filter	Kanal	p_1	p_2	p_3	p_4	p_5	p_6	p_7
0.08Hz - 2.5Hz	1	0.296	0.046	0.022	0.895	0.528	0.394	0.305
	2	0.571	0.037	0.048	0.893	0.393	0.152	0.720
	3	0.379	0.090	0.008	0.064	0.008	0.354	0.080
0.08Hz - 3Hz	1	0.305	0.071	0.024	0.936	0.420	0.441	0.243
	2	0.542	0.045	0.047	0.848	0.366	0.175	0.691
	3	0.371	0.097	0.008	0.061	0.008	0.369	0.081
0.08Hz - 4Hz	1	0.281	0.080	0.025	0.994	0.467	0.490	0.255
	2	0.571	0.046	0.048	0.827	0.357	0.167	0.679
	3	0.343	0.108	0.008	0.055	0.007	0.402	0.080
0.3Hz - 2.5Hz	1	0.160	0.126	0.726	0.138	0.117	0.036	0.051
	2	0.096	0.304	0.517	0.646	0.775	0.055	0.492
	3	0.007	0.434	0.547	0.002	0.005	0.015	0.008
0.3Hz - 3Hz	1	0.180	0.151	0.744	0.143	0.124	0.047	0.066
	2	0.098	0.267	0.565	0.606	0.717	0.049	0.564
	3	0.031	0.428	0.923	0.002	0.003	0.035	0.009
0.3Hz - 4Hz	1	0.839	0.224	0.119	0.054	0.021	0.308	0.044
	2	0.149	0.644	0.327	0.856	0.941	0.177	0.827
	3	0.030	0.125	0.790	0.018	0.016	0.008	0.060

Prvi prehod preko ničle koeficientov avtokorelacijske

Prvi prehod preko ničle koeficientov avrokorelacijske smo izračunali predvsem zato, ker smo ga potrebovali za določitev vzorčnega zamika pri rekonstrukciji faznega prostora za izračun maksimalnega eksponenta Ljapunova in korelacijske dimenzije. Vseeno so se na tretjem kanalu pri uporabi filtrov s spodnjo mejo 0.3 Hz ter zgornjimi mejami pri 2.5 Hz, 3 Hz ali 4 Hz pokazale statistične razlike med skupinama posnetkov <26-PRE in <26-TERM. Prav tako smo ob uporabi filtra od 0.3 Hz do 3 Hz na vseh kanalih, ob uporabi filtra od 0.3 Hz do 2.5 Hz na kanalih 1 in 3 ter ob uporabi filtra od 0.3 do 4 Hz na tretjem kanalu, opazili, da je povprečna vrednost prvega prehoda preko ničle koeficientov avtokorelacijske pri posnetkih, kjer je bil porod prezgoden, statistično različna od povprečne vrednosti prvega prehoda preko ničle koeficientov avtokorelacijske pri posnetkih, kjer je bil porod ob roku. Rezultati uporabe prvega prehoda preko ničle koeficientov avtokorelacijske so predstavljeni v tabeli 10.8 in na sliki 10.6.



Slika 10.6: Prvi prehodi preko ničle koeficientov avtokorelacji za skupino z enim posnetkom na nosečnost ob uporabljenem filtru od 0.3 Hz do 2.5 Hz na kanalu 3

Tabela 10.9: Maksimalni eksponent Ljapunova - povzetek rezultatov

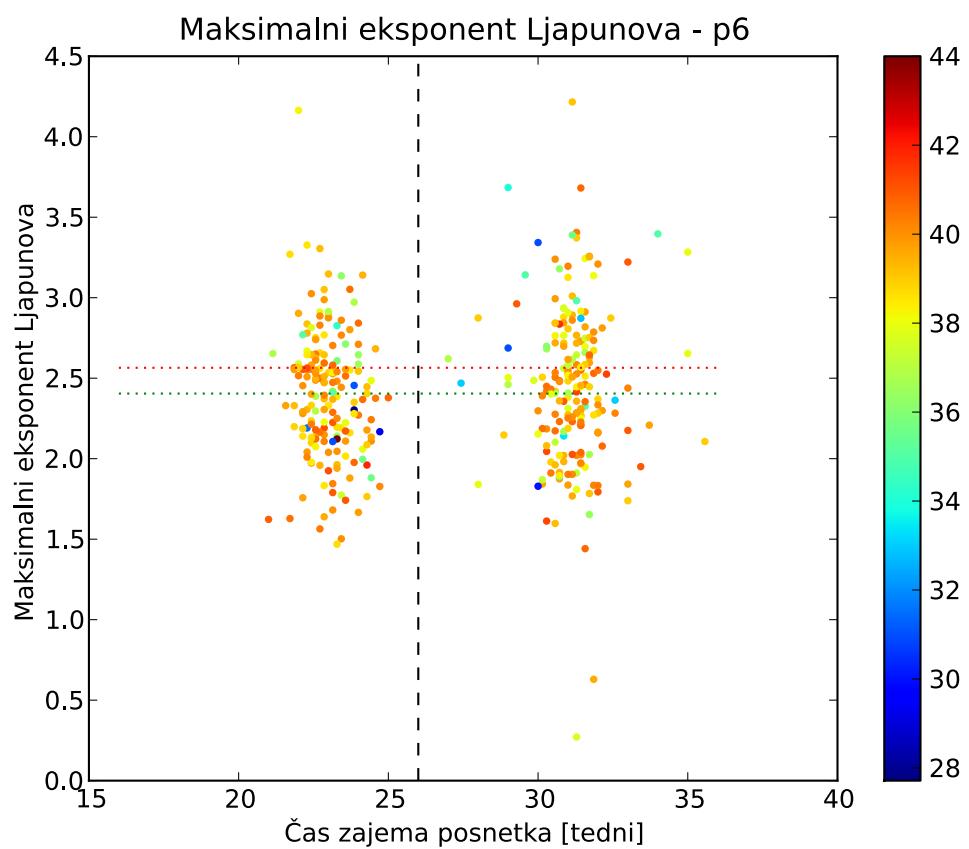
Filter	Kanal	p_1	p_2	p_3	p_4	p_5	p_6	p_7
0.08Hz - 2.5Hz	1	0.765	0.347	0.837	0.510	0.584	0.377	0.726
	2	0.928	0.087	0.099	0.456	0.214	0.150	0.141
	3	0.111	0.164	0.912	0.666	0.621	0.036	0.551
0.08Hz - 3Hz	1	0.794	0.345	0.846	0.430	0.500	0.390	0.636
	2	0.929	0.095	0.107	0.455	0.218	0.160	0.145
	3	0.113	0.169	0.904	0.623	0.580	0.037	0.532
0.08Hz - 4Hz	1	0.844	0.359	0.854	0.368	0.434	0.428	0.578
	2	0.910	0.087	0.104	0.442	0.208	0.148	0.134
	3	0.123	0.153	0.864	0.644	0.587	0.036	0.525
0.3Hz - 2.5Hz	1	0.912	0.237	0.478	0.484	0.679	0.419	0.807
	2	0.738	0.032	0.023	0.304	0.081	0.130	0.046
	3	0.375	0.041	0.251	0.465	0.254	0.027	0.186
0.3Hz - 3Hz	1	0.856	0.241	0.496	0.362	0.534	0.450	0.688
	2	0.752	0.033	0.024	0.311	0.085	0.128	0.048
	3	0.407	0.045	0.264	0.536	0.304	0.031	0.224
0.3Hz - 4Hz	1	0.786	0.241	0.543	0.201	0.323	0.488	0.476
	2	0.776	0.033	0.026	0.358	0.106	0.123	0.059
	3	0.456	0.047	0.272	0.647	0.381	0.037	0.297

Maksimalni eksponent Ljapunova in korelacijska dimenzija

Pri rekonstrukciji faznega prostora, v katerega preslikamo signal, da nato lahko ocenimo maksimalni eksponent Ljapunova in korelacijsko dimenzijo, smo morali določiti primerno vložitveno dimenzijo in vzorčni zamik. Ker smo vložitveno dimenzijo ocenili bolj ali manj na slepo, je mogoče, da bi bili rezultati boljši pri drugačni vložitveni dimenziji. Na žalost bo izbira primerne vložitvene dimenzije težavna, dokler ne ugotovimo, koliko dejavnikov vpliva na električno aktivnost maternice. Pri višji vložitveni dimenziji za dobro oceno maksimalnega koeficiente Ljapunova ter korelacijske dimenzije tudi potrebujemo daljšo časovno vrsto.

Eksponent Ljapunova

Z uporabo maksimalnega eksponenta Ljapunova so se pozno v nosečnosti pokazale razlike med skupinama posnetkov $\geq=26$ -PRE in $\geq=26$ -TERM, na drugem in tretjem kanalu pri uporabi filtrov s spodnjo mejo 0.3 Hz in zgornjo mejo pri 2.5 Hz, 3 Hz ali 4 Hz. Prav tako smo na tretjem kanalu opazili, ne glede na uporabljeni filter, da je povprečna vrednost maksimalnega eksponenta Ljapunova pri posnetkih, kjer je bil porod prezgoden, statistično različna od maksimalnega eksponenta Ljapunova pri posnetkih, kjer je bil porod ob roku. Rezultati uporabe maksimalnega eksponenta Ljapunova so predstavljeni v tabeli 10.9 in na sliki 10.7.



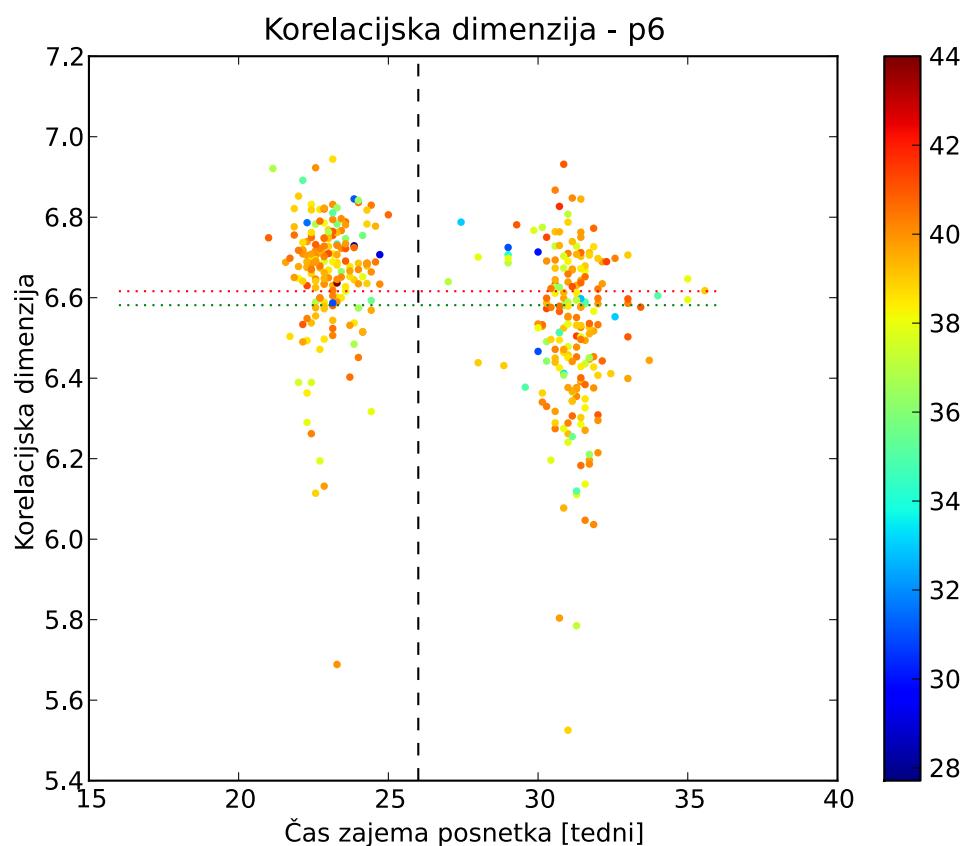
Slika 10.7: Maksimalni eksponenti Ljapunova za skupino z enim posnetkom na nosečnost ob uporabljenem filtru od 0.3 Hz do 2.5 Hz na kanalu 3

Tabela 10.10: Korelacijska dimenzija - povzetek rezultatov

Filter	Kanal	p_1	p_2	p_3	p_4	p_5	p_6	p_7
0.08Hz - 2.5Hz	1	0.434	0.320	0.006 ≤0.001	0.011 ≤0.001	0.001 ≤0.001	0.991 0.279	0.003 ≤0.001
	2	0.053	0.769	0.216	≤0.001	≤0.001	0.156	≤0.001
	3	0.145	0.519			≤0.001		
0.08Hz - 3Hz	1	0.406	0.219	0.006 ≤0.001	0.031 ≤0.001	0.005 ≤0.001	0.953 0.288	0.005 ≤0.001
	2	0.026	0.932	0.219	≤0.001	≤0.001	0.167	≤0.001
	3	0.195	0.483			≤0.001		
0.08Hz - 4Hz	1	0.540	0.473	0.007 ≤0.001	0.011 ≤0.001	0.002 ≤0.001	0.956 0.269	0.003 ≤0.001
	2	0.017	0.955	0.317	≤0.001	≤0.001	0.069	≤0.001
	3	0.048	0.412			≤0.001		
0.3Hz - 2.5Hz	1	0.338	0.834	0.085 0.010	0.073 ≤0.001	0.036 ≤0.001	0.540 0.228	0.023 ≤0.001
	2	0.566	0.070	0.452	0.154	0.108	0.920	0.085
	3	0.855	0.820					
0.3Hz - 3Hz	1	0.254	0.746	0.097 0.005	0.135 ≤0.001	0.077 ≤0.001	0.411 0.389	0.035 ≤0.001
	2	0.254	0.065	0.403	0.102	0.068	0.973	0.108
	3	0.815	0.929					
0.3Hz - 4Hz	1	0.196	0.416	0.251 0.001	0.277 ≤0.001	0.218 ≤0.001	0.170 0.177	0.196 ≤0.001
	2	0.419	0.028	0.319	0.013	0.008	0.419	0.019
	3	0.526	0.539					

Korelacijska dimenzija

Povprečna korelacijska dimenzija pri posnetkih, kjer je bil porod prezgoden, je bila statistično različna od povprečne korelacijske dimenzije pri posnetkih, kjer je bil porod ob roku, le, če smo uporabili filter od 0.08 Hz do 3 Hz na drugem kanalu ali če smo uporabili filter od 0.08 Hz do 4 Hz na drugem ali tretjem kanalu. Rezultati uporabe korelacijske dimenzije so predstavljeni v tabeli 10.10 in na sliki 10.8.



Slika 10.8: Korelacijske dimenzijske za skupino z enim posnetkom na nosečnost ob uporabljenem filtru od 0.08 Hz do 4 Hz na kanalu 2

Tabela 10.11: Vzorčna entropija - $m = 3$, $r = 0.15$ - povzetek rezultatov

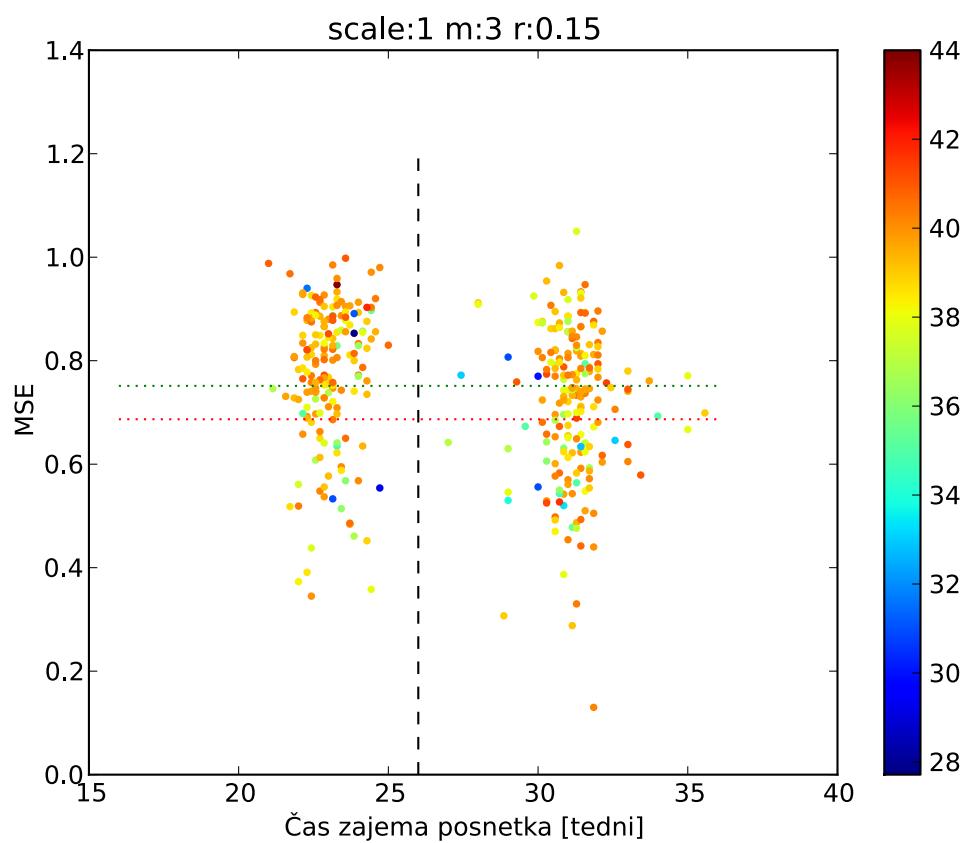
Filter	Kanal	p_1	p_2	p_3	p_4	p_5	p_6	p_7
0.08Hz - 2.5Hz	1	0.241	0.538	0.785	0.020	0.021	0.194	0.026
	2	0.933	0.478	0.187	0.014	0.005	0.495	0.024
	3	0.035	0.275	0.906	0.010	0.011	0.024	0.069
0.08Hz - 3Hz	1	0.130	0.603	0.865	0.002	0.004	0.139	0.006
	2	0.992	0.384	0.123	0.010	0.003	0.465	0.013
	3	0.024	0.173	0.739	0.002	0.002	0.010	0.015
0.08Hz - 4Hz	1	0.171	0.582	0.873	0.012	0.016	0.169	0.021
	2	0.973	0.277	0.056	0.002	≤0.001	0.386	0.002
	3	0.018	0.464	0.771	0.004	0.007	0.030	0.029
0.3Hz - 2.5Hz	1	0.404	0.501	0.493	0.002	0.002	0.259	0.010
	2	0.526	0.041	0.007	0.001	≤0.001	0.238	≤0.001
	3	0.092	0.088	0.170	≤0.001	≤0.001	0.014	0.002
0.3Hz - 3Hz	1	0.284	0.305	0.486	0.004	0.003	0.124	0.014
	2	0.424	0.009	0.001	0.001	≤0.001	0.137	≤0.001
	3	0.067	0.042	0.125	≤0.001	≤0.001	0.005	0.003
0.3Hz - 4Hz	1	0.158	0.414	0.901	0.034	0.044	0.109	0.052
	2	0.480	0.003	≤0.001	≤0.001	≤0.001	0.061	≤0.001
	3	0.101	0.238	0.357	≤0.001	≤0.001	0.042	0.008

Vzorčna entropija in večločljivostna vzorčna entropija

Večločljivostno vzorčno entropijo smo izračunali za več različnih naborov parametrov L , m in r . Izračunali smo večločljivostno vzorčno entropijo za vrednosti L od 1 do 4, m od 2 do 4 in r od 0.1 do 0.2 v korakih po 0.25. Rezultati so bili praviloma najboljši pri $L = 1$. Večločljivostna vzorčna entropija se torej ni izkazala za boljšo od navadne vzorčne entropije.

Za primerjavo z ostalimi metodami smo potem uporabili rezultate, dobljene pri $L = 1$, $m = 3$ in $r = 0.15$, pri uporabi predhodne normalizacije.

Na tretjem kanalu smo ne glede na uporabljeni filter opazili, da je povprečna vzorčna entropija pri posnetkih, kjer je bil porod prezgoden, statistično različna od povprečne vzorčne entropije pri posnetkih, kjer je bil porod ob roku. Prav tako so se na tretjem kanalu pokazale statistične razlike med skupinama <26-PRE in <26-TERM, pri uporabi filtrov s spodnjo mejo 0.08 Hz in zgornjo mejo pri 2.5 Hz, 3 Hz ali 4 Hz. Rezultati uporabe večločljivostne vzorčne entropije pri $L = 1$, $m = 3$ in $r = 0.15$ so predstavljeni v tabeli 10.11 in na sliki 10.9.



Slika 10.9: Vzorčna entropija pri $m = 3$ in $r = 0.15$ za skupino z enim posnetkom na nosečnost ob uporabljenem filtru od 0.3 Hz do 3 Hz na kanalu 3.

10.4.2 Posnetki okrog 22. in 31. tedna nosečnosti

Delovanje mišičnih celic maternice se skozi nosečnost spreminja. Pred porodom krči postanejo pogosteji. Zaradi večje vzburljivosti mišičnih celic miometrija smo zato pričakovali, da se bo električna aktivnost maternice, izmerjena v okolici 22. tedna, bistveno razlikovala od električne aktivnosti maternice, izmerjene okrog 31. tedna nosečnosti. Da bi to hipotezo preverili, je bila raziskava, na osnovi katere je bilo izdelano to delo, zamišljena tako, da bi med vsako opazovano nosečnostjo zajeli dva posnetka - enega v 22. in enega v 31. tednu nosečnosti. Posnetki so bili zajeti med rednimi pregledi, tako da so bili dejansko zajeti ne v 22. oziroma 31. tednu nosečnosti, temveč okrog teh tednov.

Posnetke smo zato glede na trajanje nosečosti v trenutku, ko so bili zajeti, razdelili na dve skupini - na tiste, kjer je bil posnetek zajet pred 26. tednom nosečnosti in na tiste, kjer je bil posnetek zajet v 26. tednu nosečnosti ali kasneje. Nato smo za vsako cenilko s pomočjo Studentovega t-testa izračunali verjetnost, da se povprečni vrednosti cenilk za dobljeni skupini ne razlikujeta (p_5). Nato smo izračunali še verjetnost, da sta povprečni vrednosti dane cenilke enaki pri posnetkih, kjer je bil porod prezgoden (p_3) in verjetnost, da sta povprečni vrednosti dane cenilke enaki pri posnetkih, kjer je bil porod ob roku (p_4). Pričakovali smo, da se bodo razlike pokazale pri večini cenilk.

Koren srednje kvadratne vrednosti signala

Ker z bližajočim se porodom jakost in frekvenca krčev maternice naraščata, smo pričakovali, da bo tudi vrednost RMS skozi nosečnost narasla.

Dejansko so se statistične razlike med skupinama <26-PRE in >=26-PRE pokazale le na drugem kanalu, ne glede na uporabljeni filter. Srednja vrednost RMS je bila pri vseh posnetkih, zajetih pred 26. tednom nosečnosti statistično različna od srednje vrednosti RMS pri posnetkih, zajetih med ali po 26. tednu nosečnosti, na kanalih 2 in 3, ko smo uporabili filtre s spodnjo mejno frekvenco 0.3 Hz in zgornjo frekvenco 2.5 Hz, 3 Hz ali 4 Hz. Rezultati uporabe korena srednje kvadratne vrednosti signala so predstavljeni v tabeli 10.3.

Frekvenca vrha močnostnega spektra signala

Za frekvenco vrha močnostnega spektra smo prav tako pričakovali, da se bo med nosečnostjo bistveno spremenila. Pri uporabi frekvence vrha močnostnega spektra, naračunane za celotne posnetke, so se razlike med skupinama dejansko pokazale na tretjem kanalu pri vseh posnetkih, na prvem kanalu pri vseh posnetkih ob uporabi filtrov s spodnjo mejno frekvenco

0.3 Hz. Pri uporabi filtrov s spodnjo mejno frekvenco 3 Hz so se razlike pokazale na prvem kanalu pri posnetkih, kjer je bil porod prezgoden. Prav tako so se razlike pokazale pri posnetkih, kjer je bil porod ob roku, vendar le na tretjem kanalu ob uporabi filtrov od 0.3 Hz do 2.5 Hz ter od 0.3 Hz do 3 Hz.

Pri uporabi frekvence vrha močnostnega spektra, izračunane z uporabo povprečenja in drsečega okna, so se statistične razlike med skupinama pokazale zgodaj v nosečnosti na kanalih 2 in 3 pri uporabi filtrov s spodnjo mejno frekvenco 0.08 Hz ter pozno v nosečnosti na prvem kanalu pri uporabi filtrov s spodnjo mejo 0.3 Hz.

Srednja frekvanca vrha močnostnega spektra je bila pri vseh posnetkih, zajetih pred 26. tednom nosečnosti statistično različna od srednje frekvance vrha močnostnega spektra pri posnetkih, zajetih med ali po 26. tednu nosečnosti, na tretjem kanalu ob uporabi filtrov od 0.08 Hz do 2.5 Hz ter od 0.08 Hz do 3 Hz ter na prvem kanalu ob uporabi filtrov s spodnjo mejo 0.3 Hz in zgornjo mejo 2.5 Hz, 3 Hz ali 4 Hz. Rezultati uporabe vrha močnostnega spektra signala so predstavljeni v tabelah 10.4 in 10.5.

Mediana frekvanca močnostnega spektra signala

Pri uporabi mediane frekvence močnostnega spektra smo pričakovali rahlo boljše rezultate, kot pri uporabi frekvence vrha močnostnega spektra.

Statistične razlike med skupino vseh posnetkov, zajetih pred 26. tednom nosečnosti in skupino vseh posnetkov, zajetih med ali po 26. tednu nosečnosti so se pokazale na kanalu 1 ob uporabi filtrov s spodnjo mejo 0.3 Hz ter na kanalu 3 ob uporabi filtrov od 0.3 Hz do 3 Hz in od 0.3 Hz do 4 Hz.

Srednja vrednost mediane frekvence je bila pri vseh posnetkih, zajetih pred 26. tednom nosečnosti, statistično različna od srednje vrednosti mediane frekvence pri posnetkih, zajetih med ali po 26. tednu nosečnosti, na kanalu 1 ob uporabi filtrov s spodnjo mejo 0.3 Hz ter zgodnjo mejo 2.5 Hz, 3 Hz ali 4 Hz in na kanalu 3 ob uporabi filtrov od 0.3 Hz do 3 Hz ali od 0.3 Hz do 4 Hz.

Prav tako so se pokazale statistične razlike med skupinama <26-PRE in >=26-PRE, na 2. in 3. kanalu pri uporabi filtrov s spodnjo mejo 0.08 Hz in z zgornjo mejo 2.5 Hz, 3 Hz ali 4 Hz. Statistične razlike med skupinama <26-TERM in >=26-TERM so se pokazale na prvem kanalu ob uporabi filtrov s spodnjo mejo 0.3 Hz in zgornjo mejo 2.5 Hz, 3 Hz ali 4 Hz ter na kanalu 3 ob uporabi filtra od 0.3 Hz do 4 Hz. Pri uporabi filtra od 0.3 Hz do 3 Hz je bila torej verjetnost, da je povprečna mediana frekvanca močnostnega spektra prvega

signala enaka pred 26. tednom nosečnosti in kasneje enaka, manj kot 0.05, ne glede na to, ali je bil porod ob roku ali ne.

Pri uporabi drsečega okna in povprečenja močnostnega spektra so bili rezultati pri posnetkih, kjer je prišlo do prezgodnjega poroda, slabši - pri uporabi filtrov s spodnjo mejo 0.3 Hz se statistične razlike med skupinama niso pokazale. Pokazale pa so se statistične razlike med skupinama <26-TERM in >=26-TERM, na prvem kanalu pri uporabi filtrov s spodnjo mejo 0.3 Hz.

Srednja vrednost mediane frekvence z drsečim oknom je bila pri vseh posnetkih, zajetih pred 26. tednom nosečnosti, statistično različna od srednje vrednosti mediane frekvence z drsečim oknom pri posnetkih, zajetih med ali po 26. tednu nosečnosti, na kanalih 2 in 3 ob uporabi filtrov od 0.08 Hz do 2.5 Hz ter od 0.08 Hz do 3 Hz, ob uporabi filtra od 0.08 Hz do 4 Hz na drugem kanalu ter ob uporabi filtrov s spodnjo mejo 0.3 Hz in zgornjo mejo 2.5 Hz, 3 Hz ali 4 Hz na prvem kanalu. Rezultati uporabe vrha močnostnega spektra signala so predstavljeni v tabelah 10.4 in 10.5.

Prvi prehod preko ničle koeficientov avtokorelacije

Glede uporabnosti prvega prehoda preko ničle koeficientov avtokorelacije nismo imeli nobenih pričakovanj. Statistične razlike so se med skupinama <26-PRE in >=26-PRE pokazale le pri uporabi filtrov s spodnjo mejno frekvenco pod 0.08 Hz in z zgornjo mejo 2.5 Hz, 3 Hz ali 4 Hz, vendar na vseh kanalih. Med skupinama <26-PRE in >=26-PRE so se statistične razlike pokazale le na tretjem kanalu ob uporabi filtrov s spodnjo frekvenco 0.3 Hz.

Srednja vrednost prvega prehoda preko ničle koeficientov avtokorelacije je bila pri vseh posnetkih, zajetih pred 26. tednom nosečnosti, statistično različna od srednje vrednosti prvega prehoda preko ničle koeficientov avtokorelacije pri posnetkih, zajetih med 26. tednom nosečnosti ali kasneje, na 3. kanalu ob uporabi katerega koli filtra, ter na prvem kanalu ob uporabi filtra od 0.3 Hz do 4 Hz. Rezultati uporabe prvega prehoda preko ničle koeficientov avtokorelacije so predstavljeni v tabeli 10.8.

Maksimalni eksponent Ljapunova in korelacijska dimenzija

Maksimalni eksponent Ljapunova

Pri uporabi maksimalnega eksponenta Ljapunova so se razlike med skupinama posnetkov, zajetih pred 26. tednom nosečnosti in posnetkov, zajetih kasneje, pokazale le pri posnetkih,

kjer je bil porod prezgoden in ob uporabi filtrov s spodnjo mejo 0.3 Hz, na drugem kanalu. Rezultati uporabe maksimalnega eksponenta Ljapunova so predstavljeni v tabeli 10.9.

Korelacijska dimenzija

Pri uporabi korelacijske dimenzije so bile razlike med skupinama opazne pogosteje. Povprečna vrednost korelacijske dimenzije za skupino posnetkov, zajetih pred 26. tednom se je skoraj vedno razlikovala od povprečne vrednosti korelacijske dimenzije za skupino posnetkov, zajetih med ali po 26. tednu. Verjetnost, da sta povprečni vrednosti enaki, je bila pri posnetkih, kjer je bil porod prezgoden, večja od 0.05 le na 3. kanalu ter na 1. kanalu ob uporabi filtrov s spodnjo mejo 0.3 Hz. Pri posnetkih, kjer je bil porod ob roku, se statistične razlike med skupinama niso pokazale edino na 1. kanalu pri uporabi filtrov s spodnjo mejo 0.3 Hz ter na 3. kanalu pri filtrih od 0.3 Hz do 2.5 Hz ter 0.3 Hz do 3 Hz. Med skupinama vseh posnetkov, zajetih pred 26. tednom nosečnosti ter posnetkov, zajetih kasneje, se statistične razlike niso pokazale pri filtru 0.3 Hz do 2.5 Hz na 3. kanalu, pri filtru 0.3 Hz do 3 Hz na prvem in tretjem kanalu ter pri filtru 0.3 Hz do 4 Hz na prvem kanalu.

Na drugem kanalu so bile statistične razlike pomembne ne glede na izbrani filter. Rezultati uporabe korelacijske dimenzije so predstavljeni v tabeli 10.10.

Vzorčna entropija in večločljivostna vzorčna entropija

Primernost vzorčne entropije za ločevanje skupin posnetkov glede na čas zajema posnetka smo za primerjavo z ostalimi metodami preverili pri parametrih $m = r$ in $r = 0.15$.

Srednja vrednost vzorčne entropije je bila pri vseh posnetkih, zajetih pred 26. tednom nosečnosti, statistično različna od srednje vrednosti vzorčne entropije pri posnetkih, zajetih med 26. tednom nosečnosti ali kasneje, ne glede na izbiro kanala ali filtra. Enako velja za posnetke, kjer je bil porod ob roku.

Pri posnetkih, kjer je bil porod prezgoden, so se statistične razlike med skupinama pokazale le ob uporabi filtrov s spodnjo mejo pri 0.3 Hz na drugem kanalu. Rezultati so predstavljeni v tabeli 10.11.

10.5 Povzetek rezultatov statistične analize

Poleg tega, katere metode so najboljše, nas je zanimalo tudi, kateri pasovno-prepustni filter je najprimernejši za predobdelavo signalov. V ta namen smo izračunane verjetnosti uredili

še po uporabljenih filtrih. Tabele so predstavljene v dodatku A.

Linearne tehnike so se obnesle bolje, ko smo uporabili filtre s spodnjo mejo prepustnega pasu pri 0.3 Hz. Rezultati uporabe filtrov s spodnjo mejo pri 0.3 Hz so predstavljeni v tabelah A.4, A.5 in A.6. Med linearimi tehnikami se je najbolje obnesla mediana frekvence močnostnega spektra. Na tretjem kanalu se je srednja vrednost mediane frekvence pri posnetkih, kjer je bil porod prezgoden, statistično pomembno razlikovala od srednje vrednosti pri posnetkih, kjer je bil porod ob roku, ko smo uporabili filtre s spodnjo mejo 0.3 Hz in zgornjo mejo 2.5 Hz, 3 Hz ali 4 Hz. Vrednosti mediane frekvence za vse posnetke ter njene srednje vrednosti zgodaj in pozno v nosečnosti so predstavljene na sliki 10.10. Verjetnosti, da so bile srednje vrednosti mediane frekvence med skupinami enake, so bile: med $<26\text{-PRE}$ proti $<26\text{-TERM}$ (p_1):0.477, med $>=26\text{-PRE}$ proti $>=26\text{-TERM}$ (p_2):0.046, med $<26\text{-PRE}$ proti $>=26\text{-PRE}$ (p_3):0.035, med $<26\text{-TERM}$ proti $>=26\text{-TERM}$ (p_4):0.014, med unijo $<26\text{-PRE}$ in $<26\text{-TERM}$ (vsemi posnetki, zajetimi zgodaj med nosečnostjo) proti uniji $>=26\text{-PRE}$ in $>=26\text{-TERM}$ (vsem posnetkom, zajetim kasneje med nosečnostjo, p_5): 0.003, med unijo $<26\text{-PRE}$ in $>=26\text{-PRE}$ (vsemi posnetki, kjer je bil porod prezgoden) proti uniji $<26\text{-TERM}$ in $>=26\text{-TERM}$ (vsem posnetkom, kjer je bil porod ob roku, p_6):0.056.

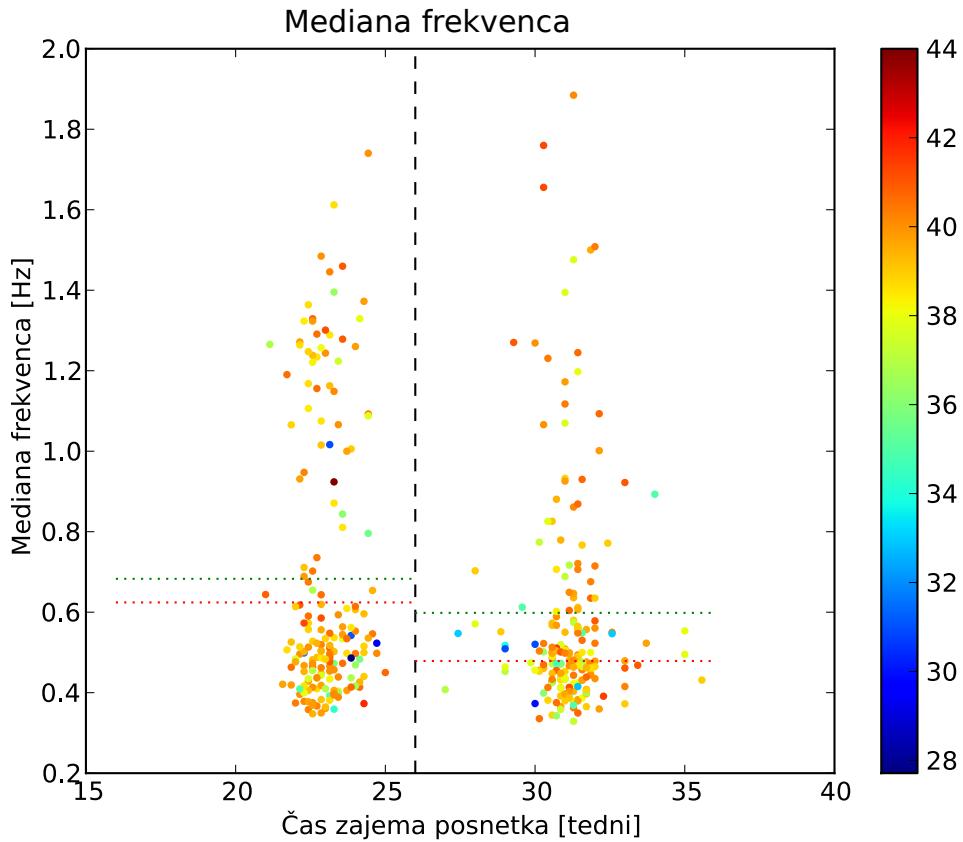
Povprečna vrednost mediane frekvence je bila ob uporabi filtra od 0.3 Hz do 3 Hz na kanalu 1 pri posnetkih, zajetih zgodaj med nosečnostjo, 0.6768 Hz pri standardni deviaciji 0.3383. Povprečna vrednost mediane frekvence pri posnetkih, zajetih kasneje med nosečnostjo, je bila ob uporabi istega filtra na istem kanalu 0.5840 Hz pri standardni deviaciji 0.2751. Močnostni spekter se je torej med nosečnostjo premaknil proti nižjim frekvencam, kar se je skladalo z našimi opažanjji pri pregledovanju močnostnih spektrov posnetkov, kakršni so prikazani na sliki 6.17. Sodeč po rezultatih lahko trdimo, da je za linearne tehnike torej pomembnejša spodnja meja uporabljenega posovno-prepustnega filtra.

Pri uporabi korelacijske dimenzije smo več statistično pomembnih razlik opazili ob uporabi filtrov s spodnjo mejo 0.08 Hz. Rezultati so predstavljeni v tabelah A.1, A.2 in A.3.

V vseh primerih se je za najbolj perspektivno metodo izkazala vzorčna entropija.

Srednja vrednost vzorčne entropije pri posnetkih, kjer je bil porod prezgoden, se je statistično pomembno razlikovala od srednje vrednosti vzorčne entropije pri posnetkih, kjer je bil porod ob roku, ne glede na uporabljeni filter.

Srednja vrednost vzorčne entropije pri posnetkih, zajetih zgodaj v nosečnosti, se je statistično pomembno razlikovala od srednje vrednosti vzorčne entropije pri posnetkih, zajetih pozno v nosečnosti, na vseh kanalih. Vrednosti vzorčne entropije za vse posnetke ter njene srednje vrednosti zgodaj in pozno v nosečnosti so predstavljene na sliki 10.11. Verjetnosti,



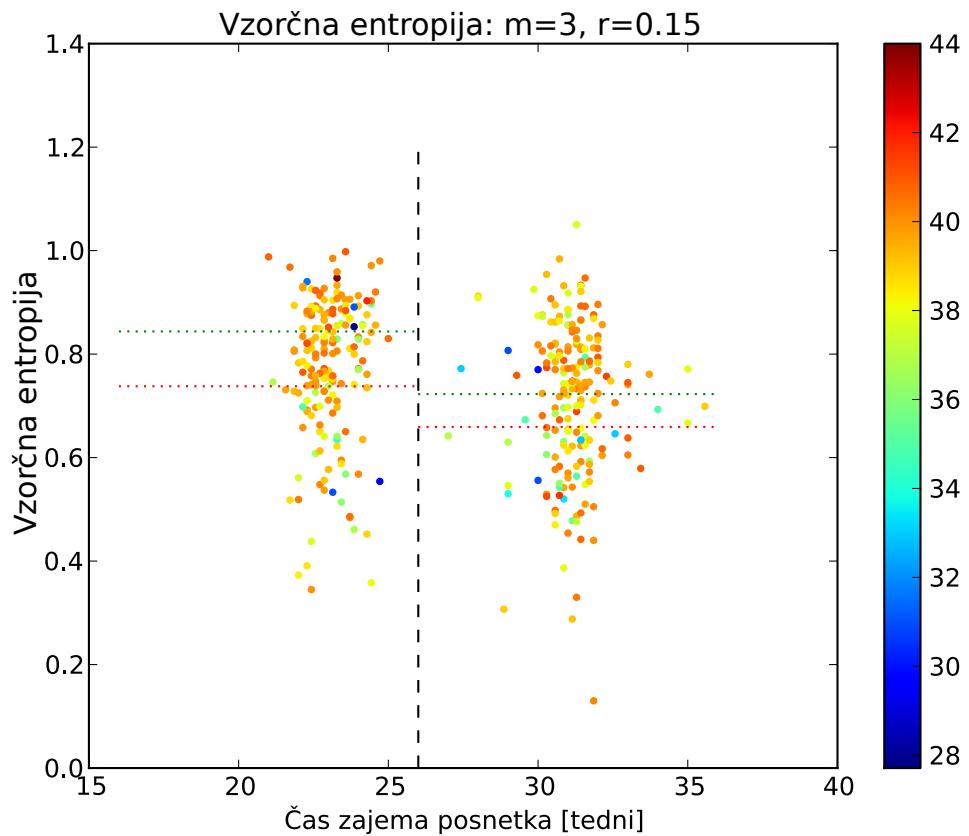
Slika 10.10: Mediane frekvence za skupino z enim posnetkom na nosečnost ob uporabljenem filtru od 0.3 Hz do 3 Hz na kanalu 1. Prikazane so srednje vrednosti za skupine posnetkov <26-PRE (modra), <26-TERM (črtkani črti na levi), >=26-PRE (modra) in >=26-TERM (črtkani črti na desni). Verjetnosti, da so povprečne vrednosti za skupine enake: med <26-PRE proti <26-TERM (p_1):0.477, med >=26-PRE proti >=26-TERM (p_2):0.046, med <26-PRE proti >=26-PRE (p_3):0.035 , med <26-TERM proti >=26-TERM (p_4):0.014, med unijo <26-PRE in <26-TERM (vsemi posnetki, zajetimi zgodaj med nosečnostjo) proti uniji >=26-PRE in >=26-TERM (vsem posnetkom, zajetim kasneje med nosečnostjo, p_5): 0.003, med unijo <26-PRE in >=26-PRE (vsemi posnetki, kjer je bil porod prezgoden) proti uniji <26-TERM in >=26-TERM (vsem posnetkom, kjer je bil porod ob roku, p_6):0.056.

da so bile srednje vrednosti vzorčne entropije med skupinami enake, ob uporabi filtra od 0.3 Hz do 3 Hz, so bile: med <26-PRE proti <26-TERM (p_1):0.067, med >=26-PRE proti >=26-TERM (p_2):0.042, med <26-PRE proti >=26-PRE (p_3):0.125 , med <26-TERM proti >=26-TERM (p_4): ≤ 0.001 , med unijo <26-PRE in <26-TERM (vsemi posnetki, zajetimi zgodaj med nosečnostjo) proti uniji >=26-PRE in >=26-TERM (vsem posnetkom, zajetim

kasneje med nosečnostjo, p_5): ≤ 0.001 , med unijo $<26\text{-PRE}$ in $>=26\text{-PRE}$ (vsemi posnetki, kjer je bil porod prezgoden) proti uniji $<26\text{-TERM}$ in $>=26\text{-TERM}$ (vsem posnetkom, kjer je bil porod ob roku, p_6): 0.005 .

Povprečna vrednost vzorčne entropije pri $r = 0.15$ in $m = 3$ je bila ob uporabi filtra od 0.3 Hz do 3 Hz na kanalu 3 pri posnetkih, zajetih zgodaj med nosečnostjo, 0.7758, standardna deviacija pa 0.1358. Povprečna vrednost vzorčne entropije pri posnetkih, zajetih kasneje med nosečnostjo, je bila ob uporabi istega filtra na istem kanalu 0.7151, standardna deviacija pa 0.1430. To pomeni, da je bila električna aktivnost zgodaj v nosečnosti bolj naključna, kot kasneje. Povprečna vrednost vzorčne entropije pri $r = 0.15$ in $m = 3$ pri posnetkih, kjer je bil porod prezgoden, ob uporabi filtra od 0.3 Hz do 3 Hz, je bila 0.6868, standardna deviacija pa 0.1304. Pri posnetkih, kjer je bil porod ob roku, je bila ob uporabi istega filtra srednja vrednost vzorčne entropije pri istih parametrih 0.7513, standardna deviacija pa 0.1428. Pri posnetkih, kjer je bil porod prezgoden je bila torej v povprečju srednja vrednost vzorčne entropije nižja, kot pri posnetkih, kjer je bil porod ob roku. To opažanje se je skladalo s predvidevanji, do katerih smo prišli ob opazovanju slike 2.1.

Srednje vrednosti večine cenilk pri posnetkih, zajetih zgodaj v nosečnosti, so se statistično pomembno razlikovale od srednjih vrednosti teh istih cenilk, zajetih pozno v nosečnosti.



Slika 10.11: Vzorčne entropije pri $m = 3$ in $r = 0.15$ za skupino z enim posnetkom na nosečnost ob uporabljenem filtru od 0.3 Hz do 3 Hz na kanalu 3. Prikazane so srednje vrednosti za skupine posnetkov $<26\text{-PRE}$ (modra), $<26\text{-TERM}$ (črtkani črti na levi), $>=26\text{-PRE}$ (modra) in $>=26\text{-TERM}$ (črtkani črti na desni). Verjetnosti, da so povprečne vrednosti za skupine enake: med $<26\text{-PRE}$ proti $<26\text{-TERM}$ (p_1):0.067, med $>=26\text{-PRE}$ proti $>=26\text{-TERM}$ (p_2):0.042, med $<26\text{-PRE}$ proti $>=26\text{-PRE}$ (p_3):0.125, med $<26\text{-TERM}$ proti $>=26\text{-TERM}$ (p_4): ≤ 0.001 , med unijo $<26\text{-PRE}$ in $<26\text{-TERM}$ (vsemi posnetki, zajetimi zgodaj med nosečnostjo) proti uniji $>=26\text{-PRE}$ in $>=26\text{-TERM}$ (vsem posnetkom, zajetim kasneje med nosečnostjo, p_5): ≤ 0.001 , med unijo $<26\text{-PRE}$ in $>=26\text{-PRE}$ (vsemi posnetki, kjer je bil porod prezgoden) proti uniji $<26\text{-TERM}$ in $>=26\text{-TERM}$ (vsem posnetkom, kjer je bil porod ob roku, p_6):0.005.

Tabela 10.12: Števila posnetkov v skupinah z dvema posnetkoma na nosečnost

Skupina	Št. nosečnosti	Št. posnetkov
<26-PRE (ZP)	14	14
≥ 26 -PRE (KP)	14	14
<26-TERM (ZR)	126	126
≥ 26 -TERM (KR)	126	126

10.5.1 Spremembe cenilk med nosečnostjo

V primerih, ko sta bila zajeta po dva posnetka na nosečnost, smo lahko opazovali spremembe cenilk skozi čas. Če bi bile spremembe pri posnetkih, kjer je bil porod prezgoden, drugačne kot pri posnetkih, kjer je bil porod ob roku, bi lahko morda prezgodnji porod napovedovali na osnovi samih sprememb. Posnetke smo spet razdelili v štiri skupine glede na trajanje nosečnosti in glede na čas zajema posnetka. Števila posnetkov v skupinah so predstavljena v tabeli 10.12. Prav tako bi lahko na osnovi sprememb cenilk med nosečnostjo sklepali o tem, ali se dana cenilka med nosečnostjo pri večini žensk res spreminja. Kadar je za vsako nosečnost dostopen le en posnetek, je namreč vedno možno, da so razlike med skupinami posnetkov v resnici posledica razlik med ženskami, ki so bile slučajno pregledane.

Koren srednje kvadratne vrednosti signala

Pri posnetkih, kjer je bil porod prezgoden, spremembe vrednosti RMS niso bile statistično pomembne. Drugače je bilo pri nosečnostih, kjer je bil porod ob roku, saj je do statistično pomembnih sprememb v vrednosti cenilke prišlo na tretjem kanalu ob uporabi vseh filtrov, razen filtra od 0.3 Hz do 4 Hz. V primeru, ko smo opazovali spremembe med nosečnostjo za vse posnetke, so se statistično pomembne spremembe pokazale na drugem kanalu pri uporabi filtrov z zgornjo mejo 4 Hz ter na drugem in tretjem kanalu pri uporabi ostalih filtrov.

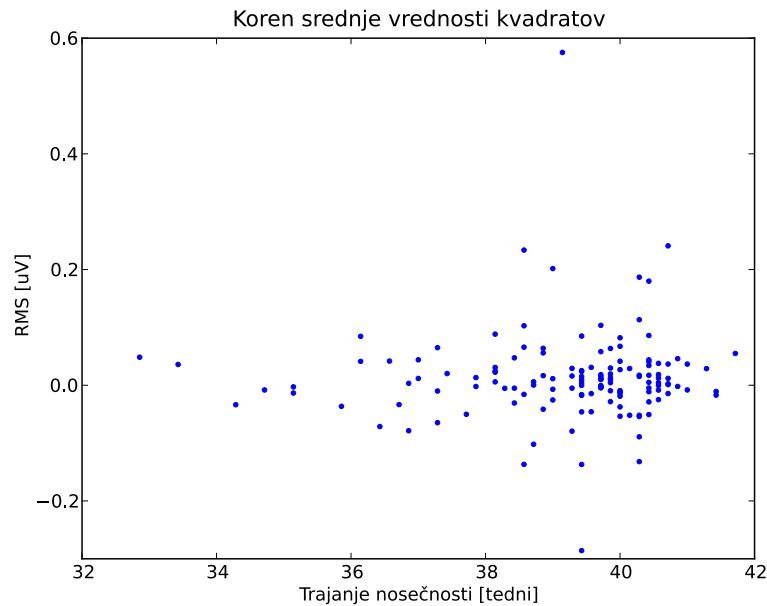
Srednja vrednost vzorčne entropije je bila pri vseh posnetkih, zajetih pred 26. tednom nosečnosti, statistično različna od srednje vrednosti vzorčne entropije pri posnetkih, zajetih med 26. tednom nosečnosti ali kasneje, ne glede na izbiro kanala ali filtra.

Spremembe vrednosti RMS pri nosečnostih, kjer je bil porod prezgoden, se niso statistično pomembno razlikovale od sprememb vrednosti RMS pri nosečnostih, kjer je bil porod ob roku.

Tabela 10.13: Koren srednje vrednosti kvadratov - povzetek rezultatov za spremembe med nosečnostjo

Filter	Kanal	p_3	p_4	p_5	p_6
0.08Hz - 2.5Hz	1	0.677	0.646	0.576	0.901
	2	0.240	0.060	0.032	0.657
	3	0.960	0.046	0.048	0.476
0.08Hz - 3Hz	1	0.681	0.660	0.589	0.900
	2	0.240	0.058	0.031	0.660
	3	0.961	0.047	0.049	0.477
0.08Hz - 4Hz	1	0.687	0.692	0.621	0.896
	2	0.241	0.057	0.030	0.666
	3	0.964	0.049	0.051	0.479
0.3Hz - 2.5Hz	1	0.602	0.715	0.618	0.793
	2	0.066	0.089	0.040	0.512
	3	0.991	0.035	0.038	0.450
0.3Hz - 3Hz	1	0.627	0.806	0.709	0.790
	2	0.067	0.091	0.042	0.530
	3	0.981	0.041	0.044	0.458
0.3Hz - 4Hz	1	0.685	0.987	0.922	0.782
	2	0.071	0.102	0.049	0.560
	3	0.937	0.053	0.059	0.463

Rezultati uporabe korena srednje kvadratne vrednosti signala so predstavljeni v tabeli 10.13 in na sliki 10.12.



Slika 10.12: Spremembe korena srednje kvadratne vrednosti signala skozi nosečnost.

Tabela 10.14: Frekvenca vrha močnostnega spektra - povzetek rezultatov za spremembe med nosečnostjo

Filter	Kanal	p_3	p_4	p_5	p_6
0.08Hz - 2.5Hz	1	0.135	0.108	0.204	0.105
	2	0.245	0.187	0.151	0.917
	3	0.329	0.991	0.940	0.801
0.08Hz - 3Hz	1	0.135	0.108	0.204	0.105
	2	0.245	0.187	0.151	0.917
	3	0.329	0.991	0.940	0.801
0.08Hz - 4Hz	1	0.135	0.978	0.867	0.650
	2	0.245	0.651	0.676	0.808
	3	0.329	0.415	0.404	0.843
0.3Hz - 2.5Hz	1	0.284	≤ 0.001	≤ 0.001	0.455
	2	0.427	0.229	0.166	0.703
	3	0.427	≤ 0.001	≤ 0.001	0.348
0.3Hz - 3Hz	1	0.284	≤ 0.001	≤ 0.001	0.386
	2	0.427	0.375	0.293	0.720
	3	0.427	≤ 0.001	≤ 0.001	0.312
0.3Hz - 4Hz	1	0.284	0.001	≤ 0.001	0.460
	2	0.427	0.972	0.861	0.638
	3	0.427	0.001	0.001	0.455

Frekvenca vrha močnostnega spektra signala

Tudi pri spremeljanju sprememb frekvence vrha močnostnega spektra pri nosečnostih, kjer je bil porod prezgoden, nismo opazili statistično pomembnih sprememb.

Spremembe pri nosečnostih, kjer je bil porod ob roku, so bile statistično pomembne pri uporabi filtrov s spodnjo mejo 0.3 Hz in zgornjo mejo pri 2.5 Hz, 3 Hz ali 4 Hz na prvem in tretjem kanalu, torej v vzdolžni smeri. Prav tako so bile spremembe statistično pomembne ob uporabi istih filtrov in na istih kanalih pri nosečnostih, kjer je bil porod ob roku.

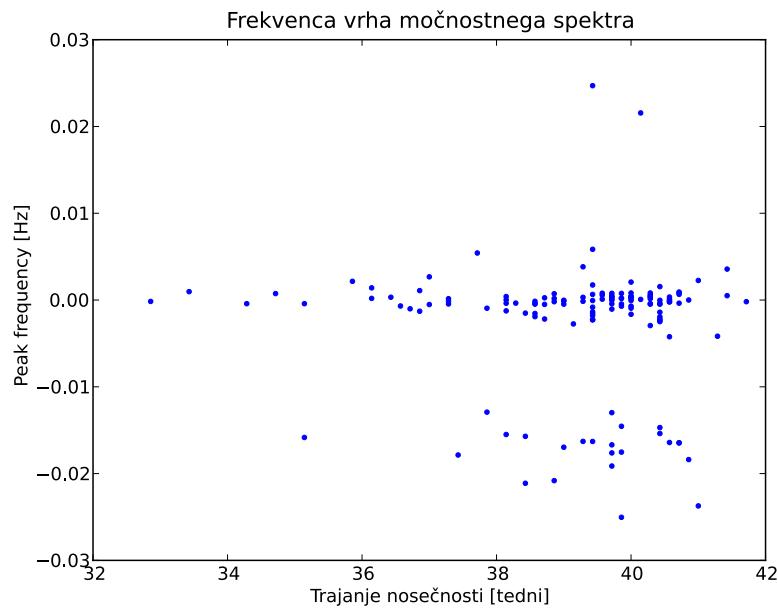
Ob uporabi drsečega okna in povprečenja močnostnega spektra so bile spremembe statistično pomembne tudi na 2. kanalu ob uporabi filtrov s spodnjo mejo 0.3 Hz in zgornjima mejama 2.5 Hz in 3 Hz.

Spremembe vrednosti frekvence vrha močnostnega spektra pri nosečnostih, kjer je bil porod prezgoden, se niso statistično pomembno razlikovale od sprememb vrednosti frekvence vrha močnostnega spektra pri nosečnostih, kjer je bil porod ob roku.

Rezultati uporabe frekvence vrha močnostnega spektra signala so predstavljeni v tabelah 10.14 in 10.15 ter na sliki 10.13.

Tabela 10.15: Frekv. vrha močnostnega spektra z drsečim oknom - povzetek rezultatov za spremembe med nosečnostjo

Filter	Kanal	p_3	p_4	p_5	p_6
0.08Hz - 2.5Hz	1	0.658	0.088	0.077	0.854
	2	0.200	0.858	0.745	0.692
	3	0.308	0.647	0.718	0.598
0.08Hz - 3Hz	1	0.598	0.109	0.090	0.986
	2	0.202	0.859	0.951	0.680
	3	0.307	0.616	0.686	0.588
0.08Hz - 4Hz	1	0.538	0.669	0.620	0.926
	2	0.202	0.383	0.405	0.678
	3	0.303	0.558	0.535	0.942
0.3Hz - 2.5Hz	1	0.209	≤ 0.001	≤ 0.001	0.618
	2	0.445	0.021	0.015	0.860
	3	0.210	≤ 0.001	≤ 0.001	0.551
0.3Hz - 3Hz	1	0.199	≤ 0.001	≤ 0.001	0.552
	2	0.457	0.031	0.023	0.885
	3	0.242	≤ 0.001	≤ 0.001	0.448
0.3Hz - 4Hz	1	0.149	0.001	≤ 0.001	0.643
	2	0.470	0.338	0.286	0.934
	3	0.188	0.006	0.003	0.917



Slika 10.13: Spremembe frekvence vrha močnostnega spektra signala skozi nosečnost.

Tabela 10.16: Mediana frekvenca - povzetek rezultatov za spremembe med nosečnostjo

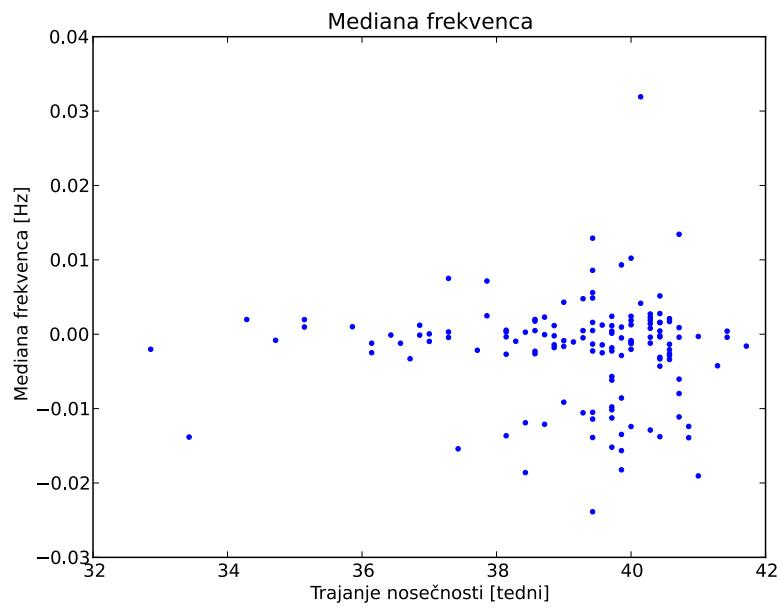
Filter	Kanal	p_3	p_4	p_5	p_6
0.08Hz - 2.5Hz	1	0.093	0.218	0.286	0.351
	2	0.425	0.751	0.796	0.776
	3	0.489	0.416	0.450	0.616
0.08Hz - 3Hz	1	0.096	0.366	0.440	0.496
	2	0.373	0.584	0.621	0.734
	3	0.517	0.491	0.521	0.681
0.08Hz - 4Hz	1	0.111	0.576	0.640	0.664
	2	0.315	0.413	0.438	0.691
	3	0.560	0.844	0.864	0.873
0.3Hz - 2.5Hz	1	0.276	0.002	0.001	0.769
	2	0.662	0.204	0.182	0.875
	3	0.704	0.001	0.001	0.450
0.3Hz - 3Hz	1	0.235	0.001	≤0.001	0.663
	2	0.541	0.251	0.207	0.944
	3	0.543	0.001	0.001	0.626
0.3Hz - 4Hz	1	0.182	0.001	≤0.001	0.829
	2	0.471	0.217	0.175	0.954
	3	0.473	≤0.001	≤0.001	0.552

Mediana frekvenca močnostnega spektra signala

Pri spremljanju mediane frekvence močnostnega spektra so bili rezultati zelo podobni, kot pri spremljanju frekvence vrha močnostnega spektra. Statistično pomembne spremembe smo opazili na drugem in tretjem kanalu pri uporabi filtrov s spodnjo mejo 0.3 Hz, ne glede na to ali smo uporabili drseče okno in povprečenje močnostnega spektra ali ne. Vrednosti p Studentovega t-testa so bile praviloma nižje, kot pri spremljanju sprememb frekvence vrha močnostnega spektra. Rezultati uporabe mediane frekvence močnostnega spektra so predstavljeni v tabelah 10.16 in 10.17 ter na sliki 10.14.

Tabela 10.17: Mediana frekvenca z drsečim oknom - povzetek rezultatov za spremembe med nosečnostjo

Filter	Kanal	p_3	p_4	p_5	p_6
0.08Hz - 2.5Hz	1	0.620	0.246	0.210	0.982
	2	0.721	0.578	0.600	0.778
	3	0.273	0.773	0.839	0.691
0.08Hz - 3Hz	1	0.513	0.300	0.239	0.827
	2	0.660	0.494	0.514	0.745
	3	0.218	0.803	0.863	0.732
0.08Hz - 4Hz	1	0.407	0.453	0.358	0.726
	2	0.462	0.427	0.452	0.697
	3	0.246	0.993	0.956	0.880
0.3Hz - 2.5Hz	1	0.114	≤ 0.001	≤ 0.001	0.875
	2	0.475	0.286	0.231	0.882
	3	0.867	≤ 0.001	≤ 0.001	0.313
0.3Hz - 3Hz	1	0.093	≤ 0.001	≤ 0.001	0.845
	2	0.396	0.302	0.233	0.810
	3	0.866	≤ 0.001	≤ 0.001	0.265
0.3Hz - 4Hz	1	0.162	≤ 0.001	≤ 0.001	0.760
	2	0.292	0.315	0.229	0.726
	3	0.476	≤ 0.001	≤ 0.001	0.544



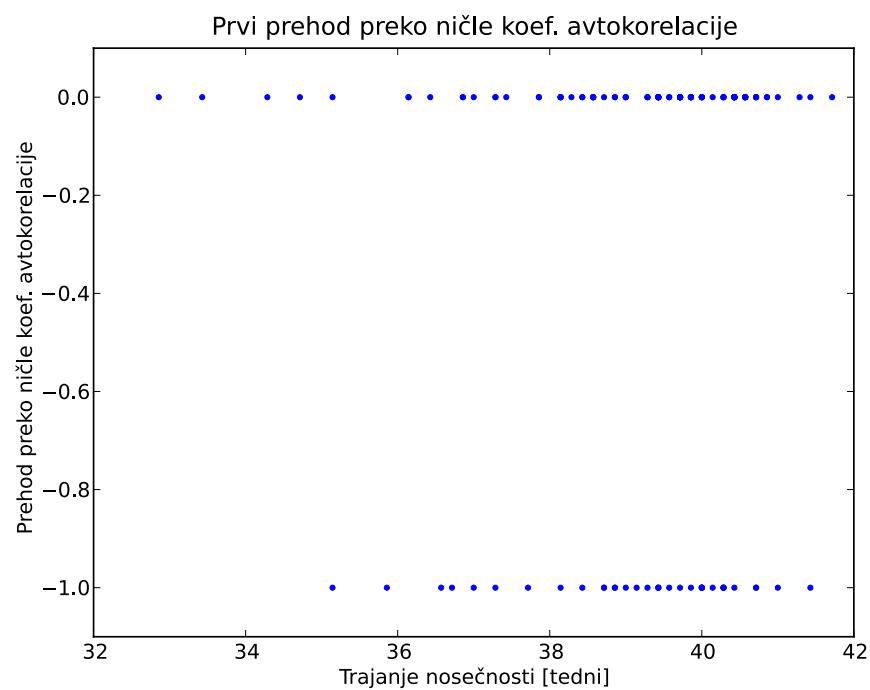
Slika 10.14: Spremembe mediane frekvence močnostnega spektra signala skozi nosečnost.

Tabela 10.18: Prvi prehod preko ničle koef. avtokorelacijs - povzetek rezultatov za spremembe med nosečnostjo

Filter	Kanal	p_3	p_4	p_5	p_6
0.08Hz - 2.5Hz	1	0.242	0.052	0.119	0.284
	2	0.845	0.049	0.058	0.953
	3	0.298	0.745	0.957	0.197
0.08Hz - 3Hz	1	0.242	0.078	0.165	0.284
	2	0.793	0.054	0.066	0.953
	3	0.315	0.789	0.991	0.218
0.08Hz - 4Hz	1	0.205	0.093	0.198	0.128
	2	0.683	0.055	0.071	0.953
	3	0.284	0.695	0.905	0.218
0.3Hz - 2.5Hz	1	0.193	0.405	0.262	0.151
	2	1.000	0.760	0.765	0.535
	3	0.935	≤0.001	≤0.001	0.849
0.3Hz - 3Hz	1	0.209	0.353	0.230	0.184
	2	0.890	0.613	0.641	0.572
	3	1.000	≤0.001	≤0.001	0.849
0.3Hz - 4Hz	1	0.762	0.119	0.112	0.865
	2	0.880	0.542	0.569	0.572
	3	0.557	≤0.001	≤0.001	0.536

Prvi prehod preko ničle koeficientov avtokorelacijs

Spremembe prvega prehoda preko ničle koeficientov avtokorelacijs so bile večinoma majhne. Ker je prehod preko ničle koeficientov avtokorelacijs celo število, so bile tudi spremembe med nosečnostjo cela števila. Tudi v primeru, ko so bile spremembe v prvem prehodu preko ničle koeficientov avtokorelacijs med nosečnostjo statistično pomembne, se je položaj prvega prehoda preko ničle spremenjal kvečjemu za en vzorec. Rezultati so predstavljeni v tabeli 10.18 in na sliki 10.15.



Slika 10.15: Spremembe prvega prehoda preko ničle koeficientov avtokorelacijske skozi nosečnost.

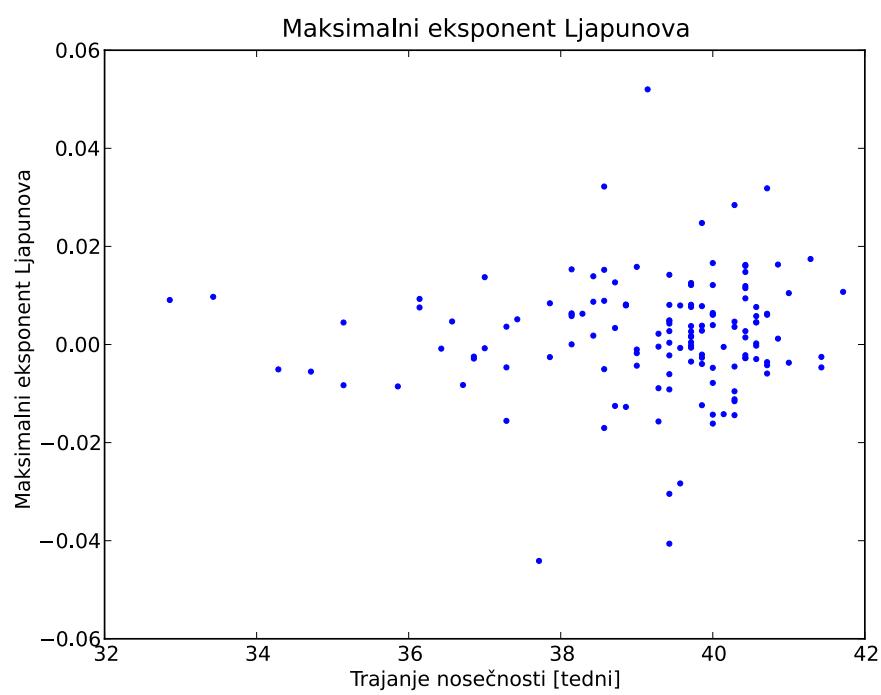
Tabela 10.19: Maksimalni eksponent Ljapunova - povzetek rezultatov za spremembe med nosečnostjo

Filter	Kanal	p_3	p_4	p_5	p_6
0.08Hz - 2.5Hz	1	0.488	0.856	0.703	0.620
	2	0.166	0.088	0.043	0.529
	3	0.885	0.049	0.050	0.588
0.08Hz - 3Hz	1	0.509	0.990	0.834	0.606
	2	0.169	0.090	0.044	0.528
	3	0.917	0.062	0.064	0.592
0.08Hz - 4Hz	1	0.580	0.963	0.904	0.663
	2	0.176	0.083	0.041	0.550
	3	0.837	0.071	0.069	0.636
0.3Hz - 2.5Hz	1	0.544	0.757	0.909	0.560
	2	0.083	0.174	0.078	0.346
	3	0.991	0.128	0.139	0.628
0.3Hz - 3Hz	1	0.580	0.589	0.721	0.551
	2	0.088	0.185	0.086	0.356
	3	0.964	0.170	0.186	0.631
0.3Hz - 4Hz	1	0.629	0.328	0.423	0.506
	2	0.103	0.205	0.101	0.388
	3	0.845	0.262	0.297	0.610

Maksimalni eksponent Ljapunova in korelacijska dimenzija

Maksimalni eksponent Ljapunova

Spremembe v maksimalnem eksponentu Ljapunova so bile le redko statistično pomembne. Pri nosečnostih, kjer je bil porod prezgoden, razlik nismo zaznali. Pri nosečnostih, kjer je bil porod ob roku, so bile razlike opazne le na tretjem kanalu ob uporabi filtra 0.08 Hz do 3 Hz. Za vse nosečnosti skupaj so bile razlike opazne na tretjem kanalu pri uporabi filtra od 0.08 Hz do 2.5 Hz ter na drugem kanalu ob uporabi filtrov s spodnjo mejo 0.08 Hz. V vseh navedenih primerih so bile vrednosti p le malo pod mejo 0.05. Rezultati uporabe maksimalnega eksponenta Ljapunova so predstavljeni v tabeli 10.19 in na sliki 10.16.



Slika 10.16: Spremembe maksimalnega eksponenta Ljapunova skozi nosečnost.

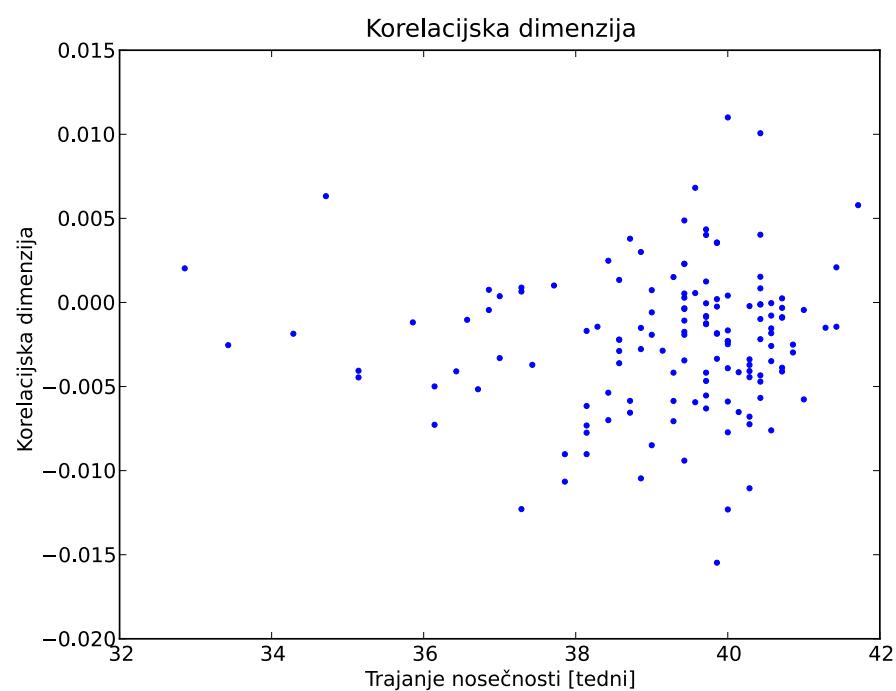
Tabela 10.20: Korelacijska dimenzija - povzetek rezultatov za spremembe med nosečnostjo

Filter	Kanal	p_3	p_4	p_5	p_6
0.08Hz - 2.5Hz	1	0.159	≤ 0.001	≤ 0.001	0.785
	2	0.092	≤ 0.001	≤ 0.001	0.524
	3	0.416	≤ 0.001	≤ 0.001	0.366
0.08Hz - 3Hz	1	0.120	≤ 0.001	≤ 0.001	0.988
	2	0.046	≤ 0.001	≤ 0.001	0.798
	3	0.295	≤ 0.001	≤ 0.001	0.486
0.08Hz - 4Hz	1	0.099	≤ 0.001	≤ 0.001	0.937
	2	0.054	≤ 0.001	≤ 0.001	0.698
	3	0.410	≤ 0.001	≤ 0.001	0.436
0.3Hz - 2.5Hz	1	0.169	0.041	0.026	0.943
	2	0.253	0.001	0.001	0.893
	3	0.885	0.082	0.088	0.796
0.3Hz - 3Hz	1	0.236	0.088	0.065	0.904
	2	0.277	0.002	0.001	0.930
	3	0.734	0.127	0.117	0.921
0.3Hz - 4Hz	1	0.264	0.184	0.145	0.961
	2	0.076	0.003	0.001	0.740
	3	0.982	0.117	0.133	0.646

Korelacijska dimenzija

Korelacijska dimenzija se je med nosečnostjo spremenjala bistveno bolj, kot maksimalni eksponent Ljapunova. Pri vseh nosečnostih skupaj ter pri nosečnostih, kjer je bil porod ob roku, so bile spremembe statistično pomembne skoraj v vseh primerih. Statistično pomembne spremembe smo tako opazili na vseh kanalih za filtre s spodnjo mejo 0.08 Hz, na prvem in drugem kanalu za filter od 0.3 Hz do 2.5 Hz ter na drugem kanalu za preostala dva filtra s spodnjo mejo 0.3 Hz.

Statistično pomembne spremembe smo opazili tudi pri nosečnostih, kjer je bil porod pred rokom, ob uporabi filtra od 0.08 Hz do 3 Hz na drugem kanalu. Rezultati uporabe korelacijske dimenzije so predstavljeni v tabeli 10.20 in na sliki 10.17.



Slika 10.17: Spremembe korelacijske dimenzije skozi nosečnost.

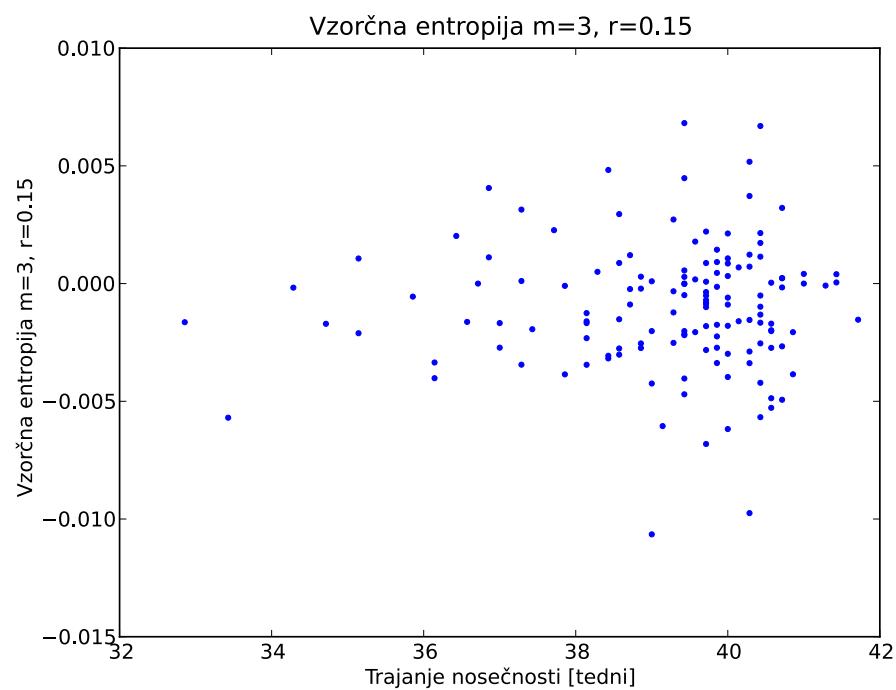
Tabela 10.21: Vzorčna entropija $m=3$, $r=0.15$ - povzetek rezultatov za spremembe tekom nosečnosti

Filter	Sig	p_3	p_4	p_5	p_6
0.08Hz - 2.5Hz	1	0.671	≤ 0.001	≤ 0.001	0.427
	2	0.128	0.002	≤ 0.001	0.758
	3	0.446	≤ 0.001	≤ 0.001	0.399
0.08Hz - 3Hz	1	0.433	≤ 0.001	≤ 0.001	0.593
	2	0.120	0.001	≤ 0.001	0.717
	3	0.243	≤ 0.001	≤ 0.001	0.473
0.08Hz - 4Hz	1	0.329	≤ 0.001	≤ 0.001	0.910
	2	0.133	≤ 0.001	≤ 0.001	0.774
	3	0.170	≤ 0.001	≤ 0.001	0.692
0.3Hz - 2.5Hz	1	0.436	0.004	0.003	0.897
	2	0.094	0.001	≤ 0.001	0.540
	3	0.183	≤ 0.001	≤ 0.001	0.865
0.3Hz - 3Hz	1	0.385	0.003	0.002	0.809
	2	0.040	≤ 0.001	≤ 0.001	0.356
	3	0.131	≤ 0.001	≤ 0.001	0.936
0.3Hz - 4Hz	1	0.472	0.009	0.007	0.836
	2	0.010	≤ 0.001	≤ 0.001	0.133
	3	0.101	≤ 0.001	≤ 0.001	0.969

Vzorčna entropija in večločljivostna vzorčna entropija

Kot pri oceni razlik med skupinami posnetkov, smo tudi pri oceni sprememb upoštevali vzorčno entropijo pri $m = 3$ in $r = 0.15$.

Statistično pomembne razlike so se pojavile pri vseh nosečnostih in pri nosečnostih, kjer je bil porod prezgoden, ne glede na opazovani kanal in uporabljeni filter. Prav tako so bile statistično pomembne spremembe pri nosečnostih, kjer je bil porod prezgoden, na drugem kanalu ob uporabi filtrov od 0.3 Hz do 3 Hz ter od 0.3 Hz do 4 Hz. Rezultati uporabe vzorčne entropije pri $m = 3$ in $r = 0.15$ so predstavljeni v tabeli 10.21 in na sliki 10.18.



Slika 10.18: Spremembe vzorčne entropije skozi nosečnost pri $m = 3$ in $r = 0.15$ pri uporabljenem filtru od 0.3 Hz do 2.5 Hz na kanalu 3

POGLAVJE 11

Avtomatska klasifikacija posnetkov

Dolgoročni cilj programa, v okviru katerega se je izvajala raziskava, predstavljena v tem delu, je izboljšati napovedni model za prezgodnji porod, še posebej zgodaj v nosečnosti. Da bi preizkusili primernost našega nabora cenilk za napovedovanje prezgodnjega poroda, smo na izračunanih cenilkah preizkusili nekaj klasifikatorjev. Za preizkušanje klasifikatorjev smo uporabili orodje in ogrodje za podatkovno rudarjenje, Orange [49], ki smo ga rahlo dodelali v skladu s svojimi potrebami.

Orange je ogrodje, ki je večinoma spisano v programskem jeziku PYTHON. Vsebuje tudi uporabniški vmesnik, s pomočjo katerega lahko tudi manj izkušeni uporabniki, ki ne znajo programirati v PYTHONU, uporablajo napredne algoritme za podatkovno rudarjenje. Programiranje se v tem primeru izvaja grafično, s povezovanjem raznovrstnih gradnikov. Med gradniki tako najdemo različne klasifikatorje, orodja za vizualizacijo naborov podatkov ter orodja za ocenjevanje uspešnosti klasifikatorjev.

Za dostop do v naši podatkovni bazi shranjenih podatkov, smo za okolje Orange implementirali gradnik za dostop do relacijskih baz podatkov. Gradnik omogoča branje podatkov iz baze s pomočjo poljubnega SQL stavka, pri čemer se tipi podatkov, ki nastopajo v bazi, samodejno prevajajo v tipe, ki jih pozna Orange.

Za preverjanje primernosti našega nabora cenilk smo uporabili dva klasifikatorja - naivni Bayesov klasifikator in klasifikacijsko drevo. Naivni Bayesov klasifikator smo izbrali zaradi njegove preprostosti, robustnosti in nizke računske zahtevnosti. Odločitvena drevesa smo izbrali zato, ker so pravila, ki jih z njihovo uporabo dobimo, človeku dokaj razumljiva in ker niso tako zelo dovetna za težave, ki izvirajo iz medsebojno povezanih lastnosti primerov, ki jih poizkušamo klasificirati.

Nekatere cenilke, ki smo jih uporabili, so med seboj povezane. Tako sta vrh močnostnega

spektra in mediana frekvenca odvisna od razporeditve frekvenc v močnostnem spektru signala. Podobno maksimalni eksponent Ljapunova, korelacijska dimenzija in vzorčna entropija ocenjujejo kompleksnost signala. Poleg tega so signali istega posnetka prav tako povezani med seboj. Da bi izboljšali delovanje klasifikatorjev, smo s pomočjo metode principalnih komponent izračunali kompozitne cenilke in posnetke poizkusili klasificirati še na osnovi le-teh.

11.1 Naivni Bayesov klasifikator

Naivni Bayesov klasifikator je osnovan na naivni predpostavki, da so lastnosti primera, ki ga poizkušamo klasificirati, neodvisne druga od druge. Če ima vsak primer v učni množici lastnosti $F_{1,\dots,k}$ in pripada enemu iz množice med seboj tujih razredov C , lahko za vse primere izračunamo verjetnosti, da pripadajo danim razredom. S pomočjo Bayesovega izreka lahko z enačbo 11.1 pri danih lastnostih neznanega primera $F_{1,\dots,k}$, izračunamo verjetnost, da pripada razredu C .

$$p(C|F) = \frac{p(F_1|C)p(F_2|C)\dots p(F_k|C)p(C)}{p(F)} . \quad (11.1)$$

Pri tem smo privzeli, da so lastnosti $F_{1,\dots,k}$ med seboj neodvisne.

Ker je imenovalec $p(F)$ vnaprej neznan, ga moramo iz izraza izločiti. Na srečo imenovalec ni odvisen od razreda C . To pomeni, da ga lahko iz različnih ocen verjetnosti pripadanja posameznim razredom izpostavimo. Če velja 11.2 sklepamo, da dani primer z naborom lastnosti $f_{1,\dots,k}$ pripada razredu c :

$$p(c) = \max\left(\prod_{i=1}^k p(f_i|c_j)); c_j \in C\right) . \quad (11.2)$$

Ne glede na preprostost se naivni Bayesov klasifikator pri napovedovanju prezgodnjega poroda obnese precej dobro [2]. Poleg tega lahko s pomočjo vizualizacije vpliva posameznih lastnosti vzorca na odločitev, v kateri razred spada poljuben vzorec, ocenimo, katere cenilke so najbolj uporabne [50].

11.2 Klasifikacija z odločitvenimi drevesi

V splošnem so odločitvena drevesa orodje za podporo pri odločanju na osnovi poljubnih dejstev. V vozliščih drevesa se nahajajo pogoji, v katerih nastopajo dejstva, v listih pa

možne odločitve, kaj storiti. Kot orodje za odločanje so odločitvena drevesa uporabljali že pred široko razprostranjenostjo računalnikov. Računalniki nam omogočajo avtomatično izdelavo odločitvenih dreves na osnovi nabora primerov. V takšnih primerih vsaka odločitev v poljubnem listu drevesa predstavlja izbiro, da dani primer pripada nekemu razredu. Pri izdelavi odločitvenih dreves se takoj soočimo z vprašanjem, kakšne pogoje zapisati v katera vozlišča, da bo drevo čim manjše ter čim bolj plitvo, obenem pa bo pravilno klasificiralo čim več učnih primerov. Ker je izdelava optimalnega odločitvenega drevesa računsko zelo zahtevna, se za določanje pogojev v vozliščih uporablja različne hevristike. Ena izmed najbolje znanih in široko uporabljanih hevristik je uporaba pribitka informacije (*information gain*) za izbiro pogojev za vejitve [51].

11.2.1 Pribitek informacije

Količina informacije, ki jo nosi sistem, je odvisna od njegove entropije. Entropijo sistema S , ki lahko zavzame med seboj tuja stanja s_1, \dots, s_N z verjetnostmi p_{s_1}, \dots, p_{s_N} , lahko izračunamo s pomočjo 11.3.

$$En(S) = - \sum_{i=1}^N p_{s_i} \log_2(p_{s_i}) . \quad (11.3)$$

Seveda mora veljati 11.4.

$$\sum_{i=1}^N p_{s_i} = 1 . \quad (11.4)$$

V primeru, ko je ena od verjetnosti $p_{s_1} \dots p_{s_N}$ enaka 1, in so torej ostale verjetnosti enake 0, je entropija sistema po dogovoru enaka 0.

Da bi določili, koliko informacije pridobimo z vpeljavo nekega pogoja, je potrebno določiti, koliko manj informacije potrebujemo za opis novega sistema. Vsako vozlišče v odločitvenem drevesu le-to razdeli na najmanj dve poddrevesi, ki ju lahko obravnavamo kot ločena podsistema S_1 in S_2 . Verjetnost, da se sistem nahaja v enem od stanj podsistema S_1 , označimo s p_{S_1} . Verjetnost, da se sistem nahaja v enem od stanj podsistema S_2 , označimo s p_{S_2} . Entropijo nastalega sistema potem izračunamo po 11.5.

$$En(S_1, S_2) = p_{S_1} \cdot En(S_1) + p_{S_2} \cdot En(S_2) . \quad (11.5)$$

Ker sta si s_1 in s_2 tuji in neodvisni, skupaj pa tvorita poln sistem, je vsota p_{S_1} in p_{S_2} natanko enaka 1. Obenem velja, da entropija sistema z neničelno entropijo ostane nespremenjena natanko tedaj, ko mu dodamo podsistem z entropijo enako 0. V primeru, da

pogoj odločitveno drevo razdeli na več poddreves, entropijo določimo tako, da izračunamo entropijo prvih dveh poddreves skupaj, nato dodamo tretje, itd. do zadnjega poddrevesa.

Da bi določili, kateri pogoj je za vejitev najprimernejši, se je za dobro izkazala hevristika, po kateri se za vejitev vedno najprej uporabi tisti pogoj, pri katerem bo razlika med entropijo drevesa pred vejitvijo in entropijo drevesa po vejitvi čim večja.

Entropija drevesa, nastalega ob vejitvi na osnovi poljubnega pogoja bo nižja od entropije drevesa pred vejitvijo, razen če bo verjetnost, da je dodani pogoj izpolnjen, enaka nič in bo entropija po vejitvi enaka. Razliki med entropijo pred in po vejitvi na osnovi pogoja rečemo pribitek informacije (information gain).

Pri uporabi pribitka informacije za izbiro pogoja, po katerem naj se izvede vejitev, nateIMO na težavo. Pribitek informacije je namreč večji pri pogojih, kjer se izvede vejitev na čim večje število poddreves. Kot skrajni primer lahko vzamemo vejitev, ki drevo razcepi na toliko poddreves, kolikor je vzorcev v učni množici. Ker bo vsak vzorec v svojem poddrevesu sam, bo entropija vsakega poddrevesa enaka nič, prav toliko pa bo vsota entropij. Pribitek informacije bo torej kar enak začetni entropiji in bo torej maksimalen. Na srečo pri zveznih lastnostih kot pogoj običajno izberemo neko mejno vrednost, na osnovi katere vse vzorce uvrstimo v eno od dveh skupin. Tako vsak pogoj drevo razbije na natančno dve poddrevesi. Težave z razbijanjem na preveliko število poddreves se običajno pojavi takrat, ko so lastnosti vzorcev diskretne in neurejene, tako da takšne meje ne moremo postaviti. Ker so bile vse lastnosti, na osnovi katerih smo izvajali klasifikacijo posnetkov EMG maternice, zvezne, smo se težavam zaradi pretiranih vejitev izognili.

11.2.2 Obrezovanje dreves

Kot mnogi drugi klasifikatorji se lahko tudi odločitvena drevesa preveč prilagodijo učni množici vzorcev. Da bi se temu izognili, lahko drevo, ki smo ga ustvarili na osnovi učne množice, obrežemo. Obrezovanje izvajamo tako, da se več listov drevesa združi v enega, pri čemer se kot razred, v katerega novi list uvršča vzorce, uporabi večinski razred združevanih listov. Obrezana drevesa so manjša, obenem pa obrezovanje pogosto izboljša delovanje dreves na vzorcih, ki jih ni v učni množici.

Seveda se spet pojavi vprašanje, katere liste se izplača obrezati.

Prvo stopnjo obrezovanja oziroma omejevanja vejitev lahko opravimo že med samim učenjem. Tako lahko liste drevesa lahko prenehamo razcepljati ko:

- dosežemo določeno globino ali

- število vzorcev iz učne množice, ki spadajo v list, pade pod določeno število ali
- število vzorcev v novem listu pade pod določeno število ali
- število vzorcev v novoustvarjenih listih pade pod določeno število ali
- ko je odstotek vzorcev v listu, ki pripadajo enemu od razredov, dovolj visok.

Drugo stopnjo obrezovanja izvedemo potem, ko je drevo že zgrajeno. Ker naj bi obrezovanje izboljšalo pravilno določanje razreda vzorcev, ki jih ni v učni množici, bi za določanje listov, ki naj se obrežejo, morali učno množico razdeliti na dve podmnožici - pravo učno in obrezovalno. Zaradi majhnega števila učnih primerov je tak pristop nezaželen.

V primerih, ko je vzorcev v učni množici malo, lahko uporabimo obrezovanje z minimalno verjetnostjo napake (*minimal error probability*, MEP). Pri pristopu z minimalno napako drevo obrezujemo od listov proti korenju. Za vsako poddrevo T s korenom v in potomci T_1, T_2, \dots določimo statično napako $e(v)$ kot verjetnost, da vzorec, ki je pristal v poddrevesu T , ne pripada najbolj pogostemu razredu v tem poddrevesu. Na osnovi te napake se potem odločimo, ali bomo poddrevo obrezali. V primeru, da poddrevo T nadomestimo z listom, ki uvršča vzorce v večinski razred, za oceno njegove napake $E(T)$ uporabimo izraz $E(T) = e(v)$. V primeru, da poddrevesa T ne obrežemo, njegovo napako ocenimo kot $E(T) = p_1 E(T_1) + p_2 E(T_2) + \dots$. Za obrezovanje se odločimo, ko je statična napaka $e(v)$ manjša od napake $E(T) = p_1 E(T_1) + p_2 E(T_2) + \dots$

Težava, s katero se soočimo, je, da statična napaka $e(t)$ ni vnaprej znana in jo moramo oceniti na osnovi učne množice. Za to lahko uporabimo oceno s parametrom m . V tem primeru najprej določimo oceno verjetnosti p_C , da uvrščevani vzorec pripada večinskemu razredu. V oceni upoštevamo a priori verjetnost, da vzorec pripada večinskemu razredu p_{C_a} , število vzorcev v listu N , število vzorcev v listu, ki pripadajo večinskemu razredu n_C in parameter m .

$$p_C = \frac{p_{C_a} m + n_C}{N + m} . \quad (11.6)$$

Oceno napake potem določimo kot $e(v) = 1 - p_C$.

Parameter m določimo glede na pričakovano stopnjo šuma v učnih podatkih. Višji, ko je parameter m , bolj verjetno bo, da se poddrevo T obreže.

V raziskavi smo kot vrednost parametra m izbrali 5. Poleg tega smo globino drevesa omejili na 21, to je število parametrov. Na ta način smo se poizkusili izogniti temu, da bi se drevo preveč prilagodilo učni množici.

11.3 Analiza principalnih komponent

Vsak vzorec z Q zveznimi lastnostmi lahko smatramo za točko v Q -dimenzionalnem prostoru. Če uporabljamo Bayesov klasifikator, vnaprej privzamemo, da so lastnosti vzorca nekorelirane. Na žalost v resnici ta pogoj pogosto ni izpolnjen. Da bi prišli do novih lastnosti, ki bi bile nekorelirane, a še vedno osnovane izključno na originalnih lastnostih, lahko uporabimo analizo principalnih komponent (*principal component analysis*, PCA).

Nabor vzorcev G s Q lastnostmi lahko smatramo kot matriko Q -dimenzionalnih vektorjev. Iz te matrike s preprostim premikom dobimo matriko X , katere empirično povprečje je enako nič, tako, da od vsakega vzorca odštejemo povprečno vrednost celotnega nabora vzorcev. Nato za dobljeno matriko X poiščemo kovariančno matriko, $\Sigma = X^T X$. Lastni vektorji matrike C predstavljajo ortonormirano bazo novega prostora. Varianca vzorcev v novem prostoru, gledano pravokotno na lastne vektorje, narašča z lastnimi vrednostmi, pripadajočimi tem vektorjem. Tako je varianca največja v smeri, pravokotni na lastni vektor, ki pripada največji lastni vrednosti in najmanjša v smeri, pravokotni na vektor, ki pripada najmanjši lastni vrednosti. Lastni vektorji kovariančne matrike so drug na drugega pravokotni in enake velikosti, tako da tvorijo ortonormirano bazo novega prostora.

Vzorci v novem prostoru, pridobljenem s pomočjo analize principalnih komponent, niso korelirani. Pričakovali smo, da bo nekoreliranost predvsem izboljšala delovanje naivnega Bayesovega klasifikatorja. Kovariančno matriko smo vsakič naračunali na vseh vzorcih in jih preslikali v novi prostor, nato pa smo preverili delovanje klasifikatorjev na preslikanih vzorcih.

11.4 Ocena delovanja klasifikatorjev

V raziskavi smo se omejili na klasifikacijo posnetkov v enega od dveh razredov. V prvem primeru sta bila to razred posnetkov, kjer je prišlo do prezgodnjega poroda in razred posnetkov, kjer je bil porod ob roku, v drugem primeru pa sta bila to razred posnetkov, narejenih pred 26. tednom nosečnosti in razred posnetkov, narejenih v ali po 26. tednu nosečnosti.

11.4.1 Občutljivost in specifičnost

Pri klasifikaciji vzorcev v eno izmed dveh skupin sta najpogosteje uporabljeni meri zmogljenosti klasifikatorja občutljivost in specifičnost. Pri populaciji vzorcev velikosti N , sestavljeni

iz dveh med seboj tujih razredov C_A in C_B velikosti N_{C_A} in N_{C_B} ,

$$Se = \frac{TP}{TP + FN} , \quad (11.7)$$

$$Sp = \frac{TN}{TN + FP} . \quad (11.8)$$

Težava s občutljivostjo in specifičnostjo je, da v primerih, ko razredi, v katere spadajo vzorci, niso enako verjetni, dobimo zapeljivo dobre rezultate z brezupno slabimi klasifikatorji. Kot primer slabega klasifikatorja lahko uporabimo majoritetni klasifikator, ki vzorce, ne glede na njihove lastnosti, uvrsti v tisti razred, ki se v učni množici pojavlja najpogosteje. Tako bo na populaciji, v kateri 90% vzorcev pripada razredu A , 10% pa razredu B , občutljivost majoritetnega klasifikatorja za razred B enaka $0.9/(0.9 + 0) = 1.0$. Še bolj absurdna bo specifičnost za razred A , saj bo zaradi dejstva, da noben vzorec ne bo klasificiran negativno, neskončna.

11.4.2 Karakteristika delovanja sprejemnika

V klasičnem smislu krivulja karakteristike delovanja sprejemnika (receiver operating characteristic, ROC) grafično prikazuje občutljivost $TP/(TP + FN)$ v odvisnosti od vrednosti $FP/(TN + FP)$ [52]. Vrednost $FP/(TN + FP)$ je ravno enaka $1 - Sp$. V primeru, ko jo uporabljam na klasifikatorjih, ki pri vsakem vzorcu vsakemu razredu dodelijo verjetnost, da vzorec pripada danemu razredu in ko sta razreda samo dva, lahko kot parameter, ki ga spremojamo, uporabimo mejo, ki jo izberemo, da vzorec dodelimo prvemu oziroma drugemu razredu. Na osnovi tako dobljene krivulje lahko izberemo najboljšo mejo pri določanju razreda. Dobljena krivulja je zvezna in povezuje spodnje levo ogljišče, kjer klasifikator vse primere uvrsti v drugi razred (in je torej občutljivost 0) ter zgornje desno ogljišče, kjer klasifikator vse primere uvrsti v prvi razred in je občutljivost enaka 1. Vmes se krivulja dobrega klasifikatorja čim bolj približa zgornjemu levemu kotu - boljši, ko je klasifikator, bolj se krivulja približa temu kotu. To tudi pomeni, da bo tudi površina pod krivuljo ROC tem večja, čim boljši je klasifikator.

ROC krivulja klasifikatorja, ki klasificira naključno, ne glede na lastnosti vzorca, poteka po diagonali od levega spodnjega do desnega zgornjega kota - kot parameter, ki določa, kje na diagonali bo točka, ki jo predstavljajo odločitve klasifikatorja, služi razmerje med rezultati klasifikacije. Tako bo klasifikator, ki enako pogosto uvršča vzorce v prvi ali drugi razred, na grafu ROC predstavljen kot točka $(0.5, 0.5)$, medtem ko bo tisti, ki 90% vzorcev uvrsti v prvi razred, predstavljen kot točka $(0.9, 0.9)$.

Karakteristike klasifikatorjev, ki so boljši od naključnega ugibanja, se morajo torej na grafu nahajati zgoraj levo od diagonale. Krivulja ROC ima to lepo lastnost, da se ne spreminja bistveno v odvisnosti od razmerja razredov v populaciji, zato je primerna za ocenjevanje delovanja klasifikatorjev, kadar je število primerov, ki spadajo v enega od razredov, majhno, ali pa v primerih, ko se razmerje v številih razredov lahko med uporabo klasifikatorja bistveno spremeni - na primer pri klasifikaciji pacientov med okužene in zdrave, ko pride do epidemije in se razmerje pozitivnih ter negativnih primerov bistveno spremeni v primerjavi z razmerjem, ki je veljalo, ko so bili izbrani kriteriji za klasifikacijo. Težava se pojavi pri klasifikatorjih, ki namesto verjetnosti, da nek vzorec pripada nekemu razredu, vrnejo samo razred. Med takšne klasifikatorje spadajo tudi odločitvena drevesa. Namesto krivulje pri takšnih klasifikatorjih na grafu ROC dobimo le točko.

11.4.3 Ocena delovanja na učni množici

Da bi na hitro ocenili, ali lahko pričakujemo, da bo klasifikator uspešno uvrščal neznane primere v njihove razrede, lahko preverimo, ali klasifikator v prave razrede razvrsti primere, na katerih smo ga učili. Običajno je delovanje klasifikatorjev na učni množici boljše kot na neznanih primerih. Uspešnost klasifikatorja na učni množici torej lahko smatramo za nekakšno zgornjo mejo uspešnosti, ki jo lahko pričakujemo na še neznanih primerih.

11.4.4 Ocena delovanja z navzkrižno validacijo

Pri preizkusu z navzkrižno validacijo smo znane primere naključno razdelili na deset podmnožic, pri čemer smo pazili, da je bilo razmerje razredov v podmnožicah približno enako, kot v množici vseh znanih primerov. Klasifikator smo nato naučili na devetih od desetih podmnožic, preizkusili pa na preostali. Ta postopek smo ponovili za vseh deset podmnožic. Na ta način smo dobili oceno delovanja klasifikatorja, ki je manj optimistična od testiranja na učni množici.

11.4.5 Ocena delovanja po principu „izpusti enega“

Običajno naj bi delovanje klasifikatorjev testirali tako, da znane primere razdelimo na učno in testno množico. Na žalost v primerih, ko je število dostopnih primerov majhno, takšen pristop ni mogoč. V takšnem primeru lahko za oceno delovanja klasifikatorja uporabimo pristop „izpusti enega“. Pri tem pristopu za vsak primer u v množici A klasifikator naučimo na množici $A \setminus u$, nakar primer u klasificiramo s pomočjo naučenega klasifikatorja. Tako je

za učenje vsakokrat na voljo dovolj vzorcev, obenem pa delovanje klasifikatorja preverimo na vseh dostopnih primerih. Hkrati se izognemo nevarnosti, ki obstaja ob uporabi metode bootstrap, to je, da se klasifikator nauči vse primere v učni množici in nato seveda pravilno klasificira tudi vse podmnožice učne množice.

11.5 Rezultati klasifikacije

Predhodno ročno pregledovanje grafov vrednosti cenilk v odvisnosti od trajanja nosečnosti ali v odvisnosti od tedna, v katerem je bil posnetek zajet, ni dalo posebno dobrih rezultatov. Med skupinami namreč nismo opazili nobenih dovolj značilnih razlik, da bi lahko poljubne neznane posnetke uvrstili v katero od skupin. Vseeno smo upali, da bo strojna klasifikacija dala vsaj kakšen vzpodbuden rezultat.

Klasifikacijo smo izvajali na petih množicah, na vsega skupaj šest načinov. Najprej smo vsak posnetek poizkusili uvrstiti med prezgodne ali terminske, glede na to, ali je bil porod prezgoden ali ob roku. Nato smo vsak posnetek poizkusili uvrstiti med zgodne ali pozne - torej glede na to, ali je bil posnetek zajet pred 26. tednom nosečnosti ali kasneje.

Nato smo klasifikacijo izvedli samo nad posnetki, zajetimi zgodaj v nosečnosti, pri čemer smo jih uvrščali med prezgodne ali terminske. Enako smo storili še za posnetke, zajete med ali po 26. tednu nosečnosti.

Posnetke, kjer je bil porod prezgoden, smo poizkusili uvrstiti med tiste, ki so bili zajeti zgodaj v nosečnosti ali tiste, ki so bili zajeti pozno v nosečnosti. Enako smo storili za posnetke, kjer je bil porod ob roku.

Klasifikatorje smo testirali na skupini posnetkov, kjer je bil izbran natanko en posnetek na nosečnost, torej na istih posnetkih, na katerih smo izvajali statistično analizo cenilk in za katere smo naračunali verjetnosti $p_1 \dots p_6$. Kot mero zmogljivosti klasifikatorja smo uporabili vsoto občutljivosti in specifičnosti.

11.5.1 Lastnosti posnetkov, izbrane za klasifikacijo

Pri klasifikaciji smo kot lastnosti posnetkov upoštevali naslednje cenilke:

- koren srednje vrednosti kvadratov,
- vrh močnostnega spektra signala,
- mediano frekvenco močnostnega spektra,

- prvi prehod preko ničle koeficientov avtokorelacijske,
- maksimalni eksponent Ljapunova,
- korelacijsko dimenzijo,
- vzorčno entropijo pri $m = 3$, $r = 0.15$.

Vsako cenilko smo uporabili po trikrat, po enkrat za vsakega od kanalov. Pri učenju klasifikatorjev in klasifikaciji posnetkov smo torej uporabili skupaj $7 \cdot 3 = 21$ lastnosti.

11.5.2 Klasifikacija z majoritetnim klasifikatorjem

Tabela 11.1: Rezultati klasifikacije posnetkov z majoritetnim klasifikatorjem na različnih skupinah z različnimi razredi

Nabor podatkov	Razred	Se	Sp	TP	FP	FN	TN
Vsi posnetki	Prezgodnji	0%	100%	0	0	43	339
Posneti pred 26. tednom	Prezgodnji	0%	100%	0	0	19	163
Postneti v 26. tednu ali kasneje	Prezgodnji	0%	100%	0	0	24	176
Vsi posnetki	Posneti pred 26. tednom	0%	100%	0	0	182	200
Prezgodnji	Posneti pred 26. tednom	0%	100%	0	0	19	24
Ob roku	Posneti pred 26. tednom	0%	100%	0	0	163	176

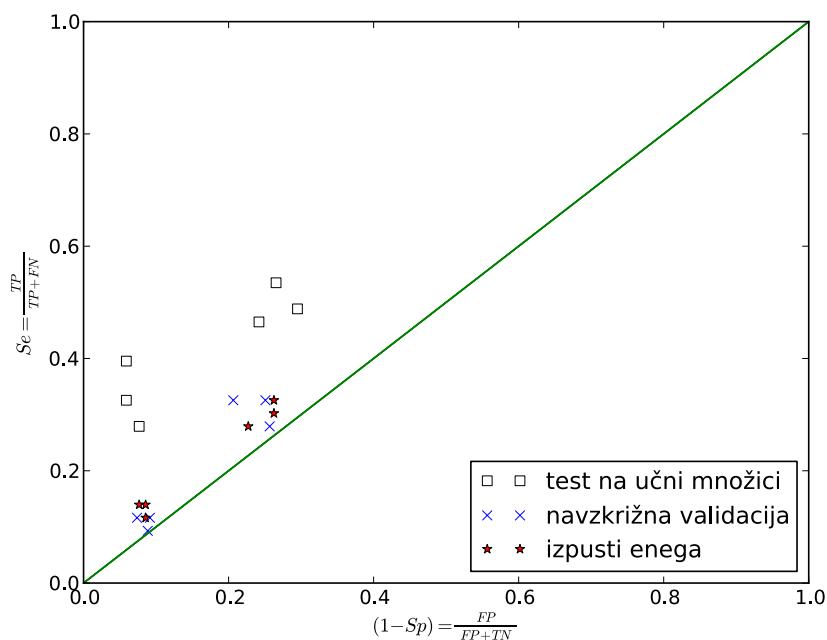
Za primerjavo z ostalimi smo posnetke najprej klasificirali z majoritetnim klasifikatorjem. Le-ta vse vzorce uvršča v večinski razred, ne glede na njihove lastnosti. To pomeni, da bi moral biti vsak klasifikator, ki uspešno uvršča vzorce v razrede glede na njihove lastnosti, boljši od majoritetnega klasifikatorja. Rezultati klasifikacije z majoritetnim klasifikatorjem torej lahko služijo kot spodnja meja, s katero potem primerjamo ostale klasifikatorje. Rezultati so predstavljeni v tabeli 11.1.

11.5.3 Klasifikacija z naivnim Bayesovim klasifikatorjem

Klasifikacija posnetkov, kjer je bil porod prezgodaj, proti tistim, kjer je bil porod ob roku

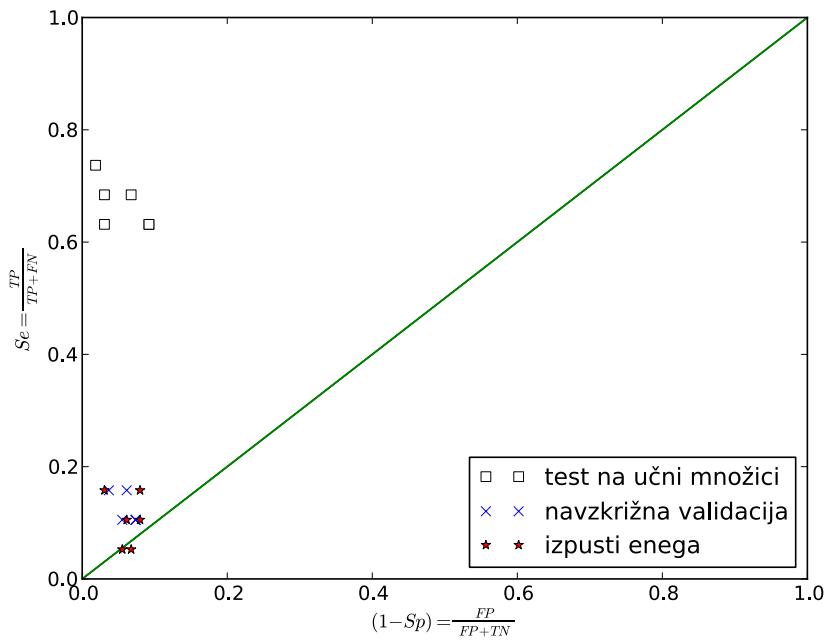
Rezultati poizkusa klasifikacije posnetkov, kjer je prišlo do prezgodnjih porodov, z uporabo naivnega Bayesovega klasifikatorja so predstavljeni na sliki 11.1 in v tabeli C.2. Gre za

klasifikacijo v skupini, za kateri smo v poglavju 10 verjetnost p_6 . Najboljši rezultat pri testiranju na učni množici smo dobili ob uporabi filtra od 0.08 do 4 Hz, ko je bila občutljivost 40% in specifičnost 94%. Pri uporabi istega filtra je bila pri testiranju z navzkrižno validacijo in po principu izpusti enega občutljivost le 12% in specifičnost 91%. Klasifikator je največ resnično prezgodnjih porodov napovedal pri uporabi filtra od 0.3 Hz do 2.5 Hz. Pri testiranju na učni množici so bili rezultati opazno boljši kot pri testiranju z navzkrižno validacijo ali po principu izpusti enega. Predvsem je bila pri testiranju na učni množici boljša občutljivost. Specifičnost je bila v vseh primerih nad 70%. Na žalost je bila občutljivost v vseh primerih nizka. Občutljivost je bila ob testiranju na učni množici največ 53%, sicer pa največ 33%. Najboljšo občutljivost smo dosegli pri uporabi filtrov od 0.3 do 3 Hz ter od 0.3 do 4 Hz.



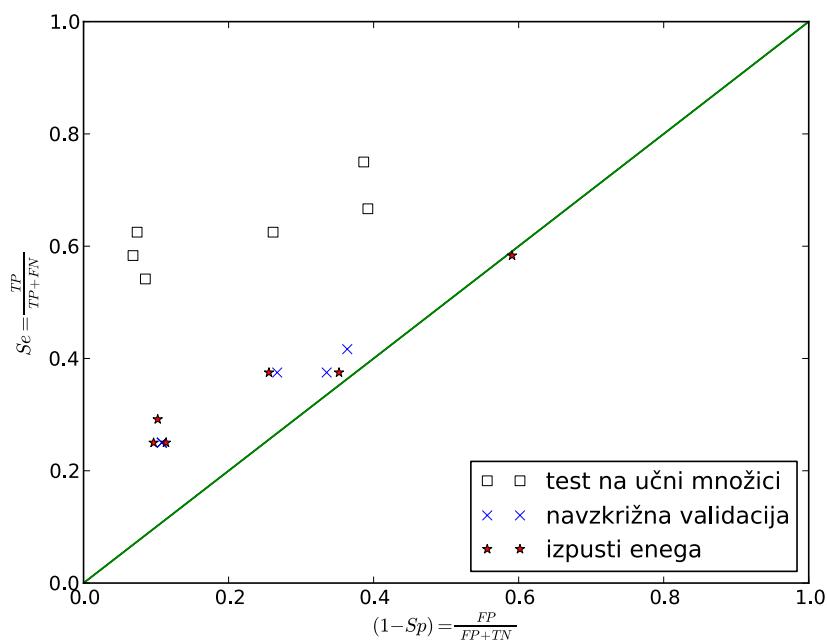
Slika 11.1: Karakteristike klasifikatorjev za Bayesov naivni klasifikator pri klasifikaciji posnetkov, kjer je bil porod prezgoden med vsemi posnetki (v smislu p_6 iz poglavja 10).

Ker bi radi nosečnosti, kjer je tveganje za prezgodnji porod večje, identificirali karseda zgodaj, smo preverili delovanje naivnega Bayesovega klasifikatorja na posnetkih, zajetih pred 26. tednom nosečnosti, torej v smislu verjetnosti p_1 iz poglavja 10. Tokrat se je klasifikator na učni množici izkazal precej bolje, kot pri testiranju z navzkrižno validacijo ali po principu izpusti enega. Ko smo klasifikator testirali na učni množici, so bili rezultati dobri, z občutljivostjo med 63% in 74% ter s specifičnostjo med 91% in 98%. Najboljši rezultat pri testiranju na učni množici smo dobili ob uporabi filtra od 0.08 do 4 Hz, ko je bila občutljivost 74% in specifičnost 98%. Pri testiranju z navzkrižno validacijo in po pristopu izpusti enega je specifičnost ostala visoka, vendar je občutljivost v vseh primerih padla na 16% ali manj, v najslabšem primeru, ob uporabi filtra od 0.3 Hz do 2.5 Hz celo na 5%. Pri uporabi filtra od 0.08 Hz do 4 Hz je bila pri testiranju z navzkrižno validacijo občutljivost 16% in specifičnost 96%, medtem ko je bila pri testiranju po principu izpusti enega specifičnost 97%. Rezultati poizkusa klasifikacije prezgodnjih porodov z uporabo naivnega Bayesovega klasifikatorja so predstavljeni na sliki 11.2 in v tabeli C.3.



Slika 11.2: Karakteristike klasifikatorjev za Bayesov naivni klasifikator pri klasifikaciji posnetkov, kjer je bil porod prezgoden med posnetki, zajetimi pred 26. tednom nosečnosti (v smislu p_1 iz poglavja 10).

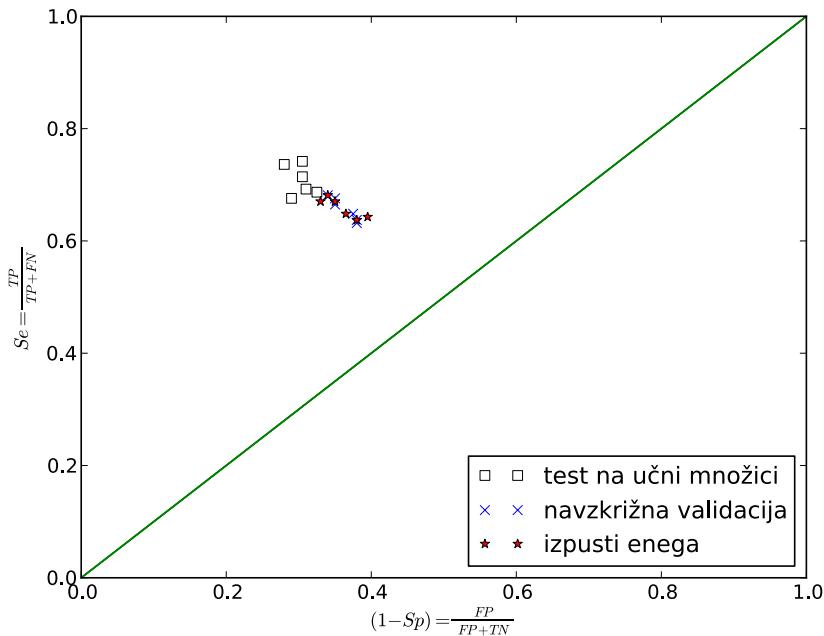
Pozneje v nosečnosti, v smislu verjetnosti p_2 iz poglavja 10, se je naivni Bayesov klasifikator izkazal bolje. Najboljše rezultate pri testiranju na učni množici smo dobili ob uporabi filtra od 0.08 Hz do 2.5 Hz, ko je bila občutljivost 63% in specifičnost 93%. Vseeno je bila občutljivost pri testiranju z navzkrižno validacijo ali po principu izpusti enega še vedno nizka, 42% ali manj. Rezultati so bili slabši pri uporabi vseh treh filtrov s spodnjo mejo pri 0.08 Hz. Pri testiranju z navzkrižno validacijo ob uporabi filtra od 0.08 Hz do 2.5 Hz je bila občutljivost 25%, specifičnost pa 89%. Pri testiranju po principu izpusti enega ob uporabi filtra od 0.08 Hz do 2.5 Hz je bila občutljivost 29%, specifičnost pa 90%. Rezultati poizkusa klasifikacije posnetkov, zajetih v ali po 26. tednu nosečnosti, kjer je prišlo do prezgodnjih porodov, so predstavljeni na sliki 11.3 in v tabeli C.4.



Slika 11.3: Karakteristike klasifikatorjev za Bayesov naivni klasifikator pri klasifikaciji posnetkov, kjer je bil porod prezgoden med posnetki, zajetimi med ali po 26. tednu nosečnosti (v smislu p_2 iz poglavja 10).

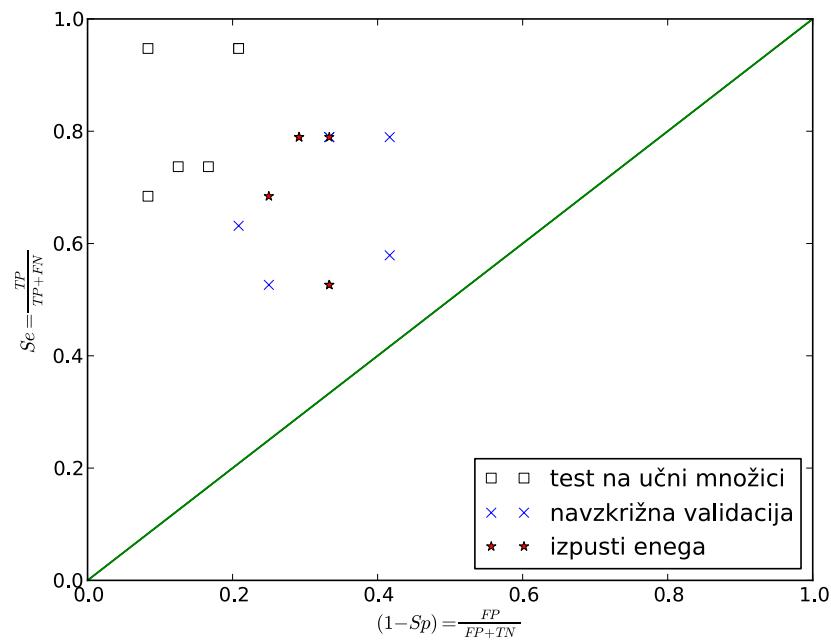
Klasifikacija posnetkov, zajetih zgodaj v nosečnosti, proti tistim, ki so bili zajeti kasneje

Pri klasifikaciji posnetkov, ki so bili zajeti pred 26. tednom nosečnosti, v smislu verjetnosti p_5 iz poglavja 10, se je naivni Bayesov klasifikator obnesel bolje. Izbira filtra na uspešnost klasifikacije ni bistveno vplivala. Tudi testiranje na učni množici ni dalo pretirano dobrih rezultatov, kar pomeni, da se klasifikator najverjetneje ni pretirano prilagodil učni množici. Najboljše rezultate pri testiranju na učni množici smo dobili ob uporabi filtra od 0.08 Hz do 4 Hz, ko je bila občutljivost 74% in specifičnost 72%. Pri testiranju z navzkrižno validacijo ob uporabi filtra od 0.08 Hz do 4 Hz je bila občutljivost 68%, specifičnost pa 65%. Pri testiranju po principu izpusti enega ob uporabi filtra od 0.08 Hz do 4 Hz je bila občutljivost 68%, specifičnost pa 66%. Rezultati klasifikacije posnetkov, ki so bili zajeti pred 26. tednom nosečnosti, so predstavljeni na sliki 11.4 in v tabeli C.1.



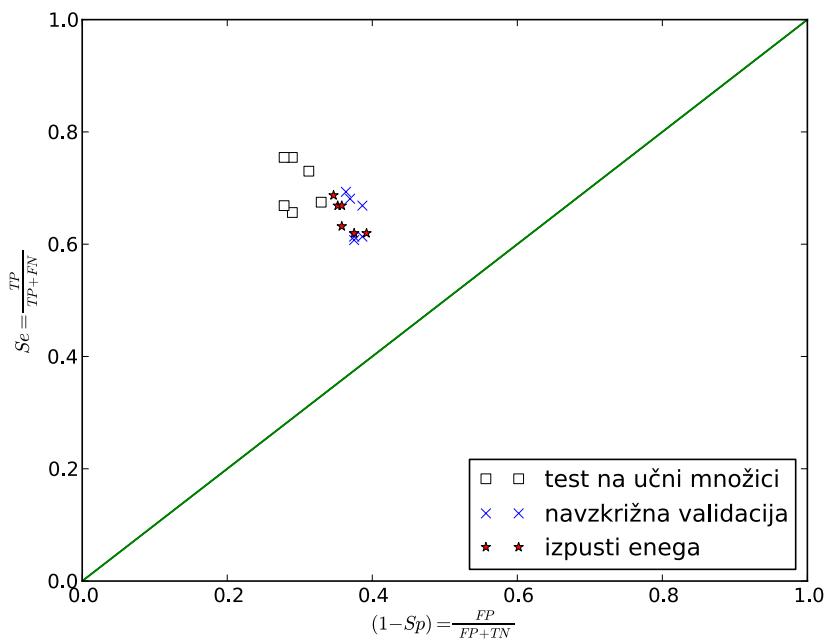
Slika 11.4: Karakteristike klasifikatorjev za Bayesov naivni klasifikator pri klasifikaciji posnetkov, zajetih pred 26. tednom nosečnosti, med vsemi posnetki (v smislu p_5 iz poglavja 10).

Množica posnetkov, kjer je bil porod prezgoden, je v primerjavi z ostalimi testnimi množicami, ki smo jih uporabili, majhna. Pri klasifikaciji posnetkov, ki so bili zajeti pred 26. tednom nosečnosti, torej v smislu verjetnosti p_3 iz poglavja 10, so bili rezultati pri testiranju na učni množici opazno boljši, kot pri testiranju z navzkrižno validacijo ali po principu izpusti enega. Najboljše rezultate smo dosegli z uporabo filtrov od 0.08 Hz do 2.5 Hz ter od 0.08 Hz do 3 Hz, ko je bila občutljivost 74% in specifičnost 72%. Pri testiranju z navzkrižno validacijo ob uporabi istih filtrov je bila občutljivost 79%, specifičnost pa 67%. Pri testiranju po principu izpusti enega ob uporabi istih filtrov je bila občutljivost 79%, specifičnost pa 71%. Rezultati poizkusa klasifikacije posnetkov, zajetih pred 26. tednom nosečnosti, med posnetki, kjer je bil porod prezgoden, so prikazani na sliki 11.5 in v tabeli C.5.



Slika 11.5: Karakteristike klasifikatorjev za Bayesov naivni klasifikator pri klasifikaciji posnetkov, zajetih pred 26. tednom nosečnosti, med posnetki, kjer je bil porod prezgoden (v smislu p_3 iz poglavja 10).

Pri klasifikaciji posnetkov, zajetih pred 26. tednom nosečnosti, med posnetki, kjer je bil porod ob roku, torej v smislu p_4 iz poglavja 10, so bili rezultati pri testiranju na učni množici bliže rezultatom pri testiranju z navzkrižno validacijo ali pri testiranju po principu izpusti enega. Na rezultate izbira filtra ni bistveno vplivala. Najboljše rezultate pri testiranju na učni množici smo dobili ob uporabi filtra od 0.08 Hz do 2.5 Hz, ko je bila občutljivost 75% in specifičnost 71%. Pri testiranju z navzkrižno validacijo ob uporabi filtra od 0.08 Hz do 2.5 Hz je bila občutljivost 68%, specifičnost pa 63%. Pri testiranju po principu izpusti enega ob uporabi filtra od 0.08 Hz do 2.5 Hz je bila občutljivost 67%, specifičnost pa 65%. Rezultati poizkusa klasifikacije posnetkov, zajetih pred 26. tednom nosečnosti, med posnetki, kjer je bil porod ob roku, so prikazani na sliki 11.6 in v tabeli C.6.

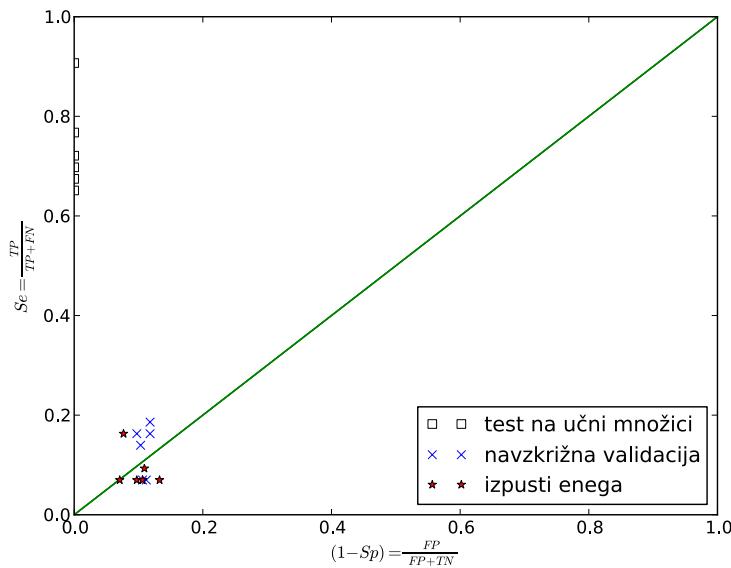


Slika 11.6: Karakteristike klasifikatorjev za Bayesov naivni klasifikator pri klasifikaciji posnetkov, zajetih pred 26. tednom nosečnosti, med posnetki, kjer je bil porod ob roku (v smislu p_4 iz poglavja 10).

11.5.4 Klasifikacija z odločitvenimi drevesi

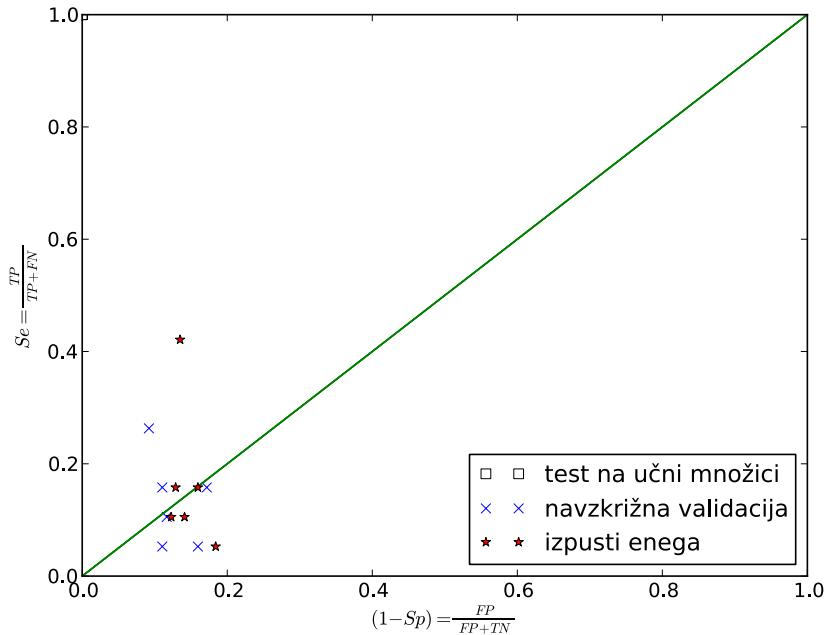
Klasifikacija posnetkov, kjer je bil porod prezgodaj, proti tistim, kjer je bil porod ob roku

V nasprotju s pričakovanji se odločitvena drevesa pri klasifikaciji posnetkov, kjer je bil porod prezgoden, med vsemi posnetki, torej v smislu verjetnosti p_6 iz poglavja 10, niso obnesla najbolje. Rezultati klasifikacije posnetkov, kjer je bil porod prezgoden, med vsemi posnetki, so prikazani na sliki 11.7 in v tabeli C.8. Iz slike je razvidno, da so rezultati testiranja klasifikatorja na učni množici zavajajoče dobri. Tako na primer pri testiranju na učni množici odločitvena drevesa niso določila niti enega neresnično pozitivnega vzorca. Najboljše rezultate pri testiranju na učni množici smo dobili ob uporabi filtra od 0.3 Hz do 3 Hz, ko je bila občutljivost 91% in specifičnost 100%. Pri testiranju z navzkrižno validacijo ob uporabi filtra od 0.3 Hz do 3 Hz je bila občutljivost 16%, specifičnost pa 90%. Pri testiranju po principu izpusti enega ob uporabi filtra od 0.3 Hz do 3 Hz je bila občutljivost 7%, specifičnost pa 89%. Občutljivost je bila ne glede na uporabo filtra relativno visoka - nad 65% v primerjavi z vrednostmi pod 19% za testiranje z navzkrižno validacijo ali po principu izpusti enega. Vse torej kaže, da so se odločitvena drevesa pretirano prilagodila učni množici.



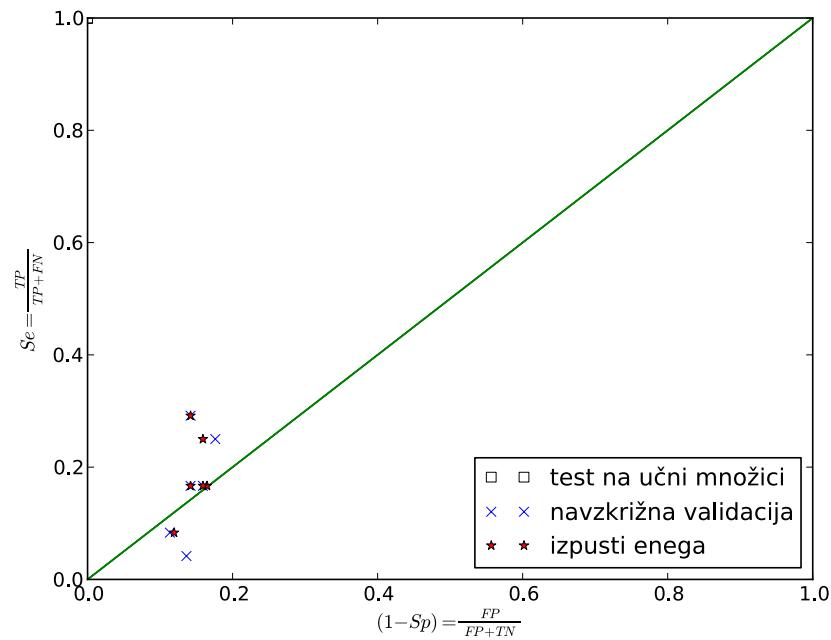
Slika 11.7: Karakteristike klasifikatorjev za odločitvena drevesa pri klasifikaciji posnetkov, kjer je bil porod prezgoden med vsemi posnetki (v smislu p_6 iz poglavja 10).

Na posnetkih, zajetih pred 26. tednom nosečnosti, torej v smislu verjetnosti p_1 iz poglavja 10, so se odločitvena drevesa učno množico naučila še bolje. Ne glede na uporabljeni filter so ob testiranju na učni množici vse posnetke klasificirala pravilno, torej sta bili občutljivost in specifičnost v vseh primerih 100%. Ob uporabi preverjanja z navzkrižno validacijo ali po principu izpusti enega so bili rezultati seveda slabši. Najboljše rezultate smo dobili ob uporabi filtra od 0.08 Hz do 4Hz, ko je bila občutljivost nad 25% in specifičnost nad 87%. V več primerih so se odločitvena drevesa izkazala za slabši klasifikator od naključnega ugibanja. Rezultati klasifikacije posnetkov, kjer je bil porod prezgoden, med posnetki, zajetimi pred 26. tednom nosečnosti, so prikazani na sliki 11.8 in v tabeli C.9.



Slika 11.8: Karakteristike klasifikatorjev za odločitvena drevesa pri klasifikaciji posnetkov, kjer je bil porod prezgoden med posnetki, zajetimi pred 26. tednom nosečnosti (v smislu p_1 iz poglavja 10).

Tudi na množici posnetkov, zajetih med ali po 26. tednu nosečnosti, torej v smislu verjetnosti p_2 iz poglavja 10, so se odločitvena drevesa preveč prilagodila učni množici. Ne glede na uporabljeni filter je klasifikator pravilno uvrstil vse posnetke. Pri testiranju z navzkrižno validacijo ali s pristopom izpusti enega so se odločitvena drevesa spet pogosto izkazala za slabši klasifikator od naključnega ugibanja. Občutljivost je bila med 4% pri uporabi filtra od 0.08 Hz do 4 Hz in 29% pri uporabi filtra od 0.3 Hz do 3 Hz. Specifičnost je bila v vseh primerih 82% ali višja. Rezultati klasifikacije posnetkov, kjer je bil porod prezgoden, med posnetki, zajetimi med ali po 26. tednu nosečnosti, so prikazani na sliki 11.7 in v tabeli C.8.

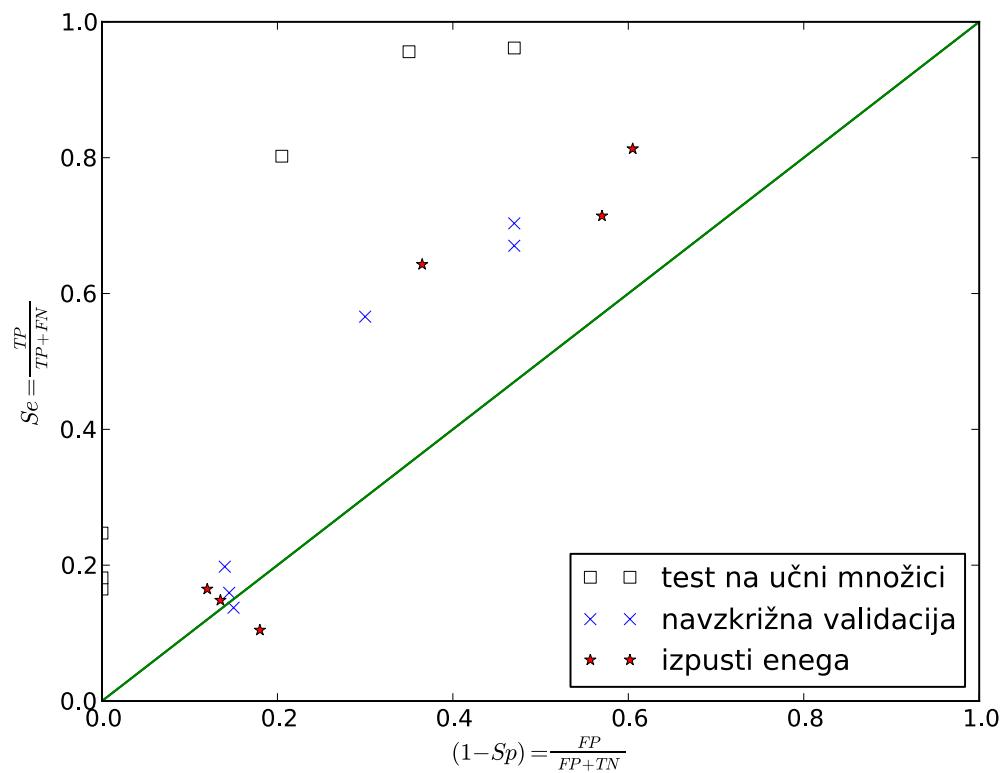


Slika 11.9: Karakteristike klasifikatorjev za odločitvena drevesa pri klasifikaciji posnetkov, kjer je bil porod prezgoden, med posnetki, zajetimi med ali po 26. tednu nosečnosti (v smislu p_2 iz poglavja 10).

Klasifikacija posnetkov, zajetih zgodaj v nosečnosti, proti tistim, ki so bili zajeti kasneje

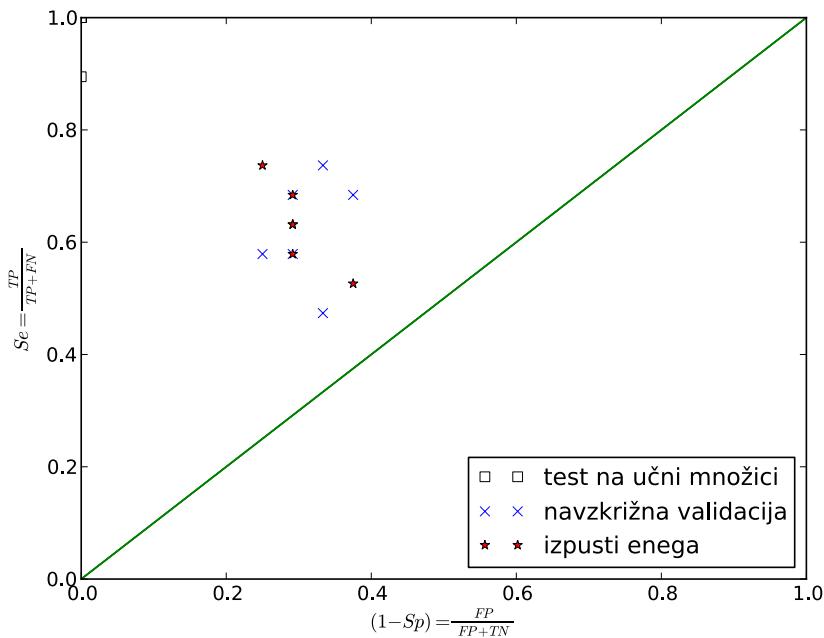
Statistična analiza cenilk je pokazala, da se povprečne vrednosti večine cenilk, izračunanih za posnetke, zajete pred 26. tednom nosečnosti, razlikujejo od povprečnih vrednosti teh cenilk, izračunanih za posnetke, zajete med ali po 26. tednu nosečnosti. Zaradi boljših rezultatov pri statistični analizi cenilk smo zato pričakovali, da bodo tudi rezultati klasifikacije posnetkov, zajetih zgodaj v nosečnosti, boljši kot so bili rezultati klasifikacije posnetkov, kjer je prišlo do prezgodnjega poroda, ne glede na uporabljeni klasifikator. Čeprav so bili rezultati boljši, se tudi pri klasifikaciji posnetkov, zajetih pred 26. tednom nosečnosti, odločitvena drevesa niso izkazala za najboljša.

Odločitvena drevesa so se pri klasifikaciji posnetkov glede na čas zajema posnetka, torej v smislu verjetnosti p_5 iz poglavja 10, najbolje obnesla ob uporabi filtrov, kjer je bila spodnja mejna frekvanca enaka 0.08 Hz. Rezultati so se močno razlikovali glede na izbrano metodo testiranja. Testiranje na učni množici je spet dalo pretirano dobre rezultate. Tako je bila najvišja občutljivost 96% ob specifičnosti 65%, najvišja specifičnost pa 100% ob občutljivosti 25%. Najboljše rezultate pri testiranju na učni množici smo dobili ob uporabi filtra od 0.08 Hz do 4 Hz, ko je bila občutljivost 96% in specifičnost 65%. Pri testiranju z navzkrižno validacijo ali s pristopom izpusti enega sta bili občutljivost in specifičnost pri uporabi filtrov s spodnjo mejo 0.08 Hz med 43% in 81%. Pri uporabi filtrov s spodnjo mejo pri 0.3 Hz je bila klasifikacija manj zanesljiva, saj je bila občutljivost vedno 20% ali manj, vendar se je povečala specifičnost, ki je bila v vseh primerih 82%. Pri testiranju z navzkrižno validacijo ob uporabi filtra od 0.08 Hz do 4 Hz je bila občutljivost 67%, specifičnost pa 53%. Pri testiranju po principu izpusti enega ob uporabi filtra od 0.08 Hz do 4 Hz je bila občutljivost 71%, specifičnost pa 43%. Rezultati klasifikacije posnetkov, zajetih pred 26. tednom nosečnosti, med vsemi posnetki, so prikazani na sliki 11.10 in v tabeli C.7.



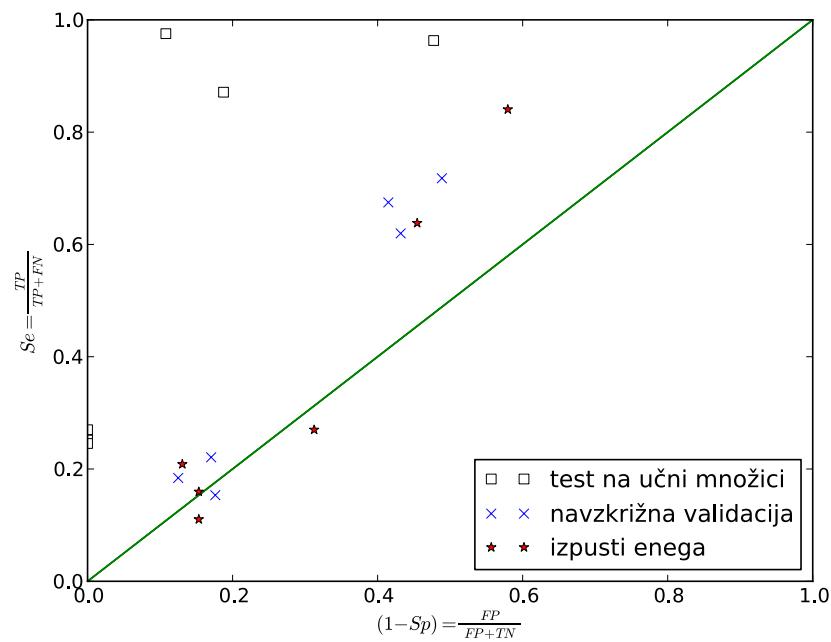
Slika 11.10: Karakteristike klasifikatorjev za odločitvena drevesa pri klasifikaciji posnetkov, zajetih pred 26. tednom nosečnosti, med vsemi posnetki (v smislu p_5 iz poglavja 10).

Tudi pri klasifikaciji posnetkov, zajetih pred 26. tednom nosečnosti, med posnetki, kjer je bil porod prezgoden, torej v smislu verjetnosti p_3 iz poglavja 10, so se odločitvena drevesa naučila celotno učno množico. Pri testiranju na učni množici so drevesa narobe klasificirala največ dva posnetka, pri uporabi filtra od 0.3 Hz do 2.5 Hz. Pri testiranju z navzkrižno validacijo in s pristopom izpusti enega so bili rezultati bolj razpršeni, ampak vedno opazno boljši od naključnega žrebanja. Pri testiranju z navzkrižno validacijo ob uporabi filtra od 0.3 Hz do 4 Hz je bila občutljivost 74%, specifičnost pa 67%. Pri testiranju po principu izpusti enega ob uporabi filtra od 0.3 Hz do 4 Hz je bila občutljivost 74%, specifičnost pa 75%. Rezultati klasifikacije posnetkov, zajetih pred 26. tednom nosečnosti, med posnetki, kjer je bil porod prezgoden, so prikazani na sliki 11.11 in v tabeli C.11.



Slika 11.11: Karakteristike klasifikatorjev za odločitvena drevesa pri klasifikaciji posnetkov, zajetih pred 26. tednom nosečnosti, med posnetki, kjer je bil porod prezgoden (v smislu p_3 iz poglavja 10).

Tudi na skupini posnetkov, kjer je bil porod ob roku, torej v smislu verjetnosti p_4 iz poglavja 10, so se odločitvena drevesa ob klasifikaciji posnetkov, zajetih pred 26. tednom nosečnosti, pretirano prilagodila učni množici. Najboljše rezultate pri testiranju na učni množici smo dobili ob uporabi filtra od 0.08 Hz do 2.5 Hz, ko je bila občutljivost 87% in specifičnost 81%. Pri testiranju z navzkrižno validacijo so bila odločitvena drevesa slabša od naključnega ugibanja pri uporabi filtra od 0.3 Hz do 4 Hz ter ob uporabi filtra od 0.08 Hz do 2.5 Hz pri testiranju po principu izpusti enega. Pri testiranju z navzkrižno validacijo ob uporabi filtra od 0.08 Hz do 2.5 Hz je bila občutljivost 67%, specifičnost pa 59%. Pri testiranju po principu izpusti enega ob uporabi filtra od 0.08 Hz do 2.5 Hz je bila občutljivost 27%, specifičnost pa 69%. Nasprotno so se odločitvena drevesa obnesla najbolje pri uporabi filtra od 0.08 Hz do 3 Hz, ko je bila občutljivost 72% ali več, specifičnost pa 42% ali več, ne glede na način testiranja. Rezultati klasifikacije posnetkov, zajetih pred 26. tednom nosečnosti, med posnetki, kjer je bil porod ob roku, so prikazani na sliki 11.12 in v tabeli C.12.



Slika 11.12: Karakteristike klasifikatorjev za odločitvena drevesa pri klasifikaciji posnetkov, zajetih pred 26. tednom nosečnosti, med posnetki, kjer je bil porod ob roku (v smislu p_4 iz poglavja 10).

11.5.5 Klasifikacija z uporabo analize principalnih komponent

Za klasifikacijo z uporabo analize principalnih komponent smo pri testiranju klasifikatorjev novi prostor vsakič določili na osnovi vseh posnetkov v skupini, na kateri smo testirali klasifikator. Posnetke smo preslikali v novi prostor in na posnetkih, preslikanih v novi prostor klasifikator testirali. Pri preslikavi v prostor, dobljen z uporabo analize principalnih komponent torej podatkov nismo delili na učno in testno množico že pred učenjem in testiranjem klasifikatorja. Novi prostor smo tako določili petkrat:

- za vse posnetke,
- za posnetke, kjer je bil porod prezgoden,
- za posnetke, kjer je bil porod ob roku,
- za posnetke, zajete pred 26. tednom nosečnosti in
- za posnetke, zajete med ali po 26. tednu nosečnosti.

V vseh primerih smo klasifikator učili na vseh dobljenih lastnostih.

Klasifikacija z naivnim Bayesovim klasifikatorjem po uporabi analize principalnih komponent

V nasprotju s pričakovanji se je Bayesov naivni klasifikator na preslikanih posnetkih obnesel slabše kot na originalnih. Možno je, da je do tega prišlo zato, ker je bila večina informacij o tem, kateremu razredu pripada dani posnetek, zajeta v prvih nekaj dimenzijah v novem prostoru. Lastnosti, ki so pojasnile manjši del variance, so nato poskrbele, da se je klasifikator učil slabše, kot v primeru, ko analize principalnih komponent nismo uporabili. Opazili smo, da se je v večini primerov specifičnost klasifikatorja pri testiranju na učni množici povečala, medtem ko sta se tako občutljivost kot specifičnost pri testiranju z navzkrižno validacijo in po principu izpusti enega zmanjšali.

Rezultati klasifikacije z naivnim Bayesovim klasifikatorjem ob uporabi analize principalnih komponent so predstavljeni v prilogi B na slikah B.1, B.2, B.3, B.4, B.5 in B.6 ter v prilogi C v tabelah C.14, C.13, C.15, C.16, C.17 in C.18.

Klasifikacija z odločitvenimi drevesi po uporabi analize principalnih komponent

Tudi odločitvena drevesa so se na preslikanih posnetkih obnesla slabše kot na originalnih. Poslabšanje je bilo celo še bolj opazno kot pri uporabi naivnega Bayesovega klasifikatorja.

Rezultati klasifikacije z odločitvenimi drevesi ob uporabi analize principalnih komponent so predstavljeni v prilogi B na slikah B.7, B.8,B.9,B.10, B.11, B.12 ter v prilogi C v tabelah C.20, C.19, C.21, C.22, C.23 in C.24.

POGLAVJE 12

Razprava

12.1 Izbira filtrov za predobdelavo ter kanalov za zajem posnetkov elektromiograma maternice

Izbira pravega filtra za predobdelavo signalov se je izkazala za zelo pomembno. Filtri z nekončnim odzivom na enotin impulz z dvosmerno shemo filtriranja so se izkazali kot primerni za predobdelavo signalov električne aktivnosti maternice. Butterworthovi filtri z dvosmerno shemo filtriranja so iz signala učinkovito odstranili šum pri nizkih in visokih frekvencah, ob minimalnih zahtevah po hitrosti delovanja strojne opreme. Rezultati statistične analize so se, predvsem pri uporabi linearnih tehnik obdelave signalov, močno spremenili, ko smo za predobdelavo uporabili filtre z različnimi mejnimi frekvencami. Za linearne tehnike obdelave signalov so se kot boljši izkazali filtri s spodnjo mejno frekvenco pri 0.3 Hz. Rezultati uporabe nelinearnih tehnik obdelave signalov niso bili tako močno odvisni od izbrane spodnje mejne frekvence filtra.

Tako linearne kot tudi nelinearne tehnike obdelave signalov so dale slabše rezultate ob uporabi filtrov z zgornjo mejo pri 2.5 Hz. Pretirano ožanje opazovanega frekvenčnega območja torej lahko slabo vpliva tako na linearne, kot tudi na nelinearne tehnike. Vseeno je močno filtriranje nujno, saj je predvsem zgodaj v nosečnosti, okrog 22. tedna, v signalih prisotno mnogo motenj, medtem ko so salve električne aktivnosti v tem obdobju redkejše.

Na rezultate je močno vplivala tudi izbira položaja elektrod. Najboljše rezultate v smislu ločevanja posnetkov glede na trajanje nosečnosti pri statistični analizi cenilk smo dobili ob opazovanju tretjega kanala - torej kanala, zajetega nižje na trebuhi, bližje materničnega vrata. Enako je veljalo za večino cenilk, ko je bila vrednost p_6 nizka. To nas je napeljalo na misel, da je bila električna aktivnost spodnjega dela maternice v primerih, ko je prišlo

do prezgodnjega poroda, verjetno drugačna kot v primerih, ko je prišlo do poroda ob roku. Pozno v nosečnosti so bile razlike v vzorčni entropiji med skupinami pogosteje statistično pomembne ob opazovanju 2. kanala, torej ob meritvi napetosti v vzdolžni smeri maternice. Mogoče je torej, da je najboljši položaj elektrod za merjenje električne aktivnosti odvisen tudi od časa, v katerem se izvaja njeno merjenje. Ker se prostornina maternice med nosečnostjo poveča, elektrode pa smo namestili glede na položaj popka, je mogoče, da so bile razlike v vrednostih izmerjenih cenilk zgodaj in pozno v nosečnosti delno tudi posledica premika elektrod. Zgodaj v nosečnosti so bile razlike med skupinami glede na to, ali je bil porod prezgoden, pogosteje statistično pomembno različne, ko smo opazovali 3. kanal. Takrat sta bili elektrodi E3 in E4 bliže materničnemu vratu. Pri kasnejših meritvah sta bili ti dve elektrodi bliže telesu maternice. Rezultati ob uporabi mediane frekvence so bili praviloma najboljši ob opazovanju prvega kanala. Verjetno je torej optimalni položaj elektrod tudi od uporabljene tehnike obdelave signalov. Položaj elektrod ni bistveno vplival na vrednost p_5 , kar pomeni, da položaj elektrod za spremeljanje sprememb električne aktivnosti med nosečnostjo verjetno ni tako pomemben.

Na žalost je bil položaj elektrod določen glede na položaj popka, kar pomeni, da so se zaradi raztezanja maternice med meritvami elektrode glede na maternico premaknile in zato ni nujno, da so se elektrode zgodaj v nosečnosti nahajale nad istimi predeli maternice, kot pozno v nosečnosti. Točen vpliv položaja elektrod na napovedno vrednost elektromiograma maternice bomo zato morali preveriti v eni od prihodnjih raziskav.

12.2 Tehnike vizualizacije

Pri ocenjevanju nekaterih fizioloških signalov, kot so elektrokardiogrami, se je grafični prikaz signala izkazal za nadvse koristnega. Človeški eksperti - kardiologi - znajo na osnovi prikaza signalov elektrokardiograma kot časovnih vrst dokaj uspešno prepoznati nekatera bolezenska stanja. Fiziološko ozadje signalov je v primeru elektrokardiograma dokaj dobro raziskano.

Pri analizi grafičnih prikazov EMG maternice smo se soočili z nekaj težavami. Zaradi pomanjkljivega poznavanja delovanja same maternice ne moremo vnaprej vedeti, kako naj bi izgledali signali električne aktivnosti maternice, kadar grozi prezgodnji porod oziroma takrat, kadar prezgodnji porod ne grozi.

Ne glede na težavnost prepoznavanja vzorcev v posnetkih električne aktivnosti maternice so nekatere raziskovalne ekipe objavile vzpodbudne rezultate [24], na osnovi katerih bi lahko pričakovali da bodo razlike med posnetki, ki pripadajo različnim skupinam, opazne v

časovno-frekvenčnih predstavivah teh posnetkov.

Ker je frekvenčni pas, kjer lahko opazujemo električno aktivnost maternice, dokaj ozek, smo predvidevali, da se bodo razlike bolje pokazale ob uporabi metod, kjer je ločljivost v frekvenčnem prostoru višja. V ta namen smo uporabili časovno-frekvenčno predstavitev Wignerja in Villeja.

Čeprav nismo opazili značilnih razlik med posnetki, ki pripadajo različnim skupinam, se je časovno-frekvenčna predstavitev Wignerja in Villeja izkazala za dobro pri opazovanju krčev maternice. Artefakti, ki bi jih sicer lahko smatrali kot slabost te časovno-frekvenčne predstaviteve, namreč pogosto sovpadajo s salvami električne aktivnosti maternice in tako poudarijo mesta, kjer pride do krčev.

12.3 Karakterizacija posnetkov elektromiograma maternice

V primerih, ko sta bila na voljo dva posnetka EMG maternice, zajeta v različnih obdobjih nosečnosti, smo opazovali lastnosti močnostnih spektrov signalov. Izkazalo se je, da se močnostni spektri pri posnetkih, zajetih zgodaj v nosečnosti, razlikujejo od močnostnih spektrov pri posnetkih, zajetih kasneje v nosečnosti. Takšen rezultat je bil pričakovani, saj se električna aktivnost maternice med nosečnostjo najverjetneje spreminja. Vrhovi, kakršne smo opazili sliki 6.15, so se običajno premaknili proti nižjim frekvencam, kot je to prikazano na sliki 6.17.

12.4 Delitev tehnik obdelave signalov na linearne in nelinearne

Po definiciji je linearna tista funkcija $f(x)$, za katero velja:

$$f(x + y) = f(x) + f(y) \quad (12.1)$$

in

$$f(a \cdot x) = a \cdot f(x) \quad . \quad (12.2)$$

Čeprav je Fourierjeva transformacija linearna, izračun močnostnega spektra P ni linearna tehnika.

$$P(x(t) + y(t)) \neq P(x(t)) + P(y(t)) \quad . \quad (12.3)$$

Kot dokaz lahko vzamemo primer, ko sta:

$$x(t) = -1, \quad y(t) = 1 \quad \Rightarrow \quad x(t) + y(t) = 0 \quad . \quad (12.4)$$

Očitno velja:

$$P(x(t)) = \left| \sum_{\omega=-\infty}^{\infty} -1e^{-j\omega n} \right|^2 = \left| -1 \sum_{\omega=-\infty}^{\infty} e^{-j\omega n} \right|^2 = P(y(t)) \neq 0 \quad . \quad (12.5)$$

in

$$P(x(t) + y(t)) = 0 \quad . \quad (12.6)$$

Koren srednje vrednosti kvadratov v splošnem ni linearna funkcija:

$$RMS(x(t) + y(t)) = \sqrt{\frac{1}{N} \left(\sum_{i=0}^{N-1} x(i)^2 + y(i)^2 + 2xy \right)} \quad , \quad (12.7)$$

$$RMS(x(t)) + RMS(y(t)) = \sqrt{\frac{1}{N} \sum_{i=0}^{N-1} x(i)^2} + \sqrt{\frac{1}{N} \sum_{i=0}^{N-1} y(i)^2} \neq 0 \quad , \quad (12.8)$$

$$RMS(x(t) + y(t)) \neq RMS(x(t)) + RMS(y(t)) \quad . \quad (12.9)$$

Vseeno velja:

$$RMS(k \cdot x(t)) = \sqrt{\frac{1}{N} \sum_{i=0}^{N-1} k^2 \cdot x(i)^2} = \sqrt{\frac{k^2}{N} \sum_{i=0}^{N-1} x(i)^2} = k \cdot RMS(x(t)) \quad . \quad (12.10)$$

Po Parsevalovi formuli lahko vrednost RMS izračunamo tudi iz moči signala, ki jo izračunamo na osnovi močnostnega spektra signala. Očitno je torej, da nobena uporabljeni tehnika ni bila linearna. Vseeno lahko uporabljeni tehnike v grobem razdelimo v dve skupini - tiste, ki so osnovane na močnostnem spektru signala in tiste, ki so osnovane na ocenjevanju kompleksnosti signalov.

Linearne tehnike smo torej poimenovali kot linearne zato, ker je Fourierjeva transformacija, na osnovi katere smo izračunali močnostni spekter, linearna.

12.5 Določanje parametrov pri nelinearnih tehnikah obdelave signalov

Pri uporabi nelinearnih metod obdelave signalov smo se soočili z nekaj težavami. Prva težava je ta, da je pri vsaki od teh metod potrebno določiti nekaj parametrov, pri čemer nam vrednosti teh parametrov niso bile vnaprej znane.

V primeru maksimalnega eksponenta Ljapunova in koreacijske dimenzijske je bila takšen parameter predvsem vložitvena dimenzija Q . Dokler ne vemo, koliko dejavnikov dejansko vpliva na električno aktivnost maternice, ne moremo določiti optimalne vložitvene dimenzijske.

Tudi pri določanju vložitvene zakasnitve, D_{smp} , smo se soočili s težavo - ali naj pri vsakem posnetku uporabimo zakasnitev, enako prvemu prehodu preko ničle koeficientov avtokorelacji ali kaki drugi lastnosti signala, ali naj za vse posnetke uporabimo enako, a dovolj veliko zakasnitev. Na osnovi literature [53] smo se odločili za zakasnitev, enako prvemu prehodu preko ničle koeficientov avtokorelacji. To seveda nikakor ne pomeni, da ne obstaja nobena zakasnitev, ki bi bila boljša.

Za izračun vzorčne entropije in večločljivostne vzorčne entropije smo morali določiti tri parametre: razmerje L , dolžino vzorcev, ki jih primerjamo m in dovoljeno razliko med vzorci r .

Pri prevelikih vrednostih m postane verjetnost, da v signalu ne bo nobenih ujemanj, visoka. Vzorčna entropija signala je v takšnih primerih odvisna le od njegove dolžine in zelo visoka. Po naših izkušnjah je primerna zgornja meja parametra m običajno nekje okrog 4 - 10 vzorcev. Če je m previsok in se vzorčna entropija za nekatere signale izračuna na osnovi dolžine signala, vzorčna entropija teh signalov izrazito odstopa od vzorčne entropije ostalih signalov. Pri statistični analizi lahko že nekaj takšnih signalov povzroči, da se povprečna vrednost vzorčne entropije ene skupine signalov bistveno razlikuje od vzorčne entropije druge skupine, kar pomeni, da pri uporabi Sturentovega t-testa dobimo nerealno nizko vrednost p .

Pri majhnih vrednostih r se prav tako poveča verjetnost, da v signalu ne bo nobenih ujemanj. Prav tako pri velikih r naraste verjetnost, da se bodo ujemali prav vsi vzorci, kar pomeni, da bo vzorčna entropija enaka 0.

Druga težava, s katero smo se soočili pri uporabi nelinearnih metod obdelave signalov, je njihova računska zahtevnost. Izračun koreacijske dimenzijske in maksimalnega eksponenta Ljapunova za signale, ki smo jih uporabili v raziskavi, je trajal več dni, pri čemer je bilo z računanjem ves čas zasedenih pet jeder na dveh računalnikih. Zaradi časovne potratnosti in zaradi dejstva, da fiziološke utemeljitve za izbor naborov parametrov Q in D_{smp} nismo imeli, smo se odločili, da preizkusimo le en nabor.

Zaradi manjše računske zahtevnosti smo pri večločljivostni vzorčni entropiji lahko preverili več različnih naborov vrednosti L , m in r .

12.6 Primernost tehnik za ločevanje skupin posnetkov

Pri ločevanju skupin posnetkov glede na čas poroda se je za najboljšo in tudi najbolj robustno izkazala vzorčna entropija. Pri vzorčni entropiji so bile vrednosti p_6 na tretjem kanalu nizke ne glede na uporabljeni pasovno-prepustni filter. Zgodaj v nosečnosti so se posnetki, kjer je bil porod prezgoden, razlikovali od posnetkov, kjer je bil porod ob roku, le ob uporabi filtrov s spodnjo mejo pri 0.08 Hz. Precej opaznejše so bile razlike v vzorčni entropiji med skupinami posnetkov glede na čas zajema posnetka. Nizke vrednosti p_4 in p_5 smo opazili ne glede na izbrani filter. Nizko vrednost p_2 smo opazili na kanalu 2, ne glede na izbrano spodnjo mejo izbranega filtra. Vzorčna entropija se je torej pri ločevanju skupin posnetkov glede na čas zajema posnetkov izkazala za robustno, nedovzetno za spremembe v spodnji meji filtra za predobdelavo signalov. Višjo (slabšo) vrednost p_2 smo opazili samo ob uporabi filtra od 0.08 Hz do 2.5 Hz. Maksimalni eksponent Ljapunova in Korelacijska dimenzija sta se izkazala kot manj primerni tehniki za ločevanje skupin posnetkov. Poleg tega sta ti dve tehniki računsko precej zahtevnejši od ostalih. Korelacijska dimenzija se je izkazala za boljšo v smislu ločevanja posnetkov glede na čas zajema (p_5).

Izmerjena povprečna vzorčna entropija pri posnetkih, kjer je bil porod ob roku, je bila višja kot povprečna vzorčna entropija pri posnetkih, kjer je bil porod prezgoden. Električna aktivnost maternic v primerih, ko je bil porod prezgoden, je bila torej bolj ponavljajoča se od električne aktivnosti maternic v primerih, ko je bil porod ob roku. Večja kompleksnost pri posnetkih, kjer je bil porod ob roku, je tudi potrdila domneve, ki smo jih postavili ob opazovanju signalov, predstavljenih na sliki 2.1.

Ostale tehnike so se izkazale za bolj občutljive na izbiro filtra. Še posebej je bila na izbiro filtra občutljiva mediana frekvence. Najboljše rezultate v smislu ločevanja skupin smo dobili ob uporabi filtrov od 0.3 Hz do 3 Hz in od 0.3 Hz do 4 Hz. Mediana frekvence se je obnesla bolje od korena srednje vrednosti kvadratov in od vrha močnostnega spektra. V nekaterih primerih smo opazili, da se srednja vrednost prvega prehoda preko ničle koeficientov avtokorelacije pri posnetkih, kjer je bil porod prezgoden, razlikuje od srednje vrednosti prvega prehoda preko ničle koeficientov avtokorelacije pri posnetkih, kjer je bil porod ob roku. Na žalost ob uporabi prvega prehoda preko ničle koeficientov avtokorelacije nikoli nismo obenem (ob uporabi istega filtra na istem kanalu) opazili nizkih vrednosti p_2 , p_3 , p_4 , p_5 in p_6 . Prvi prehod preko ničle koeficientov avtokorelacije lahko zato smatramo za manj robustno tehnika za ločevanje skupin posnetkov kot sta vzorčna entropija in mediana frekvence močnostnega spektra.

Pri nobeni tehniki nismo na istem kanalu ob istem uporabljenem filtru dobili nizkih vrednosti p_1 , p_2 in p_6 . Predvsem se je za težavno izkazalo ločevanje skupin glede na trajanje nosečnosti zgodaj v nosečnosti. Vseeno statistične razlike ob uporabi nekaterih tehnik obdelave signalov zgodaj v nosečnosti med skupinama, kjer je bil porod prezgoden oziroma ob roku nakazujejo, da lahko električno aktivnost maternice analiziramo tudi zgodaj, že okrog 22. tedna nosečnosti.

12.7 Rezultati statistične analize

V objavah drugih raziskovalcev [6, 18, 36, 44] smo zasledili, da se močnostni spekter električne aktivnosti maternice premakne proti višjim frekvencam, ko se približuje porod. V naši raziskavi pa smo opazili, da se je močnostni spekter med nosečnostjo premaknil proti nižjim frekvencam. Razlogov za nastalo razliko v rezultatih je več. Prvi razlog je ta, da smo v okviru naše raziskave obdelovali celotne 30-minutne posnetke EMG maternice, medtem ko so se tuji raziskovalci osredotočali na električno aktivnost maternice med ročno izbranimi salvami električne aktivnosti, povezanimi s krči maternice. Drugi razlog za razlike v rezultatih je ta, da so nekateri tuji raziskovalci dvig močnostnega spektra pri posnetkih, kjer je bil porod prezgoden in pri posnetkih, kjer je bil porod ob roku, opazili med porodom [18, 36]. Drugi so dvig močnostnega spektra signala opazili 24 ur pred porodom za posnetke, kjer je bil porod ob roku, oziroma 4 dni pred porodom za posnetke, kjer je bil porod prezgoden [44]. Nobena od tujih raziskovalnih ekip ni opazovala električne aktivnosti maternice bolj zgodaj v nosečnosti. V [6] so raziskovalci pri opazovanju posnetkov, kjer je bil porod prezgoden, v času od 6 do 8.5 tednov pred nosečnostjo opazili povečanje moči v območjih od 0.3 Hz do 0.6 Hz, od 0.6 Hz do 0.9 Hz ter od 1.2 Hz do 1.5 Hz, nato pa v času od 4.5 do 5.5 tednov pred porodom zmanjšanje moči v teh frekvenčnih pasovih. Povečanje moči v območjih od 0.3 Hz do 0.6 Hz, od 0.6 Hz do 0.9 Hz ter od 1.2 Hz do 1.5 Hz lahko smatramo kot premik močnostnega spektra proti nižjim frekvencam. Zmanjšanje moči v teh območjih lahko smatramo kot premik močnostnega spektra proti višjim frekvencam. Pri opazovanju posnetkov, kjer je bil porod ob roku, so v času od 6 do 8.5 tednov pred porodom opazili povečanje moči v območju od 0.9 Hz in 1.2 Hz, nato pa so v času od 4.5 do 5.5 tednov pred porodom opazili manjšanje moči v tem območju. Povečanje moči v območju od 0.9 Hz do 1.2 Hz lahko smatramo kot premik močnostnega spektra proti višjim frekvencam. Manjšanje moči v območju od 0.9 Hz do 1.2 Hz lahko smatramo kot premik močnostnega spektra proti nižjim frekvencam.

Posnetki, ki smo jih uporabili v naši raziskavi, so bili zajeti dosti bolj zgodaj v nosečnosti, kot posnetki tujih raziskovalcev. Med 382 posnetki s po enim posnetkom na nosečnost, nad katerimi smo izvajali statistično analizo, jih je bilo 54 zajetih manj kot 7 tednov pred porodom; med njimi je bilo 26 posnetkov zajetih med nosečnostmi, kjer je bil porod prezgoden. Manj kot 5 tednov pred nosečnostjo je bilo zajetih le 17 posnetkov, med njimi 14 takšnih, da je bil porod prezgoden. Zato lahko trdimo, da se močnostni spekter pri posnetkih, zajetih več kot 7 tednov pred porodom, med nosečnostjo premakne proti nižjim frekvencam.

Opazili smo tudi, da je bila mediana frekvenca močnostnega spektra nizka pri vseh posnetkih, zajetih pozno (okrog 31. tedna) v nosečnosti. To pomeni, da bi imela visoka mediana frekvenca posnetkov EMG maternice lahko negativno napovedno vrednost za grožnjo prezgodnjega poroda.

12.8 Izbira lastnosti za klasifikacijo

Pri klasifikaciji posnetkov smo kot lastnosti, na osnovi katerih smo klasificirali posnetke, uporabili večino naračunanih cenilk. Le pri večločljivostni vzorčni entropiji smo se omejili na en sam nabor parametrov L , m in r . Takšen pristop smo ubrali zato, ker smo pri statistični analizi cenilk ugotovili, da je v vsaj enem primeru vsaka cenilka potencialno uporabna za ločevanje skupin. Raje, kot da bi pri vsakem poizkusu tehtali ali morda celo izločevali cenilke, smo tudi zaradi boljše preglednosti rezultatov kot lastnosti posnetkov vsakič uporabili iste cenilke.

Pri klasifikaciji posnetkov z uporabo analize principalnih komponent smo prav tako uporabili vse pridobljene lastnosti. Običajno lahko tiste lastnosti, pridobljene z analizo principalnih komponent, ki razložijo najmanj variance, zavrzemo. Ker nismo vedeli, koliko lastnosti bi bilo smiselno upoštevati, smo se tudi tu odločili uporabiti vse. Verjetno bi bili rezultati klasifikacije z uporabo analize principalnih komponent boljši, če bi lastnosti, ki pojasnijo najmanj variance vzorcev in tako morda pomenijo le šum, zanemarili.

12.9 Testiranje klasifikatorjev

Pri klasifikaciji poljubnih vzorcev se pogosto soočamo s težavami zaradi premajhe učne množice. Takšne težave so še posebej značilne za medicinske raziskave, kjer je pridobivanje vsakega vzorca drago. V naši raziskavi smo se poleg tega srečali z dejstvom, da je bila učna množica v primerih, ko smo klasificirali posnetke glede na to, ali je do poroda prišlo

prezgodaj ali ob roku, močno neuravnotežena - porodov ob roku je namreč precej več, kot prezgodnjih.

Zaradi hude neuravnoteženosti našega nabora posnetkov je bilo v nekaterih primerih število pozitivnih primerov dovolj majhno, da se je klasifikator lahko naučil klasificirati vse posamezne pozitivne primere.

Pri testiranju performans klasifikatorjev, ko je učna množica majhna, je popularna metoda bootstrap [54], ali pa celo testiranje na sami učni množici. V naši raziskavi smo pokazali, da bi bilo takšno preverjanje klasifikatorjev, kot so odločitvena drevesa, nepravilno. Performanse odločitvenih dreves na učni množici so bile namreč nerealno dobre, medtem ko so se taista drevesa pri testiranju na množicah, ki niso bile enake učni, izkazala precej slabše. Klasifikacija z uporabo odločitvenih dreves se je tako v nekaterih primerih celo izkazala za slabšo od naključnega ugibanja, česar pa ob testiranju na učni množici ali njenih podmnožicah ne bi opazili.

Predvsem pri klasifikaciji v skupine, kjer je bilo število pozitivnih primerov majhno, kot na primer pri klasifikaciji posnetkov, kjer je bil porod prezgoden med posnetki, zajetimi pred 26. tednom nosečnosti, je bila uspešnost klasifikacije močno odvisna od metode testiranja. V primerih, ko je bilo število pozitivnih primerov večje, so bile razlike med rezultati testiranja z različnimi metodami manjše.

POGLAVJE 13

Zaključek

13.1 Prispevki znanosti

- **Razvoj robustnih avtomatskih tehnik za analizo posnetkov EMG maternice.**

Razvili smo orodja za obdelavo EMG maternice in spremljajočih podatkov ter njihov prikaz. Na osnovi orodij smo nato razvili uporabniški vmesnik za pregledovanje posnetkov ter izračunali vrsto cenilk in statistik. Orodja sestavljajo naslednji moduli:

- vmesnik za pregledovanje posnetkov,
- modul za filtriranje signalov,
- modul za izračun poljubne cenilke na poljubnem odseku signala, s pomočjo poljubnega zunanjega programa,
- modul za grafični prikaz osnovnih signalov, močnostnega spektra, spektrograma in časovno-frekvenčne predstavitev Wignerja in Villeja,
- modul za grafični prikaz in izpis podatkov statistične analize,
- modul za hiter razvoj, ažuriranje in testiranje klasifikatorjev, med kakršne sodijo naivni Bayesov klasifikator in odločitvena drevesa.

Za razliko od drugih avtorjev, ki analizirajo električno aktivnost med posameznimi, ročno izbranimi krči maternice, smo analizirali celotne 30 minutne posnetke električne aktivnosti maternice, s čimer smo se izognili subjektivnim vplivom, neizbežnim priročnem izbiranju posameznih salv električne aktivnosti maternice. Izračune vrednosti cenilk in statistik ter njihovih grafičnih predstavitev smo vršili avtomatsko, brez

človeške intervencije in vzporedno na več računalnikih.

- **Karakterizacija posnetkov EMG maternice v različnih obdobjih nosečnosti.**

Posnetke, pri katerih je bila poleg električne aktivnosti zajeta tudi ocena tlaka znotraj maternice, smo karakterizirali z uporabo časovno-frekvenčne predstavitve Wignerja in Villeja. Ugotovili smo, da se ob salvah električne aktivnosti, ki spremljajo krče maternice, v časovno-frekvenčni predstavitevi Wignerja in Villeja pojavljajo artefakti, ki izboljšajo opaznost salv električne aktivnosti. Takšnih artefaktov v spektrogramih nismo opazili. Ugotovili smo torej, da je časovno-frekvenčna predstavitev Wignerja in Villeja za analizo EMG maternice v nekaterih primerih primernejša od spektrograma. Za nekatere nosečnosti sta bila na voljo dva posnetka, eden narejen okrog 22. tedna, drugi okrog 31. tedna nosečnosti. Opazili smo, da se spekter med nosečnostjo prema-kne proti nižjim frekvencam.

- **Izbor linearnih in nelinearnih tehnik analize signalov za ločevanje skupin posnetkov EMG maternice s prezgodnjim porodom in porodom ob roku, narejenih tako okrog 22. kot okrog 31. tedna nosečnosti.**

Preizkusili smo več linearnih in nelinearnih tehnik obdelave signalov. Na osnovi statističnih ocen dobljenih cenilk smo ugotovili, da je najboljša linearna tehnika za ločevanje skupin posnetkov, kjer je prišlo do poroda ob roku ali prezgodnjega poroda in skupin posnetkov, narejenih okrog 22. in okrog 31. tedna nosečnosti, mediana frekvenca. Verjetnost, da je mediana frekvenca po predobdelavi s pasovno-prepustnim filtrom od 0.3 Hz do 4 Hz pri posnetkih, kjer je bil porod ob roku, enaka kot pri posnet-kih, kjer je bil porod prezgoden (p_6), je bila 0.045. Verjetnost, da je bila ob uporabi istega filtra mediana frekvenca med posnetki, zajetimi okrog 31. tedna nosečnosti, kjer je bil porod prezgoden, enaka kot pri posnetkih, zajetih okrog 31. tedna, kjer je bil porod ob roku (p_2), je bila 0.034. Verjetnost, da je mediana frekvenca pri posnetkih, zajetih okrog 22. tedna nosečnosti enaka, kot pri posnetkih, zajetih okrog 31. tedna nosečnosti (p_5), je bila 0.004.

Med nelinearnimi tehnikami se je za najboljšo izkazala vzorčna entropija. Verjetnost, da je vzorčna entropija pri $m = 3$ in $r = 0.15$ po predobdelavi s pasovno-prepustnim filtrom od 0.3 Hz do 3 Hz pri posnetkih, kjer je bil porod ob roku, enaka kot pri posnet-kih, kjer je bil porod prezgoden (p_6), je bila 0.005. Verjetnost, da je bila ob uporabi

istega filtra mediana frekvenca med posnetki, zajetimi okrog 31. tedna nosečnosti, kjer je bil porod prezgoden, enaka kot pri posnetkih, zajetih okrog 31. tedna, kjer je bil porod ob roku (p_2), je bila 0.042. Verjetnost, da je mediana frekvenca pri posnetkih, zajetih okrog 22. tedna nosečnosti enaka, kot pri posnetkih, zajetih okrog 31. tedna nosečnosti (p_5), je bila manj kot 0.001.

- **Analiza posnetkov EMG maternice zgodaj v nosečnosti, že okrog 22. tedna.**

Analizirali smo tudi posnetke, zajete okrog 22. tedna nosečnosti. Statistična analiza pridobljenih cenilk je pokazala, da se povprečna vrednost vzorčne entropije pri posnetkih, zajetih okrog 22. tedna nosečnosti, kjer je bil porod prezgodaj, razlikuje od povprečne vrednosti vzorčne entropije pri posnetkih, zajetih okrog 22. tedna nosečnosti, kjer je bil porod ob roku. Analiza posnetkov električne aktivnosti maternice je torej mogoča že tudi zgodaj v nosečnosti, v 22. tednu.

- **Razvoj hitrejšega algoritma za izračun vzorčne entropije.**

Za izračun vzorčne entropije se je doslej uporabljal algoritem, katerega časovna zahtevnost je $O(N^2)$. V okviru doktorske disertacije smo razvili hitrejši algoritem, katerega časovna zahtevnost na tipičnih signalih se približuje $O(N \cdot \log(N))$.

13.2 Nadaljne delo

Na področju raziskav EMG maternice je še dosti nepojasnjenega. V nadaljevanju so zato opisane le smeri raziskovanja, ki jih nameravamo ubrati v bližnji prihodnosti.

13.2.1 Izvoz posnetkov iz baze

Trenutno razviti in v tej doktorski disertaciji predstavljeni sistem za obdelavo je dovolj fleksibilen tudi za naše prihodnje potrebe, baza pa dobro urejena in dovolj zmogljiva za nadaljne delo. Vseeno bi bilo za širjenje našega sodelovanja dobro, če bi podatke iz baze lahko uporabljajo tudi ljudje, ki našega sistema ne poznajo in ki morda uporabljajo drugačna orodja, kot mi. Zato nameravamo v kratkem našemu sistemu dodati funkcionalnost, ki bo

omogočala izvoz posnetkov in spremljajočih podatkov v formatih, ki jih lahko berejo orodja za numerično matematiko, kot so OCTAVE, SCILAB in MATLAB ter v formatu WFDB [55].

13.2.2 Razširitev baze

V prihodnosti pričakujemo, da bomo lahko zajeli še več posnetkov EMG maternice. Te posnetke nameravamo dodati v našo podatkovno bazo in jo na ta način razširiti. Upamo, da bomo tako pridobili tudi po več posnetkov na eno nosečnost. Tako bi lahko opazovali spremembe lastnosti električne aktivnosti maternice, ko se bliža porod ter morda nekaj dni vnaprej napovedali, da bo do poroda prišlo zelo kmalu.

13.2.3 Analiza večkanalnih posnetkov

Še vedno ni jasno, kje in kako se v maternici prožijo popadki. Če bo mogoče, nameravamo z uporabo nove opreme v prihodnosti analizirati tudi več kot 4-kanalne posnetke električne aktivnosti maternice. S takimi posnetki bi verjetno lahko ugotovili, če v maternici res obstajajo t.i. pacemakerji in če, kje se nahajajo. Z večkanalnimi posnetki bi verjetno lahko tudi opazovali širjenje krčev po maternici. Na osnovi načina širjenja bi verjetno lahko sklepali, ali bo krčenje maternice učinkovito in se bodo kmalu začeli popadki, ali pa gre le za nenevarne krče.

13.2.4 Izračun drsečé vzorčne entropije

Novi algoritem za izračun vzorčne entropije, opisan v tem delu, ima to lastnost, da će časovni vrsti z znano entropijo na konec dodamo en sam vzorec, lahko dovolj podobne vzorce in ujemajoča se podzaporedja najdemo hitro in tako tudi hitro izračunamo vzorčno entropijo nove časovne vrste. Enako velja, če en vzorec začetka časovne vrste odstranimo. Ta lastnost novega algoritma nam omogoča, da lahko za poljubno časovno vrsto izračunamo vzorčno entropijo z drsečim oknom, ki nam lahko pove, kako se vzorčna entropija časovne vrste spreminja skozi čas.

V bližnji prihodnosti nameravamo preveriti, kako se drseča vzorčna entropija spreminja med krči maternice, kasneje, ko bodo na voljo novi posnetki, pa nameravamo preveriti, ali se vzorčna entropija spremeni ob uporabi določenih zdravil, kot kažejo nekatere raziskave [56].

13.2.5 Izboljšava klasifikacije

V tem delu smo poizkusili klasificirati posnetke v razrede, vendar smo pri tem uporabili le en nabor lastnosti posnetkov ter dve vrsti klasifikatorjev. V prihodnosti nameravamo preizkusiti še nekaj pristopov h klasifikaciji, predvsem tako, da pri klasifikaciji ne bomo uporabili tistih cenilk, ki so se v okviru raziskave izkazale za manj perspektivne. Poizkusili bomo tudi klasificirati posamezne signale, nato pa posnetek klasificirati glede na večinski razred, v katerega so bili uvrščeni signali, ki ga sestavlja.

Čeprav je meja 37 tednov nosečnosti za prezgodnji porod določena kot standard Svetovne zdravstvene organizacije (WHO), je očitno, da se tveganje za novorojenčka, ki je bil rojen dan pred dopolnjenim 37. tednom nosečnosti ne razlikuje bistveno od tveganja za novorojenčka, ki je bil rojen dva dni kasneje. Čim nižja pa je gestacijska starost, tem večje je tveganje za novorojenčka. Zato nameravamo v prihodnosti poleg klasifikacije v razrede poizkusiti tudi napovedati, čez koliko časa bo porod najverjetneje nastopil.

DODATEK A

Tabele izračunanih statistik

A.1 Povzetki statistik, urejeni po filtrih

Tabela A.1: Povzetek rezultatov za pasovno-prepustni filter 0.08Hz - 2.5Hz

Metoda	Kanal	p_1	p_2	p_3	p_4	p_5	p_6	p_7
Koren srednje vrednosti kvadrata <i>RMS</i>	1	0.987	0.504	0.650	0.763	0.882	0.623	0.992
	2	0.477	0.142	0.022	0.361	0.124	0.503	0.136
	3	0.329	0.527	0.507	0.216	0.166	0.293	0.319
Frekvenca vrha močnostnega spektra f_{\max}	1	0.621	0.388	0.203	0.592	0.779	0.957	0.892
	2	0.410	0.098	0.087	0.632	0.886	0.298	0.558
	3	0.831	0.773	0.249	0.081	0.048	0.688	0.015
Frekv. vrha močnostnega spektra z drsečim oknom f_{\max}	1	0.591	0.689	0.306	0.887	0.936	0.929	0.626
	2	0.265	0.310	0.036	0.244	0.083	0.530	0.180
	3	0.086	0.490	0.008	0.093	0.023	0.890	0.028
Mediana frekvenca f_{med}	1	0.406	0.795	0.060	0.955	0.832	0.708	0.702
	2	0.376	0.623	0.032	0.173	0.079	0.758	0.293
	3	0.338	0.520	0.022	0.298	0.132	0.851	0.174
Mediana frekvenca z drsečim oknom f_{med}	1	0.652	0.785	0.411	0.959	0.811	0.914	0.623
	2	0.112	0.672	0.021	0.071	0.023	0.933	0.121
	3	0.077	0.569	0.014	0.076	0.020	0.949	0.038
Prvi prehod preko ničle koef. avtokorelacije $\tau_{R_{xx}}$	1	0.296	0.046	0.022	0.895	0.528	0.394	0.305
	2	0.571	0.037	0.048	0.893	0.393	0.152	0.720
	3	0.379	0.090	0.008	0.064	0.008	0.354	0.080
Maksimalni eksponent Ljapunova λ_{\max}	1	0.765	0.347	0.837	0.510	0.584	0.377	0.726
	2	0.928	0.087	0.099	0.456	0.214	0.150	0.141
	3	0.111	0.164	0.912	0.666	0.621	0.036	0.551
Korelacijska dimenzija D_{corr}	1	0.434	0.320	0.006	0.011	0.001	0.991	0.003
	2	0.053	0.769	≤ 0.001	≤ 0.001	≤ 0.001	0.279	≤ 0.001
	3	0.145	0.519	0.216	≤ 0.001	≤ 0.001	0.156	≤ 0.001
Večločljivostna vzorčna entropija - najboljša $MSE, L = 1 m = 2, r = 0.1$	1	0.175	0.426	0.641	0.001	0.002	0.121	0.006
	2	0.723	0.261	0.053	≤ 0.001	≤ 0.001	0.282	0.001
	3	0.009	0.260	0.798	≤ 0.001	≤ 0.001	0.021	0.010
Vzorčna entropija - $m = 3, r = 0.15$ $sampEn$	1	0.241	0.538	0.785	0.020	0.021	0.194	0.026
	2	0.933	0.478	0.187	0.014	0.005	0.495	0.024
	3	0.035	0.275	0.906	0.010	0.011	0.024	0.069
Vzorčna entropija - najboljša $sampEn, m = 2, r = 0.1$	1	0.175	0.426	0.722	0.006	0.010	0.121	0.024
	2	0.824	0.353	0.114	0.005	0.002	0.420	0.014
	3	0.017	0.269	0.832	0.002	0.003	0.021	0.032

Tabela A.2: Povzetek rezultatov za pasovno-prepustni filter 0.08Hz - 3Hz

Metoda	Kanal	p_1	p_2	p_3	p_4	p_5	p_6	p_7
Koren srednje vrednosti kvadrata <i>RMS</i>	1	0.983	0.505	0.652	0.752	0.870	0.627	0.997
	2	0.477	0.145	0.022	0.354	0.121	0.507	0.138
	3	0.331	0.528	0.507	0.218	0.167	0.294	0.321
Frekvenca vrha močnostnega spektra f_{\max}	1	0.621	0.388	0.203	0.592	0.779	0.957	0.892
	2	0.410	0.098	0.087	0.632	0.886	0.298	0.558
	3	0.831	0.773	0.249	0.081	0.048	0.688	0.015
Frekv. vrha močnostnega spektra z drsečim oknom f_{\max}	1	0.706	0.771	0.447	0.916	0.958	0.949	0.637
	2	0.263	0.471	0.035	0.194	0.075	0.671	0.278
	3	0.094	0.585	0.009	0.094	0.027	0.945	0.033
Mediana frekvenca f_{med}	1	0.414	0.997	0.068	0.995	0.837	0.590	0.724
	2	0.376	0.786	0.033	0.152	0.079	0.897	0.335
	3	0.382	0.681	0.023	0.360	0.194	0.985	0.250
Mediana frekvenca z drsečim oknom f_{med}	1	0.645	0.932	0.516	0.941	0.954	0.796	0.742
	2	0.111	0.840	0.021	0.070	0.028	0.933	0.157
	3	0.067	0.719	0.013	0.099	0.033	0.912	0.050
Prvi prehod preko ničle koef. avtokorelacije $\tau_{R_{xx}}$	1	0.305	0.071	0.024	0.936	0.420	0.441	0.243
	2	0.542	0.045	0.047	0.848	0.366	0.175	0.691
	3	0.371	0.097	0.008	0.061	0.008	0.369	0.081
Maksimalni eksponent Ljapunova λ_{\max}	1	0.794	0.345	0.846	0.430	0.500	0.390	0.636
	2	0.929	0.095	0.107	0.455	0.218	0.160	0.145
	3	0.113	0.169	0.904	0.623	0.580	0.037	0.532
Koreacijska dimenzija D_{corr}	1	0.406	0.219	0.006	0.031	0.005	0.953	0.005
	2	0.026	0.932	≤ 0.001	≤ 0.001	≤ 0.001	0.288	≤ 0.001
	3	0.195	0.483	0.219	≤ 0.001	≤ 0.001	0.167	≤ 0.001
Večločljivostna vzorčna entropija - najboljša $MSE, L = 1 m = 2, r = 0.1$	1	0.102	0.497	0.669	≤ 0.001	0.001	0.093	0.004
	2	0.733	0.221	0.028	≤ 0.001	≤ 0.001	0.322	≤ 0.001
	3	0.009	0.171	0.739	≤ 0.001	≤ 0.001	0.010	0.005
Vzorčna entropija - $m = 3, r = 0.15$ <i>sampEn</i>	1	0.130	0.603	0.865	0.002	0.004	0.139	0.006
	2	0.992	0.384	0.123	0.010	0.003	0.465	0.013
	3	0.024	0.173	0.739	0.002	0.002	0.010	0.015
Vzorčna entropija - najboljša <i>sampEn</i> , $m = 2, r = 0.1$	1	0.102	0.497	0.805	0.002	0.003	0.093	0.005
	2	0.864	0.225	0.046	0.007	0.002	0.374	0.008
	3	0.015	0.171	0.739	0.001	0.001	0.010	0.014

Tabela A.3: Povzetek rezultatov za pasovno-prepustni filter 0.08Hz - 4Hz

Metoda	Kanal	p_1	p_2	p_3	p_4	p_5	p_6	p_7
Koren srednje vrednosti kvadrata <i>RMS</i>	1	0.974	0.505	0.655	0.726	0.842	0.632	0.971
	2	0.476	0.149	0.022	0.348	0.118	0.512	0.144
	3	0.335	0.528	0.505	0.221	0.170	0.296	0.326
Frekvenca vrha močnostnega spektra f_{\max}	1	0.654	0.965	0.203	0.890	0.809	0.769	0.539
	2	0.410	0.960	0.087	0.371	0.286	0.957	0.151
	3	0.831	0.860	0.249	0.139	0.113	0.916	0.051
Frekvn. vrha močnostnega spektra z drsečim oknom f_{\max}	1	0.594	0.838	0.621	0.653	0.678	0.595	0.955
	2	0.260	0.970	0.035	0.166	0.111	0.892	0.173
	3	0.115	0.902	0.010	0.169	0.115	0.771	0.082
Mediana frekvenca f_{med}	1	0.391	0.815	0.082	0.925	0.818	0.485	0.697
	2	0.361	0.996	0.033	0.139	0.088	0.918	0.330
	3	0.401	0.983	0.026	0.376	0.259	0.761	0.278
Mediana frekvenca z drsečim oknom f_{med}	1	0.589	0.847	0.685	0.730	0.773	0.599	0.998
	2	0.141	0.921	0.023	0.078	0.042	0.757	0.198
	3	0.069	0.974	0.012	0.144	0.076	0.680	0.079
Prvi prehod preko ničle koef. avtokorelacije τ_{Rxx}	1	0.281	0.080	0.025	0.994	0.467	0.490	0.255
	2	0.571	0.046	0.048	0.827	0.357	0.167	0.679
	3	0.343	0.108	0.008	0.055	0.007	0.402	0.080
Maksimalni eksponent Ljapunova λ_{\max}	1	0.844	0.359	0.854	0.368	0.434	0.428	0.578
	2	0.910	0.087	0.104	0.442	0.208	0.148	0.134
	3	0.123	0.153	0.864	0.644	0.587	0.036	0.525
Korelacijska dimenzija D_{corr}	1	0.540	0.473	0.007	0.011	0.002	0.956	0.003
	2	0.017	0.955	≤0.001	≤0.001	≤0.001	0.269	≤0.001
	3	0.048	0.412	0.317	≤0.001	≤0.001	0.069	≤0.001
Večločljivostna vzorčna entropija - najboljša $MSE, L = 1 m = 2, r = 0.1$	1	0.096	0.532	0.726	≤0.001	0.001	0.129	0.004
	2	0.807	0.154	0.017	≤0.001	≤0.001	0.294	≤0.001
	3	0.009	0.287	0.641	≤0.001	≤0.001	0.016	0.004
Vzorčna entropija - $m = 3, r = 0.15$ $sampEn$	1	0.171	0.582	0.873	0.012	0.016	0.169	0.021
	2	0.973	0.277	0.056	0.002	≤0.001	0.386	0.002
	3	0.018	0.464	0.771	0.004	0.007	0.030	0.029
Vzorčna entropija - najboljša $sampEn, m = 2, r = 0.1$	1	0.096	0.532	0.857	0.002	0.003	0.129	0.004
	2	0.838	0.168	0.017	0.001	≤0.001	0.324	0.001
	3	0.013	0.345	0.672	0.001	0.004	0.019	0.014

Tabela A.4: Povzetek rezultatov za pasovno-prepustni filter 0.3Hz - 2.5Hz

Metoda	Kanal	p_1	p_2	p_3	p_4	p_5	p_6	p_7
Koren srednje vrednosti kvadrata RMS	1	0.945	0.248	0.366	0.947	0.707	0.324	0.722
	2	0.456	0.003	0.004	0.147	0.014	0.059	0.017
	3	0.472	0.073	0.105	0.089	0.029	0.049	0.080
Frekvenca vrha močnostnega spektra f_{max}	1	0.641	0.084	0.014	0.052	0.009	0.377	0.014
	2	0.770	0.455	0.657	0.721	0.908	0.802	0.724
	3	0.995	0.406	0.157	0.038	0.016	0.572	0.086
Frekv. vrha močnostnega spektra z drsečim oknom f_{max}	1	0.925	0.262	0.080	0.020	0.006	0.361	0.033
	2	0.852	0.591	0.428	0.149	0.103	0.588	0.074
	3	0.848	0.204	0.125	0.143	0.064	0.275	0.145
Mediana frekvenca f_{med}	1	0.456	0.066	0.062	0.016	0.005	0.070	0.001
	2	0.467	0.558	0.997	0.570	0.563	0.346	0.468
	3	0.087	0.215	0.827	0.081	0.072	0.034	0.073
Mediana frekvenca z drsečim oknom f_{med}	1	0.498	0.182	0.169	0.025	0.010	0.145	0.014
	2	0.708	0.408	0.530	0.581	0.472	0.376	0.299
	3	0.120	0.159	0.770	0.391	0.344	0.035	0.347
Prvi prehod preko ničle koef. avtokorelacije $\tau_{R_{xx}}$	1	0.160	0.126	0.726	0.138	0.117	0.036	0.051
	2	0.096	0.304	0.517	0.646	0.775	0.055	0.492
	3	0.007	0.434	0.547	0.002	0.005	0.015	0.008
Maksimalni eksponent Ljapunova λ_{max}	1	0.912	0.237	0.478	0.484	0.679	0.419	0.807
	2	0.738	0.032	0.023	0.304	0.081	0.130	0.046
	3	0.375	0.041	0.251	0.465	0.254	0.027	0.186
Korelacijska dimenzija D_{corr}	1	0.338	0.834	0.085	0.073	0.036	0.540	0.023
	2	0.566	0.070	0.010	≤0.001	≤0.001	0.228	≤0.001
	3	0.855	0.820	0.452	0.154	0.108	0.920	0.085
Večločljivostna vzorčna entropija - najboljša $MSE, L = 1 m = 2, r = 0.1$	1	0.259	0.320	0.388	≤0.001	≤0.001	0.187	0.001
	2	0.484	0.006	≤0.001	≤0.001	≤0.001	0.047	≤0.001
	3	0.061	0.072	0.056	≤0.001	≤0.001	0.010	≤0.001
Vzorčna entropija - $m = 3, r = 0.15$ $sampEn$	1	0.404	0.501	0.493	0.002	0.002	0.259	0.010
	2	0.526	0.041	0.007	0.001	≤0.001	0.238	≤0.001
	3	0.092	0.088	0.170	≤0.001	≤0.001	0.014	0.002
Vzorčna entropija - najboljša $sampEn, m = 2, r = 0.1$	1	0.259	0.431	0.458	≤0.001	≤0.001	0.187	0.002
	2	0.484	0.006	0.002	≤0.001	≤0.001	0.056	≤0.001
	3	0.073	0.087	0.109	≤0.001	≤0.001	0.014	≤0.001

Tabela A.5: Povzetek rezultatov za pasovno-prepustni filter 0.3Hz - 3Hz

Metoda	Kanal	p_1	p_2	p_3	p_4	p_5	p_6	p_7
Koren srednje vrednosti kvadrata RMS	1	0.971	0.258	0.384	0.970	0.790	0.343	0.792
	2	0.457	0.004	0.004	0.142	0.014	0.065	0.020
	3	0.486	0.075	0.109	0.099	0.033	0.052	0.088
Frekvenca vrha močnostnega spektra f_{max}	1	0.641	0.084	0.014	0.052	0.009	0.377	0.014
	2	0.770	0.675	0.657	0.976	0.833	0.913	0.548
	3	0.960	0.406	0.157	0.027	0.011	0.542	0.069
Frekv. vrha močnostnega spektra z drsečim oknom f_{max}	1	0.937	0.258	0.073	0.019	0.005	0.364	0.032
	2	0.869	0.583	0.463	0.245	0.179	0.589	0.097
	3	0.842	0.212	0.138	0.163	0.076	0.280	0.157
Mediana frekvenca f_{med}	1	0.477	0.046	0.035	0.014	0.003	0.056	0.001
	2	0.530	0.491	0.778	0.586	0.539	0.343	0.368
	3	0.081	0.152	0.571	0.065	0.050	0.023	0.057
Mediana frekvenca z drsečim oknom f_{med}	1	0.455	0.172	0.137	0.014	0.005	0.124	0.012
	2	0.857	0.405	0.401	0.565	0.424	0.440	0.266
	3	0.118	0.128	0.576	0.228	0.179	0.027	0.207
Prvi prehod preko ničle koef. avtokorelacije τ_{Rxx}	1	0.180	0.151	0.744	0.143	0.124	0.047	0.066
	2	0.098	0.267	0.565	0.606	0.717	0.049	0.564
	3	0.031	0.428	0.923	0.002	0.003	0.035	0.009
Maksimalni eksponent Ljapunova λ_{max}	1	0.856	0.241	0.496	0.362	0.534	0.450	0.688
	2	0.752	0.033	0.024	0.311	0.085	0.128	0.048
	3	0.407	0.045	0.264	0.536	0.304	0.031	0.224
Korelacijska dimenzija D_{corr}	1	0.254	0.746	0.097	0.135	0.077	0.411	0.035
	2	0.254	0.065	0.005	≤0.001	≤0.001	0.389	≤0.001
	3	0.815	0.929	0.403	0.102	0.068	0.973	0.108
Večločljivostna vzorčna entropija - najboljša $MSE, L = 1 m = 2, r = 0.1$	1	0.176	0.250	0.372	≤0.001	≤0.001	0.081	0.002
	2	0.349	0.003	≤0.001	≤0.001	≤0.001	0.062	≤0.001
	3	0.063	0.023	0.068	≤0.001	≤0.001	0.004	0.001
Vzorčna entropija - $m = 3, r = 0.15$ $sampEn$	1	0.284	0.305	0.486	0.004	0.003	0.124	0.014
	2	0.424	0.009	0.001	0.001	≤0.001	0.137	≤0.001
	3	0.067	0.042	0.125	≤0.001	≤0.001	0.005	0.003
Vzorčna entropija - najboljša $sampEn, m = 2, r = 0.1$	1	0.176	0.250	0.372	≤0.001	≤0.001	0.081	0.002
	2	0.356	0.003	≤0.001	≤0.001	≤0.001	0.090	≤0.001
	3	0.067	0.023	0.068	≤0.001	≤0.001	0.004	0.001

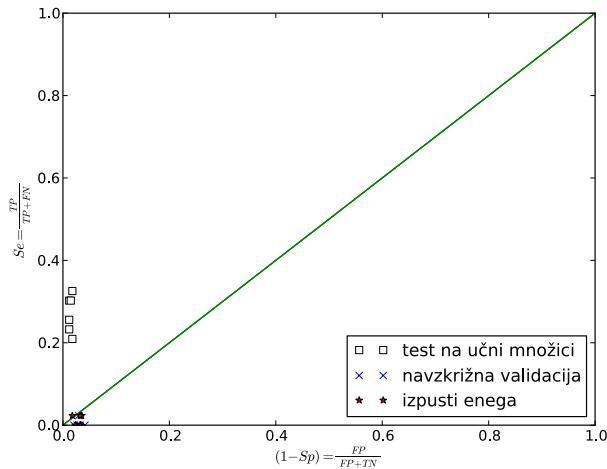
Tabela A.6: Povzetek rezultatov za pasovno-prepustni filter 0.3Hz - 4Hz

Metoda	Kanal	<i>p</i> ₁	<i>p</i> ₂	<i>p</i> ₃	<i>p</i> ₄	<i>p</i> ₅	<i>p</i> ₆	<i>p</i> ₇
Koren srednje vrednosti kvadrata <i>RMS</i>	1	0.987	0.266	0.419	0.788	0.978	0.369	0.956
	2	0.462	0.007	0.004	0.146	0.015	0.074	0.028
	3	0.514	0.076	0.110	0.116	0.040	0.056	0.101
Frekvenca vrha močnostnega spektra <i>f</i> _{max}	1	0.783	0.103	0.014	0.104	0.026	0.320	0.049
	2	0.211	0.902	0.424	0.913	0.794	0.404	0.663
	3	0.266	0.395	0.095	0.066	0.017	0.756	0.105
Frekv. vrha močnostnega spektra z drsečim oknom <i>f</i> _{max}	1	0.610	0.345	0.111	0.015	0.006	0.283	0.052
	2	0.834	0.514	0.477	0.863	0.732	0.494	0.562
	3	0.602	0.298	0.261	0.345	0.231	0.240	0.459
Mediana frekvenca <i>f</i> _{med}	1	0.480	0.034	0.015	0.018	0.004	0.045	0.005
	2	0.665	0.483	0.496	0.435	0.351	0.403	0.204
	3	0.237	0.084	0.096	0.027	0.011	0.035	0.036
Mediana frekvenca z drsečim oknom <i>f</i> _{med}	1	0.452	0.276	0.139	0.007	0.003	0.177	0.013
	2	0.863	0.401	0.227	0.463	0.289	0.567	0.231
	3	0.157	0.153	0.493	0.136	0.099	0.040	0.141
Prvi prehod preko ničle koef. avtokorelacije $\tau_{R_{xx}}$	1	0.839	0.224	0.119	0.054	0.021	0.308	0.044
	2	0.149	0.644	0.327	0.856	0.941	0.177	0.827
	3	0.030	0.125	0.790	0.018	0.016	0.008	0.060
Maksimalni eksponent Ljapunova λ_{\max}	1	0.786	0.241	0.543	0.201	0.323	0.488	0.476
	2	0.776	0.033	0.026	0.358	0.106	0.123	0.059
	3	0.456	0.047	0.272	0.647	0.381	0.037	0.297
Koreacijska dimenzija <i>D</i> _{corr}	1	0.196	0.416	0.251	0.277	0.218	0.170	0.196
	2	0.419	0.028	0.001	≤0.001	≤0.001	0.177	≤0.001
	3	0.526	0.539	0.319	0.013	0.008	0.419	0.019
Večločljivostna vzorčna entropija - najboljša <i>MSE</i> , <i>L</i> = 1 <i>m</i> = 2, <i>r</i> = 0.1	1	0.158	0.318	0.520	0.008	0.010	0.102	0.018
	2	0.327	0.001	≤0.001	≤0.001	≤0.001	0.036	≤0.001
	3	0.090	0.096	0.132	≤0.001	≤0.001	0.016	0.003
Vzorčna entropija - <i>m</i> = 3, <i>r</i> = 0.15 <i>sampEn</i>	1	0.158	0.414	0.901	0.034	0.044	0.109	0.052
	2	0.480	0.003	≤0.001	≤0.001	≤0.001	0.061	≤0.001
	3	0.101	0.238	0.357	≤0.001	≤0.001	0.042	0.008
Vzorčna entropija - najboljša <i>sampEn</i> , <i>m</i> = 2, <i>r</i> = 0.1	1	0.158	0.318	0.520	0.012	0.010	0.102	0.018
	2	0.412	0.001	≤0.001	≤0.001	≤0.001	0.036	≤0.001
	3	0.092	0.177	0.346	≤0.001	≤0.001	0.029	0.004

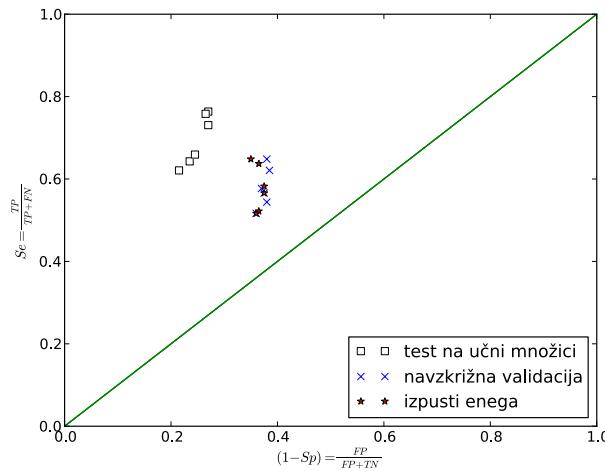
DODATEK B

Karakteristike klasifikatorjev z uporabo analize principalnih komponent

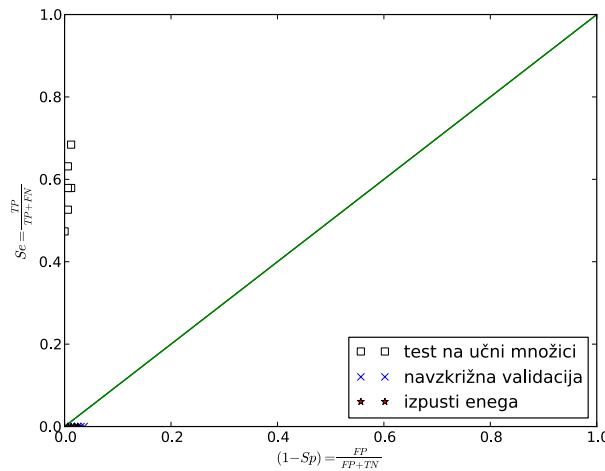
V tem dodatku so predstavljene karakteristike klasifikatorjev z uporabo analize principalnih komponent. Podatki, na osnovi katerih so bile sestavljene karakteristike, so predstavljeni v tabelah v dodatku C.



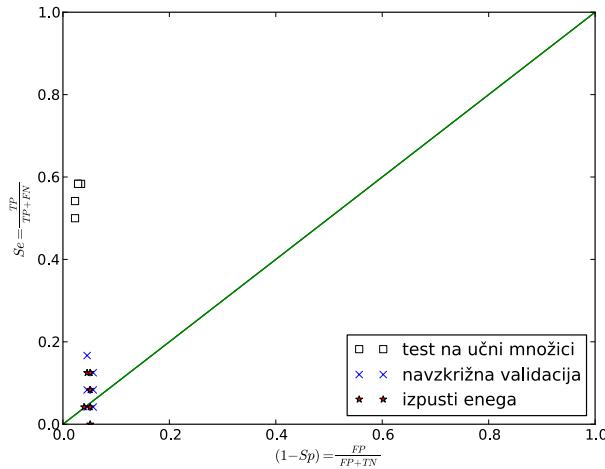
Slika B.1: Karakteristike klasifikatorjev za Bayesov naivni klasifikator pri klasifikaciji posnetkov, kjer je bil porod prezgoden, med vsemi posnetki (v smislu p_6 iz poglavja 10) z uporabo analize principalnih komponent.



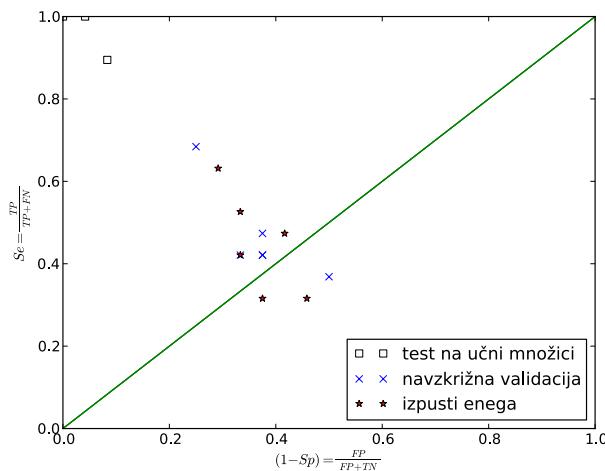
Slika B.2: Karakteristike klasifikatorjev za Bayesov naivni klasifikator pri klasifikaciji posnetkov, zajetih pred 26. tednom nosečnosti, med vsemi posnetki (v smislu p_5 iz poglavja 10) z uporabo analize principalnih komponent.



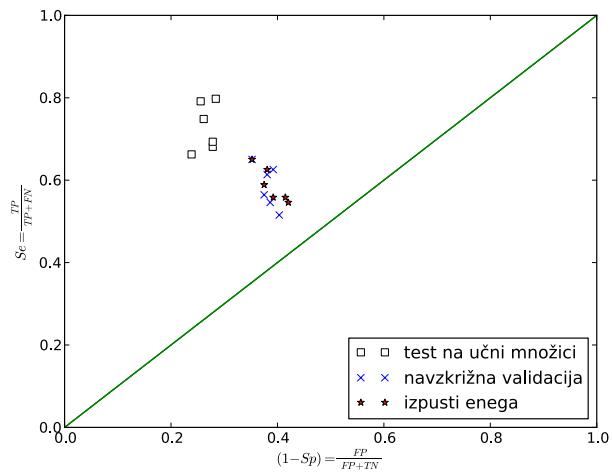
Slika B.3: Karakteristike klasifikatorjev za Bayesov naivni klasifikator pri klasifikaciji posnetkov, kjer je bil porod prezgoden, med posnetki, zajetimi pred 26. tednom nosečnosti (v smislu p_1 iz poglavja 10), z uporabo analize principalnih komponent.



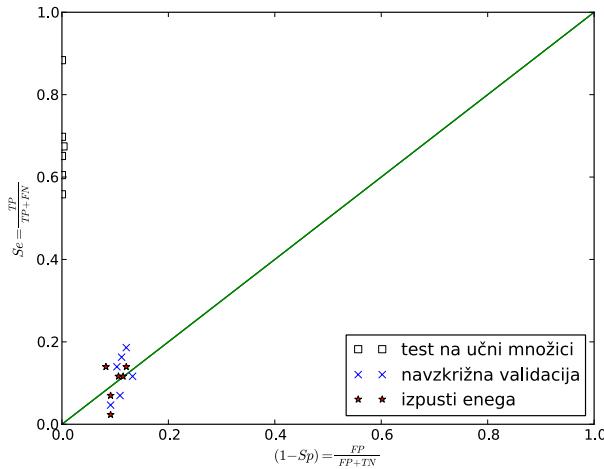
Slika B.4: Karakteristike klasifikatorjev za Bayesov naivni klasifikator pri klasifikaciji posnetkov, kjer je bil porod prezgoden, med posnetki, zajetimi med ali po 26. tednu nosečnosti (v smislu p_2 iz poglavja 10), z uporabo analize principalnih komponent.



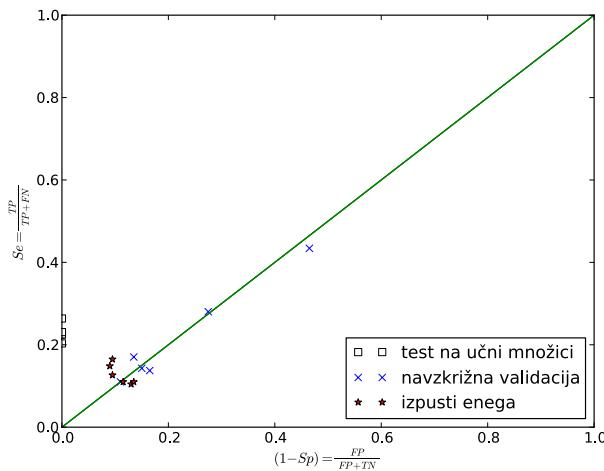
Slika B.5: Karakteristike klasifikatorjev za Bayesov naivni klasifikator pri klasifikaciji posnetkov, zajetih pred 26. tednom nosečnosti, med posnetki, kjer je bil porod prezgoden (v smislu p_3 iz poglavja 10), z uporabo analize principalnih komponent.



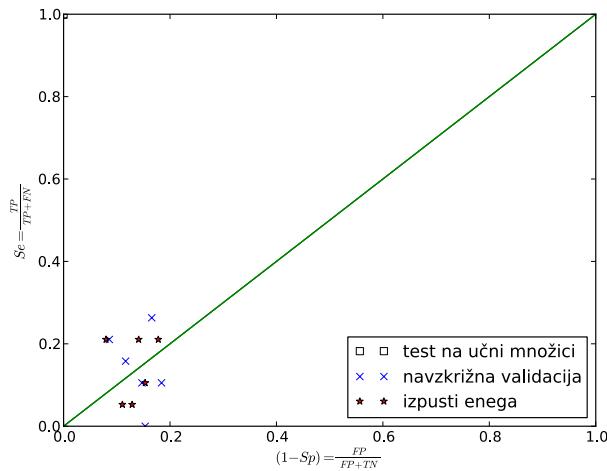
Slika B.6: Karakteristike klasifikatorjev za Bayesov naivni klasifikator pri klasifikaciji posnetkov, zajetih pred 26. tednom nosečnosti, med posnetki, kjer je bil porod ob roku (v smislu p_4 iz poglavja 10), z uporabo analize principalnih komponent



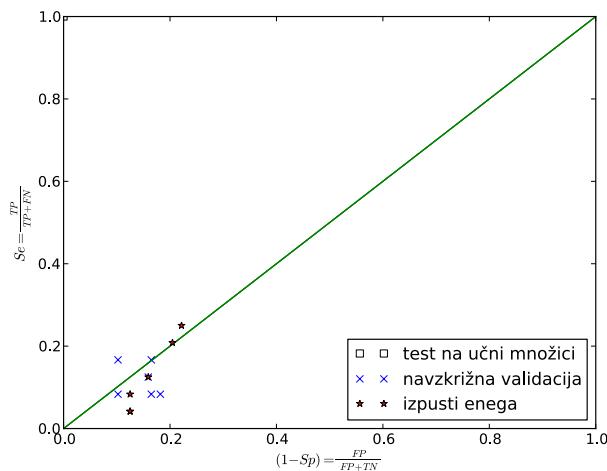
Slika B.7: Karakteristike klasifikatorjev za odločitvena drevesa pri klasifikaciji posnetkov, kjer je bil porod prezgoden, med vsemi posnetki (v smislu p_6 iz poglavja 10), z uporabo analize principalnih komponent.



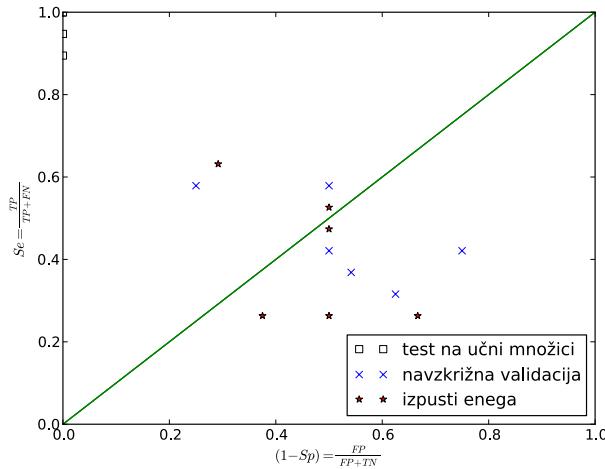
Slika B.8: Karakteristike klasifikatorjev za odločitvena drevesa pri klasifikaciji posnetkov, zajetih pred 26. tednom nosečnosti, med vsemi posnetki (v smislu p_5 iz poglavja 10), z uporabo analize principalnih komponent



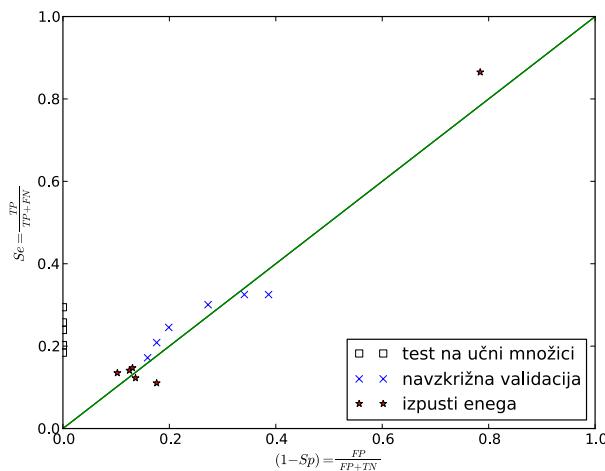
Slika B.9: Karakteristike klasifikatorjev za odločitvena drevesa pri klasifikaciji posnetkov, kjer je bil porod prezgoden, med posnetki, zajetimi pred 26. tednom nosečnosti (v smislu p_1 iz poglavja 10), z uporabo analize principalnih komponent



Slika B.10: Karakteristike klasifikatorjev za odločitvena drevesa pri klasifikaciji posnetkov, kjer je bil porod prezgoden, med posnetki, zajetimi med ali po 26. tednu nosečnosti (v smislu p_2 iz poglavja 10), z uporabo analize principalnih komponent



Slika B.11: Karakteristike klasifikatorjev za odločitvena drevesa pri klasifikaciji posnetkov, zajetih pred 26. tednom nosečnosti, med posnetki, kjer je bil porod prezgoden (v smislu p_3 iz poglavja 10), z uporabo analize principalnih komponent



Slika B.12: Karakteristike klasifikatorjev za odločitvena drevesa pri klasifikaciji posnetkov, zajetih pred 26. tednom nosečnosti, med postnetki, kjer je bil porod ob roku (v smislu p_4 iz poglavja 10), z uporabo analize principalnih komponent

DODATEK C

Tabele z rezultati preizkusov klasifikatorjev

Tabela C.1: Rezultati klasifikacije posnetkov, zajetih pred 26. tednom nosečnosti, z naivnim Bayesovim klasifikatorjem na vseh posnetkih

Metoda testiranja	Filter	<i>Se</i>	<i>Sp</i>	<i>Se + Sp</i>	<i>TP</i>	<i>FP</i>	<i>FN</i>	<i>TN</i>
Test na učni množici	0.08 - 2.5	71%	70%	141%	130	61	52	139
Navzkrižna validacija	0.08 - 2.5	66%	65%	131%	121	70	61	130
Izpusti enega	0.08 - 2.5	67%	67%	134%	122	66	60	134
Test na učni množici	0.08 - 3	74%	70%	144%	135	61	47	139
Navzkrižna validacija	0.08 - 3	68%	66%	134%	124	68	58	132
Izpusti enega	0.08 - 3	67%	65%	132%	122	70	60	130
Test na učni množici	0.08 - 4	74%	72%	146%	134	56	48	144
Navzkrižna validacija	0.08 - 4	68%	65%	133%	123	70	59	130
Izpusti enega	0.08 - 4	68%	66%	134%	124	68	58	132
Test na učni množici	0.3 - 2.5	68%	71%	139%	123	58	59	142
Navzkrižna validacija	0.3 - 2.5	64%	62%	126%	116	76	66	124
Izpusti enega	0.3 - 2.5	64%	62%	126%	116	76	66	124
Test na učni množici	0.3 - 3	69%	69%	138%	126	62	56	138
Navzkrižna validacija	0.3 - 3	63%	62%	125%	115	76	67	124
Izpusti enega	0.3 - 3	64%	61%	125%	117	79	65	121
Test na učni množici	0.3 - 4	69%	68%	136%	125	65	57	135
Navzkrižna validacija	0.3 - 4	65%	63%	127%	118	75	64	125
Izpusti enega	0.3 - 4	65%	64%	128%	118	73	64	127

Tabela C.2: Rezultati klasifikacije posnetkov, kjer je bil porod prezgoden, z naivnim Bayesovim klasifikatorjem na vseh posnetkih

Metoda testiranja	Filter	<i>Se</i>	<i>Sp</i>	<i>Se + Sp</i>	<i>TP</i>	<i>FP</i>	<i>FN</i>	<i>TN</i>
Test na učni množici	0.08 - 2.5	33%	94%	127%	14	20	29	319
Navzkrižna validacija	0.08 - 2.5	12%	93%	104%	5	25	38	314
Izпусти enega	0.08 - 2.5	14%	92%	106%	6	26	37	313
Test na učni množici	0.08 - 3	28%	92%	120%	12	26	31	313
Navzkrižna validacija	0.08 - 3	9%	91%	100%	4	30	39	309
Izpuсти enega	0.08 - 3	14%	91%	105%	6	29	37	310
Test na učni množici	0.08 - 4	40%	94%	134%	17	20	26	319
Navzkrižna validacija	0.08 - 4	12%	91%	102%	5	31	38	308
Izpuсти enega	0.08 - 4	12%	91%	103%	5	29	38	310
Test na učni množici	0.3 - 2.5	53%	73%	127%	23	90	20	249
Navzkrižna validacija	0.3 - 2.5	28%	74%	102%	12	87	31	252
Izpuсти enega	0.3 - 2.5	30%	74%	104%	13	89	30	250
Test na učni množici	0.3 - 3	49%	71%	119%	21	100	22	239
Navzkrižna validacija	0.3 - 3	33%	75%	107%	14	85	29	254
Izpuсти enega	0.3 - 3	33%	74%	106%	14	89	29	250
Test na učni množici	0.3 - 4	47%	76%	122%	20	82	23	257
Navzkrižna validacija	0.3 - 4	33%	79%	112%	14	70	29	269
Izpuсти enega	0.3 - 4	28%	77%	105%	12	77	31	262

Tabela C.3: Rezultati klasifikacije posnetkov, kjer je bil porod prezgoden, z naivnim Bayesovim klasifikatorjem na posnetkih, zajetih pred 26. tednom nosečnosti,

Metoda testiranja	Filter	<i>Se</i>	<i>Sp</i>	<i>Se + Sp</i>	<i>TP</i>	<i>FP</i>	<i>FN</i>	<i>TN</i>
Test na učni množici	0.08 - 2.5	63%	97%	160%	12	5	7	158
Navzkrižna validacija	0.08 - 2.5	11%	94%	105%	2	9	17	154
Izpuсти enega	0.08 - 2.5	5%	94%	100%	1	9	18	154
Test na učni množici	0.08 - 3	68%	97%	165%	13	5	6	158
Navzkrižna validacija	0.08 - 3	16%	94%	110%	3	10	16	153
Izpuсти enega	0.08 - 3	11%	94%	104%	2	10	17	153
Test na učni množici	0.08 - 4	74%	98%	172%	14	3	5	160
Navzkrižna validacija	0.08 - 4	16%	96%	112%	3	6	16	157
Izpuсти enega	0.08 - 4	16%	97%	113%	3	5	16	158
Test na učni množici	0.3 - 2.5	63%	91%	154%	12	15	7	148
Navzkrižna validacija	0.3 - 2.5	11%	93%	103%	2	12	17	151
Izpuсти enega	0.3 - 2.5	5%	93%	99%	1	11	18	152
Test na učni množici	0.3 - 3	68%	93%	162%	13	11	6	152
Navzkrižna validacija	0.3 - 3	11%	93%	103%	2	12	17	151
Izpuсти enega	0.3 - 3	16%	92%	108%	3	13	16	150
Test na učni množici	0.3 - 4	63%	91%	154%	12	15	7	148
Navzkrižna validacija	0.3 - 4	11%	93%	103%	2	12	17	151
Izpuсти enega	0.3 - 4	11%	92%	103%	2	13	17	150

Tabela C.4: Rezultati klasifikacije posnetkov, kjer je bil porod prezgoden, z naivnim Bayesovim klasifikatorjem na posnetkih, zajetih med ali po 26. tednu nosečnosti,

Metoda testiranja	Filter	<i>Se</i>	<i>Sp</i>	<i>Se + Sp</i>	<i>TP</i>	<i>FP</i>	<i>FN</i>	<i>TN</i>
Test na učni množici	0.08 - 2.5	63%	93%	155%	15	13	9	163
Navzkrižna validacija	0.08 - 2.5	25%	89%	114%	6	19	18	157
Izpusti enega	0.08 - 2.5	29%	90%	119%	7	18	17	158
Test na učni množici	0.08 - 3	58%	93%	152%	14	12	10	164
Navzkrižna validacija	0.08 - 3	25%	89%	114%	6	19	18	157
Izpusti enega	0.08 - 3	25%	90%	115%	6	17	18	159
Test na učni množici	0.08 - 4	54%	91%	146%	13	15	11	161
Navzkrižna validacija	0.08 - 4	25%	89%	114%	6	19	18	157
Izpusti enega	0.08 - 4	25%	89%	114%	6	20	18	156
Test na učni množici	0.3 - 2.5	67%	61%	127%	16	69	8	107
Navzkrižna validacija	0.3 - 2.5	38%	66%	104%	9	59	15	117
Izpusti enega	0.3 - 2.5	58%	41%	99%	14	104	10	72
Test na učni množici	0.3 - 3	75%	61%	136%	18	68	6	108
Navzkrižna validacija	0.3 - 3	42%	64%	105%	10	64	14	112
Izpusti enega	0.3 - 3	38%	65%	102%	9	62	15	114
Test na učni množici	0.3 - 4	63%	74%	136%	15	46	9	130
Navzkrižna validacija	0.3 - 4	38%	73%	111%	9	47	15	129
Izpusti enega	0.3 - 4	38%	74%	112%	9	45	15	131

Tabela C.5: Rezultati klasifikacije posnetkov, zajetih pred 26. tednom nosečnosti, z naivnim Bayesovim klasifikatorjem na posnetkih, kjer je bil porod prezgoden,

Metoda testiranja	Filter	<i>Se</i>	<i>Sp</i>	<i>Se + Sp</i>	<i>TP</i>	<i>FP</i>	<i>FN</i>	<i>TN</i>
Test na učni množici	0.08 - 2.5	95%	79%	174%	18	5	1	19
Navzkrižna validacija	0.08 - 2.5	79%	67%	146%	15	8	4	16
Izpusti enega	0.08 - 2.5	79%	71%	150%	15	7	4	17
Test na učni množici	0.08 - 3	95%	79%	174%	18	5	1	19
Navzkrižna validacija	0.08 - 3	79%	67%	146%	15	8	4	16
Izpusti enega	0.08 - 3	79%	71%	150%	15	7	4	17
Test na učni množici	0.08 - 4	95%	92%	186%	18	2	1	22
Navzkrižna validacija	0.08 - 4	79%	58%	137%	15	10	4	14
Izpusti enega	0.08 - 4	79%	67%	146%	15	8	4	16
Test na učni množici	0.3 - 2.5	74%	83%	157%	14	4	5	20
Navzkrižna validacija	0.3 - 2.5	58%	58%	116%	11	10	8	14
Izpusti enega	0.3 - 2.5	53%	67%	119%	10	8	9	16
Test na učni množici	0.3 - 3	68%	92%	160%	13	2	6	22
Navzkrižna validacija	0.3 - 3	53%	75%	128%	10	6	9	18
Izpusti enega	0.3 - 3	53%	67%	119%	10	8	9	16
Test na učni množici	0.3 - 4	74%	88%	161%	14	3	5	21
Navzkrižna validacija	0.3 - 4	63%	79%	142%	12	5	7	19
Izpusti enega	0.3 - 4	68%	75%	143%	13	6	6	18

Tabela C.6: Rezultati klasifikacije posnetkov, zajetih pred 26. tednom nosečnosti, z naivnim Bayesovim klasifikatorjem na posnetkih, kjer je bil porod ob roku,

Metoda testiranja	Filter	<i>Se</i>	<i>Sp</i>	<i>Se + Sp</i>	<i>TP</i>	<i>FP</i>	<i>FN</i>	<i>TN</i>
Test na učni množici	0.08 - 2.5	75%	71%	146%	123	51	40	125
Navzkrižna validacija	0.08 - 2.5	68%	63%	131%	111	65	52	111
Izпусти enega	0.08 - 2.5	67%	65%	132%	109	62	54	114
Test na učni množici	0.08 - 3	73%	69%	142%	119	55	44	121
Navzkrižna validacija	0.08 - 3	67%	61%	128%	109	68	54	108
Izpuсти enega	0.08 - 3	67%	64%	131%	109	63	54	113
Test na učni množici	0.08 - 4	75%	72%	148%	123	49	40	127
Navzkrižna validacija	0.08 - 4	69%	64%	133%	113	64	50	112
Izpuсти enega	0.08 - 4	69%	65%	134%	112	61	51	115
Test na učni množici	0.3 - 2.5	66%	71%	137%	107	51	56	125
Navzkrižna validacija	0.3 - 2.5	61%	63%	124%	100	66	63	110
Izpuсти enega	0.3 - 2.5	63%	64%	127%	103	63	60	113
Test na učni množici	0.3 - 3	67%	72%	139%	109	49	54	127
Navzkrižna validacija	0.3 - 3	61%	63%	123%	99	66	64	110
Izpuсти enega	0.3 - 3	62%	63%	124%	101	66	62	110
Test na učni množici	0.3 - 4	67%	67%	135%	110	58	53	118
Navzkrižna validacija	0.3 - 4	61%	61%	123%	100	68	63	108
Izpuсти enega	0.3 - 4	62%	61%	123%	101	69	62	107

Tabela C.7: Rezultati klasifikacije posnetkov, zajetih pred 26. tednom nosečnosti, z odločitvenimi drevesi na vseh posnetkih

Metoda testiranja	Filter	<i>Se</i>	<i>Sp</i>	<i>Se + Sp</i>	<i>TP</i>	<i>FP</i>	<i>FN</i>	<i>TN</i>
Test na učni množici	0.08 - 2.5	80%	80%	160%	146	41	36	159
Navzkrižna validacija	0.08 - 2.5	57%	70%	127%	103	60	79	140
Izpusti enega	0.08 - 2.5	64%	64%	128%	117	73	65	127
Test na učni množici	0.08 - 3	96%	53%	149%	175	94	7	106
Navzkrižna validacija	0.08 - 3	70%	53%	123%	128	94	54	106
Izpusti enega	0.08 - 3	81%	40%	121%	148	121	34	79
Test na učni množici	0.08 - 4	96%	65%	161%	174	70	8	130
Navzkrižna validacija	0.08 - 4	67%	53%	120%	122	94	60	106
Izpusti enega	0.08 - 4	71%	43%	114%	130	114	52	86
Test na učni množici	0.3 - 2.5	16%	100%	116%	30	0	152	200
Navzkrižna validacija	0.3 - 2.5	16%	86%	101%	29	29	153	171
Izpusti enega	0.3 - 2.5	16%	88%	104%	30	24	152	176
Test na učni množici	0.3 - 3	18%	100%	118%	33	0	149	200
Navzkrižna validacija	0.3 - 3	20%	86%	106%	36	28	146	172
Izpusti enega	0.3 - 3	15%	87%	101%	27	27	155	173
Test na učni množici	0.3 - 4	25%	100%	125%	45	0	137	200
Navzkrižna validacija	0.3 - 4	14%	85%	99%	25	30	157	170
Izpusti enega	0.3 - 4	10%	82%	92%	19	36	163	164

Tabela C.8: Rezultati klasifikacije posnetkov, kjer je bil porod prezgoden, z odločitvenimi drevesi na vseh posnetkih

Metoda testiranja	Filter	<i>Se</i>	<i>Sp</i>	<i>Se + Sp</i>	<i>TP</i>	<i>FP</i>	<i>FN</i>	<i>TN</i>
Test na učni množici	0.08 - 2.5	67%	100%	167%	29	0	14	339
Navzkrižna validacija	0.08 - 2.5	19%	88%	107%	8	40	35	299
Izpusti enega	0.08 - 2.5	7%	87%	94%	3	45	40	294
Test na učni množici	0.08 - 3	77%	100%	177%	33	0	10	339
Navzkrižna validacija	0.08 - 3	16%	88%	104%	7	40	36	299
Izpusti enega	0.08 - 3	7%	90%	97%	3	33	40	306
Test na učni množici	0.08 - 4	65%	100%	165%	28	0	15	339
Navzkrižna validacija	0.08 - 4	7%	89%	96%	3	36	40	303
Izpusti enega	0.08 - 4	7%	93%	100%	3	24	40	315
Test na učni množici	0.3 - 2.5	72%	100%	172%	31	0	12	339
Navzkrižna validacija	0.3 - 2.5	7%	89%	96%	3	38	40	301
Izpusti enega	0.3 - 2.5	9%	89%	98%	4	37	39	302
Test na učni množici	0.3 - 3	91%	100%	191%	39	0	4	339
Navzkrižna validacija	0.3 - 3	16%	90%	107%	7	33	36	306
Izpusti enega	0.3 - 3	7%	89%	96%	3	36	40	303
Test na učni množici	0.3 - 4	70%	100%	170%	30	0	13	339
Navzkrižna validacija	0.3 - 4	14%	90%	104%	6	35	37	304
Izpusti enega	0.3 - 4	16%	92%	109%	7	26	36	313

Tabela C.9: Rezultati klasifikacije posnetkov, kjer je bil porod prezgoden, z odločitvenimi drevesi na posnetkih, zajetih pred 26. tednom nosečnosti,

Metoda testiranja	Filter	<i>Se</i>	<i>Sp</i>	<i>Se + Sp</i>	<i>TP</i>	<i>FP</i>	<i>FN</i>	<i>TN</i>
Test na učni množici	0.08 - 2.5	100%	100%	200%	19	0	0	163
Navzkrižna validacija	0.08 - 2.5	5%	89%	94%	1	18	18	145
Izпусти enega	0.08 - 2.5	11%	88%	98%	2	20	17	143
Test na učni množici	0.08 - 3	100%	100%	200%	19	0	0	163
Navzkrižna validacija	0.08 - 3	11%	88%	99%	2	19	17	144
Izpuсти enega	0.08 - 3	11%	86%	96%	2	23	17	140
Test na učni množici	0.08 - 4	100%	100%	200%	19	0	0	163
Navzkrižna validacija	0.08 - 4	26%	91%	117%	5	15	14	148
Izpuсти enega	0.08 - 4	42%	87%	129%	8	22	11	141
Test na učni množici	0.3 - 2.5	100%	100%	200%	19	0	0	163
Navzkrižna validacija	0.3 - 2.5	16%	89%	105%	3	18	16	145
Izpuсти enega	0.3 - 2.5	16%	87%	103%	3	21	16	142
Test na učni množici	0.3 - 3	100%	100%	200%	19	0	0	163
Navzkrižna validacija	0.3 - 3	16%	83%	99%	3	28	16	135
Izpuсти enega	0.3 - 3	16%	84%	100%	3	26	16	137
Test na učni množici	0.3 - 4	100%	100%	200%	19	0	0	163
Navzkrižna validacija	0.3 - 4	5%	84%	89%	1	26	18	137
Izpuсти enega	0.3 - 4	5%	82%	87%	1	30	18	133

Tabela C.10: Rezultati klasifikacije posnetkov, kjer je bil porod prezgoden, z odločitvenimi drevesi na posnetkih, zajetih med ali po 26. tednu nosečnosti,

Metoda testiranja	Filter	<i>Se</i>	<i>Sp</i>	<i>Se + Sp</i>	<i>TP</i>	<i>FP</i>	<i>FN</i>	<i>TN</i>
Test na učni množici	0.08 - 2.5	100%	100%	200%	24	0	0	176
Navzkrižna validacija	0.08 - 2.5	8%	89%	97%	2	20	22	156
Izpuсти enega	0.08 - 2.5	17%	84%	100%	4	29	20	147
Test na učni množici	0.08 - 3	100%	100%	200%	24	0	0	176
Navzkrižna validacija	0.08 - 3	17%	86%	102%	4	25	20	151
Izpuсти enega	0.08 - 3	25%	84%	109%	6	28	18	148
Test na učni množici	0.08 - 4	100%	100%	200%	24	0	0	176
Navzkrižna validacija	0.08 - 4	4%	86%	91%	1	24	23	152
Izpuсти enega	0.08 - 4	8%	88%	96%	2	21	22	155
Test na učni množici	0.3 - 2.5	100%	100%	200%	24	0	0	176
Navzkrižna validacija	0.3 - 2.5	17%	84%	101%	4	28	20	148
Izpuсти enega	0.3 - 2.5	17%	84%	101%	4	28	20	148
Test na učni množici	0.3 - 3	100%	100%	200%	24	0	0	176
Navzkrižna validacija	0.3 - 3	29%	86%	115%	7	25	17	151
Izpuсти enega	0.3 - 3	29%	86%	115%	7	25	17	151
Test na učni množici	0.3 - 4	100%	100%	200%	24	0	0	176
Navzkrižna validacija	0.3 - 4	25%	82%	107%	6	31	18	145
Izpuсти enega	0.3 - 4	17%	86%	102%	4	25	20	151

Tabela C.11: Rezultati klasifikacije posnetkov, zajetih pred 26. tednom nosečnosti, z odločitvenimi drevesi na posnetkih, kjer je bil porod prezgoden,

Metoda testiranja	Filter	<i>Se</i>	<i>Sp</i>	<i>Se + Sp</i>	<i>TP</i>	<i>FP</i>	<i>FN</i>	<i>TN</i>
Test na učni množici	0.08 - 2.5	100%	100%	200%	19	0	0	24
Navzkrižna validacija	0.08 - 2.5	68%	71%	139%	13	7	6	17
Izpusti enega	0.08 - 2.5	68%	71%	139%	13	7	6	17
Test na učni množici	0.08 - 3	100%	100%	200%	19	0	0	24
Navzkrižna validacija	0.08 - 3	47%	67%	114%	9	8	10	16
Izpusti enega	0.08 - 3	53%	63%	115%	10	9	9	15
Test na učni množici	0.08 - 4	100%	100%	200%	19	0	0	24
Navzkrižna validacija	0.08 - 4	68%	63%	131%	13	9	6	15
Izpusti enega	0.08 - 4	63%	71%	134%	12	7	7	17
Test na učni množici	0.3 - 2.5	89%	100%	189%	17	0	2	24
Navzkrižna validacija	0.3 - 2.5	58%	75%	133%	11	6	8	18
Izpusti enega	0.3 - 2.5	63%	71%	134%	12	7	7	17
Test na učni množici	0.3 - 3	100%	100%	200%	19	0	0	24
Navzkrižna validacija	0.3 - 3	58%	71%	129%	11	7	8	17
Izpusti enega	0.3 - 3	58%	71%	129%	11	7	8	17
Test na učni množici	0.3 - 4	100%	100%	200%	19	0	0	24
Navzkrižna validacija	0.3 - 4	74%	67%	140%	14	8	5	16
Izpusti enega	0.3 - 4	74%	75%	149%	14	6	5	18

Tabela C.12: Rezultati klasifikacije posnetkov, zajetih pred 26. tednom nosečnosti, z odločitvenimi drevesi na posnetkih, kjer je bil porod ob roku,

Metoda testiranja	Filter	<i>Se</i>	<i>Sp</i>	<i>Se + Sp</i>	<i>TP</i>	<i>FP</i>	<i>FN</i>	<i>TN</i>
Test na učni množici	0.08 - 2.5	87%	81%	168%	142	33	21	143
Navzkrižna validacija	0.08 - 2.5	67%	59%	126%	110	73	53	103
Izpusti enega	0.08 - 2.5	27%	69%	96%	44	55	119	121
Test na učni množici	0.08 - 3	96%	52%	149%	157	84	6	92
Navzkrižna validacija	0.08 - 3	72%	51%	123%	117	86	46	90
Izpusti enega	0.08 - 3	84%	42%	126%	137	102	26	74
Test na učni množici	0.08 - 4	98%	89%	187%	159	19	4	157
Navzkrižna validacija	0.08 - 4	62%	57%	119%	101	76	62	100
Izpusti enega	0.08 - 4	64%	55%	118%	104	80	59	96
Test na učni množici	0.3 - 2.5	27%	100%	127%	44	0	119	176
Navzkrižna validacija	0.3 - 2.5	22%	83%	105%	36	30	127	146
Izpusti enega	0.3 - 2.5	21%	87%	108%	34	23	129	153
Test na učni množici	0.3 - 3	25%	100%	125%	41	0	122	176
Navzkrižna validacija	0.3 - 3	18%	88%	106%	30	22	133	154
Izpusti enega	0.3 - 3	16%	85%	101%	26	27	137	149
Test na učni množici	0.3 - 4	25%	100%	125%	40	0	123	176
Navzkrižna validacija	0.3 - 4	15%	82%	98%	25	31	138	145
Izpusti enega	0.3 - 4	11%	85%	96%	18	27	145	149

Tabela C.13: Rezultati klasifikacije posnetkov, zajetih pred 26. tednom nosečnosti, z naivnim Bayesovim klasifikatorjem z uporabo PCA na vseh posnetkih

Metoda testiranja	Filter	<i>Se</i>	<i>Sp</i>	<i>Se + Sp</i>	<i>TP</i>	<i>FP</i>	<i>FN</i>	<i>TN</i>
Test na učni množici	0.08 - 2.5	76%	73%	149%	139	54	43	146
Navzkrižna validacija	0.08 - 2.5	62%	62%	124%	113	77	69	123
Izпусти enega	0.08 - 2.5	64%	64%	127%	116	73	66	127
Test na učni množici	0.08 - 3	73%	73%	146%	133	54	49	146
Navzkrižna validacija	0.08 - 3	58%	63%	121%	105	74	77	126
Izпусти enega	0.08 - 3	58%	63%	121%	106	75	76	125
Test na učni množici	0.08 - 4	76%	74%	149%	138	53	44	147
Navzkrižna validacija	0.08 - 4	65%	62%	127%	118	76	64	124
Izпусти enega	0.08 - 4	65%	65%	130%	118	70	64	130
Test na učni množici	0.3 - 2.5	64%	77%	141%	117	47	65	153
Navzkrižna validacija	0.3 - 2.5	54%	62%	116%	99	76	83	124
Izпусти enega	0.3 - 2.5	52%	64%	116%	95	73	87	127
Test na učni množici	0.3 - 3	66%	76%	141%	120	49	62	151
Navzkrižna validacija	0.3 - 3	57%	63%	119%	103	75	79	125
Izпусти enega	0.3 - 3	57%	63%	119%	103	75	79	125
Test na učni množici	0.3 - 4	62%	79%	141%	113	43	69	157
Navzkrižna validacija	0.3 - 4	52%	64%	116%	94	72	88	128
Izпусти enega	0.3 - 4	52%	64%	116%	94	72	88	128

Tabela C.14: Rezultati klasifikacije posnetkov, kjer je bil porod prezgoden, z naivnim Bayesovim klasifikatorjem z uporabo PCA na vseh posnetkih

Metoda testiranja	Filter	<i>Se</i>	<i>Sp</i>	<i>Se + Sp</i>	<i>TP</i>	<i>FP</i>	<i>FN</i>	<i>TN</i>
Test na učni množici	0.08 - 2.5	30%	99%	129%	13	4	30	335
Navzkrižna validacija	0.08 - 2.5	0%	97%	97%	0	10	43	329
Izпусти enega	0.08 - 2.5	0%	97%	97%	0	11	43	328
Test na učni množici	0.08 - 3	26%	99%	124%	11	4	32	335
Navzkrižna validacija	0.08 - 3	0%	98%	98%	0	7	43	332
Izпусти enega	0.08 - 3	0%	98%	98%	0	8	43	331
Test na učni množici	0.08 - 4	33%	98%	131%	14	6	29	333
Navzkrižna validacija	0.08 - 4	0%	96%	96%	0	14	43	325
Izпусти enega	0.08 - 4	2%	96%	99%	1	12	42	327
Test na učni množici	0.3 - 2.5	23%	99%	122%	10	4	33	335
Navzkrižna validacija	0.3 - 2.5	2%	97%	99%	1	10	42	329
Izпусти enega	0.3 - 2.5	2%	98%	101%	1	6	42	333
Test na učni množici	0.3 - 3	21%	98%	119%	9	6	34	333
Navzkrižna validacija	0.3 - 3	0%	97%	97%	0	11	43	328
Izпусти enega	0.3 - 3	0%	97%	97%	0	11	43	328
Test na učni množici	0.3 - 4	30%	99%	129%	13	5	30	334
Navzkrižna validacija	0.3 - 4	0%	97%	97%	0	9	43	330
Izпусти enega	0.3 - 4	2%	97%	99%	1	11	42	328

Tabela C.15: Rezultati klasifikacije posnetkov, kjer je bil porod prezgoden, z naivnim Bayesovim klasifikatorjem z uporabo PCA na posnetkih, zajetih pred 26. tednom nosečnosti,

Metoda testiranja	Filter	<i>Se</i>	<i>Sp</i>	<i>Se + Sp</i>	<i>TP</i>	<i>FP</i>	<i>FN</i>	<i>TN</i>
Test na učni množici	0.08 - 2.5	68%	99%	167%	13	2	6	161
Navzkrižna validacija	0.08 - 2.5	0%	98%	98%	0	4	19	159
Izpusti enega	0.08 - 2.5	0%	98%	98%	0	4	19	159
Test na učni množici	0.08 - 3	53%	99%	152%	10	1	9	162
Navzkrižna validacija	0.08 - 3	0%	96%	96%	0	6	19	157
Izpusti enega	0.08 - 3	0%	98%	98%	0	4	19	159
Test na učni množici	0.08 - 4	58%	99%	157%	11	2	8	161
Navzkrižna validacija	0.08 - 4	0%	97%	97%	0	5	19	158
Izpusti enega	0.08 - 4	0%	99%	99%	0	2	19	161
Test na učni množici	0.3 - 2.5	63%	99%	163%	12	1	7	162
Navzkrižna validacija	0.3 - 2.5	0%	99%	99%	0	2	19	161
Izpusti enega	0.3 - 2.5	0%	98%	98%	0	3	19	160
Test na učni množici	0.3 - 3	47%	100%	147%	9	0	10	163
Navzkrižna validacija	0.3 - 3	0%	98%	98%	0	4	19	159
Izpusti enega	0.3 - 3	0%	99%	99%	0	1	19	162
Test na učni množici	0.3 - 4	58%	99%	157%	11	1	8	162
Navzkrižna validacija	0.3 - 4	0%	100%	100%	0	0	19	163
Izpusti enega	0.3 - 4	0%	98%	98%	0	3	19	160

Tabela C.16: Rezultati klasifikacije posnetkov, kjer je bil porod prezgoden, z naivnim Bayesovim klasifikatorjem z uporabo PCA na posnetkih, zajetih med ali po 26. tednu nosečnosti,

Metoda testiranja	Filter	<i>Se</i>	<i>Sp</i>	<i>Se + Sp</i>	<i>TP</i>	<i>FP</i>	<i>FN</i>	<i>TN</i>
Test na učni množici	0.08 - 2.5	54%	98%	152%	13	4	11	172
Navzkrižna validacija	0.08 - 2.5	4%	95%	100%	1	8	23	168
Izpusti enega	0.08 - 2.5	4%	96%	100%	1	7	23	169
Test na učni množici	0.08 - 3	58%	97%	155%	14	5	10	171
Navzkrižna validacija	0.08 - 3	17%	95%	112%	4	8	20	168
Izpusti enega	0.08 - 3	13%	95%	108%	3	8	21	168
Test na učni množici	0.08 - 4	58%	97%	155%	14	6	10	170
Navzkrižna validacija	0.08 - 4	4%	94%	98%	1	10	23	166
Izpusti enega	0.08 - 4	0%	95%	95%	0	9	24	167
Test na učni množici	0.3 - 2.5	58%	97%	155%	14	5	10	171
Navzkrižna validacija	0.3 - 2.5	8%	94%	103%	2	10	22	166
Izpusti enega	0.3 - 2.5	8%	95%	103%	2	9	22	167
Test na učni množici	0.3 - 3	50%	98%	148%	12	4	12	172
Navzkrižna validacija	0.3 - 3	13%	94%	107%	3	10	21	166
Izpusti enega	0.3 - 3	13%	95%	107%	3	9	21	167
Test na učni množici	0.3 - 4	58%	97%	155%	14	5	10	171
Navzkrižna validacija	0.3 - 4	8%	95%	104%	2	8	22	168
Izpusti enega	0.3 - 4	4%	95%	99%	1	9	23	167

Tabela C.17: Rezultati klasifikacije posnetkov, zajetih pred 26. tednom nosečnosti, z naivnim Bayesovim klasifikatorjem z uporabo PCA na posnetkih, kjer je bil porod prezgoden,

Metoda testiranja	Filter	<i>Se</i>	<i>Sp</i>	<i>Se + Sp</i>	<i>TP</i>	<i>FP</i>	<i>FN</i>	<i>TN</i>
Test na učni množici	0.08 - 2.5	100%	96%	196%	19	1	0	23
Navzkrižna validacija	0.08 - 2.5	42%	67%	109%	8	8	11	16
Izposti enega	0.08 - 2.5	53%	67%	119%	10	8	9	16
Test na učni množici	0.08 - 3	100%	100%	200%	19	0	0	24
Navzkrižna validacija	0.08 - 3	42%	63%	105%	8	9	11	15
Izposti enega	0.08 - 3	32%	63%	94%	6	9	13	15
Test na učni množici	0.08 - 4	100%	100%	200%	19	0	0	24
Navzkrižna validacija	0.08 - 4	47%	63%	110%	9	9	10	15
Izposti enega	0.08 - 4	42%	67%	109%	8	8	11	16
Test na učni množici	0.3 - 2.5	100%	100%	200%	19	0	0	24
Navzkrižna validacija	0.3 - 2.5	37%	50%	87%	7	12	12	12
Izposti enega	0.3 - 2.5	32%	54%	86%	6	11	13	13
Test na učni množici	0.3 - 3	100%	100%	200%	19	0	0	24
Navzkrižna validacija	0.3 - 3	68%	75%	143%	13	6	6	18
Izposti enega	0.3 - 3	63%	71%	134%	12	7	7	17
Test na učni množici	0.3 - 4	89%	92%	181%	17	2	2	22
Navzkrižna validacija	0.3 - 4	42%	63%	105%	8	9	11	15
Izposti enega	0.3 - 4	47%	58%	106%	9	10	10	14

Tabela C.18: Rezultati klasifikacije posnetkov, zajetih pred 26. tednom nosečnosti, z naivnim Bayesovim klasifikatorjem z uporabo PCA na posnetkih, kjer je bil porod ob roku,

Metoda testiranja	Filter	<i>Se</i>	<i>Sp</i>	<i>Se + Sp</i>	<i>TP</i>	<i>FP</i>	<i>FN</i>	<i>TN</i>
Test na učni množici	0.08 - 2.5	75%	74%	149%	122	46	41	130
Navzkrižna validacija	0.08 - 2.5	61%	62%	123%	100	67	63	109
Izposti enega	0.08 - 2.5	59%	63%	121%	96	66	67	110
Test na učni množici	0.08 - 3	80%	72%	151%	130	50	33	126
Navzkrižna validacija	0.08 - 3	63%	61%	123%	102	69	61	107
Izposti enega	0.08 - 3	63%	62%	125%	102	67	61	109
Test na učni množici	0.08 - 4	79%	74%	154%	129	45	34	131
Navzkrižna validacija	0.08 - 4	65%	65%	130%	106	62	57	114
Izposti enega	0.08 - 4	65%	65%	130%	106	62	57	114
Test na učni množici	0.3 - 2.5	68%	72%	140%	111	49	52	127
Navzkrižna validacija	0.3 - 2.5	56%	63%	119%	92	66	71	110
Izposti enega	0.3 - 2.5	56%	61%	117%	91	69	72	107
Test na učni množici	0.3 - 3	69%	72%	141%	113	49	50	127
Navzkrižna validacija	0.3 - 3	55%	61%	116%	89	68	74	108
Izposti enega	0.3 - 3	56%	59%	114%	91	73	72	103
Test na učni množici	0.3 - 4	66%	76%	142%	108	42	55	134
Navzkrižna validacija	0.3 - 4	52%	60%	111%	84	71	79	105
Izposti enega	0.3 - 4	55%	58%	113%	89	74	74	102

Tabela C.19: Rezultati klasifikacije posnetkov, zajetih pred 26. tednom nosečnosti, z odločitvenimi drevesi z uporabo PCA na vseh posnetkih

Metoda testiranja	Filter	<i>Se</i>	<i>Sp</i>	<i>Se + Sp</i>	<i>TP</i>	<i>FP</i>	<i>FN</i>	<i>TN</i>
Test na učni množici	0.08 - 2.5	23%	100%	123%	41	0	141	200
Navzkrižna validacija	0.08 - 2.5	14%	84%	97%	25	33	157	167
Izpusti enega	0.08 - 2.5	16%	91%	107%	30	19	152	181
Test na učni množici	0.08 - 3	20%	100%	120%	37	0	145	200
Navzkrižna validacija	0.08 - 3	28%	73%	101%	51	55	131	145
Izpusti enega	0.08 - 3	13%	91%	103%	23	19	159	181
Test na učni množici	0.08 - 4	23%	100%	123%	41	0	141	200
Navzkrižna validacija	0.08 - 4	43%	54%	97%	79	93	103	107
Izpusti enega	0.08 - 4	10%	87%	97%	19	26	163	174
Test na učni množici	0.3 - 2.5	23%	100%	123%	41	0	141	200
Navzkrižna validacija	0.3 - 2.5	14%	85%	99%	26	30	156	170
Izpusti enega	0.3 - 2.5	11%	87%	97%	20	27	162	173
Test na učni množici	0.3 - 3	26%	100%	126%	48	0	134	200
Navzkrižna validacija	0.3 - 3	11%	89%	100%	20	22	162	178
Izpusti enega	0.3 - 3	11%	89%	99%	20	23	162	177
Test na učni množici	0.3 - 4	23%	100%	123%	42	0	140	200
Navzkrižna validacija	0.3 - 4	17%	87%	104%	31	27	151	173
Izpusti enega	0.3 - 4	15%	91%	106%	27	18	155	182

Tabela C.20: Rezultati klasifikacije posnetkov, kjer je bil porod prezgoden, z odločitvenimi drevesi z uporabo PCA na vseh posnetkih

Metoda testiranja	Filter	<i>Se</i>	<i>Sp</i>	<i>Se + Sp</i>	<i>TP</i>	<i>FP</i>	<i>FN</i>	<i>TN</i>
Test na učni množici	0.08 - 2.5	56%	100%	156%	24	0	19	339
Navzkrižna validacija	0.08 - 2.5	19%	88%	107%	8	41	35	298
Izpusti enega	0.08 - 2.5	14%	92%	106%	6	28	37	311
Test na učni množici	0.08 - 3	65%	100%	165%	28	0	15	339
Navzkrižna validacija	0.08 - 3	12%	87%	98%	5	45	38	294
Izpusti enega	0.08 - 3	7%	91%	98%	3	31	40	308
Test na učni množici	0.08 - 4	88%	100%	188%	38	0	5	339
Navzkrižna validacija	0.08 - 4	14%	90%	104%	6	35	37	304
Izpusti enega	0.08 - 4	14%	88%	102%	6	41	37	298
Test na učni množici	0.3 - 2.5	70%	100%	170%	30	0	13	339
Navzkrižna validacija	0.3 - 2.5	7%	89%	96%	3	37	40	302
Izpusti enega	0.3 - 2.5	12%	88%	100%	5	39	38	300
Test na učni množici	0.3 - 3	60%	100%	160%	26	0	17	339
Navzkrižna validacija	0.3 - 3	5%	91%	96%	2	31	41	308
Izpusti enega	0.3 - 3	2%	91%	93%	1	31	42	308
Test na učni množici	0.3 - 4	67%	100%	167%	29	1	14	338
Navzkrižna validacija	0.3 - 4	16%	89%	105%	7	38	36	301
Izpusti enega	0.3 - 4	12%	89%	101%	5	36	38	303

Tabela C.21: Rezultati klasifikacije posnetkov, kjer je bil porod prezgoden, z odločitvenimi drevesi z uporabo PCA na posnetkih, zajetih pred 26. tednom nosečnosti,

Metoda testiranja	Filter	<i>Se</i>	<i>Sp</i>	<i>Se + Sp</i>	<i>TP</i>	<i>FP</i>	<i>FN</i>	<i>TN</i>
Test na učni množici	0.08 - 2.5	100%	100%	200%	19	0	0	163
Navzkrižna validacija	0.08 - 2.5	11%	82%	92%	2	30	17	133
Izпусти enega	0.08 - 2.5	21%	82%	103%	4	29	15	134
Test na učni množici	0.08 - 3	100%	100%	200%	19	0	0	163
Navzkrižna validacija	0.08 - 3	26%	83%	110%	5	27	14	136
Izpuсти enega	0.08 - 3	21%	86%	107%	4	23	15	140
Test na učni množici	0.08 - 4	100%	100%	200%	19	0	0	163
Navzkrižna validacija	0.08 - 4	0%	85%	85%	0	25	19	138
Izpuсти enega	0.08 - 4	5%	87%	92%	1	21	18	142
Test na učni množici	0.3 - 2.5	100%	100%	200%	19	0	0	163
Navzkrižna validacija	0.3 - 2.5	16%	88%	104%	3	19	16	144
Izpuсти enega	0.3 - 2.5	5%	89%	94%	1	18	18	145
Test na učni množici	0.3 - 3	100%	100%	200%	19	0	0	163
Navzkrižna validacija	0.3 - 3	11%	85%	96%	2	24	17	139
Izpuсти enega	0.3 - 3	11%	85%	95%	2	25	17	138
Test na učni množici	0.3 - 4	100%	100%	200%	19	0	0	163
Navzkrižna validacija	0.3 - 4	21%	91%	112%	4	14	15	149
Izpuсти enega	0.3 - 4	21%	92%	113%	4	13	15	150

Tabela C.22: Rezultati klasifikacije posnetkov, kjer je bil porod prezgoden, z odločitvenimi drevesi z uporabo PCA na posnetkih, zajetih med ali po 26. tednu nosečnosti,

Metoda testiranja	Filter	<i>Se</i>	<i>Sp</i>	<i>Se + Sp</i>	<i>TP</i>	<i>FP</i>	<i>FN</i>	<i>TN</i>
Test na učni množici	0.08 - 2.5	100%	100%	200%	24	0	0	176
Navzkrižna validacija	0.08 - 2.5	17%	84%	100%	4	29	20	147
Izpuсти enega	0.08 - 2.5	25%	78%	103%	6	39	18	137
Test na učni množici	0.08 - 3	100%	100%	200%	24	0	0	176
Navzkrižna validacija	0.08 - 3	13%	84%	97%	3	28	21	148
Izpuсти enega	0.08 - 3	21%	80%	100%	5	36	19	140
Test na učni množici	0.08 - 4	100%	100%	200%	24	0	0	176
Navzkrižna validacija	0.08 - 4	17%	90%	106%	4	18	20	158
Izpuсти enega	0.08 - 4	4%	88%	92%	1	22	23	154
Test na učni množici	0.3 - 2.5	100%	100%	200%	24	0	0	176
Navzkrižna validacija	0.3 - 2.5	8%	84%	92%	2	29	22	147
Izpuсти enega	0.3 - 2.5	8%	88%	96%	2	22	22	154
Test na učni množici	0.3 - 3	100%	100%	200%	24	0	0	176
Navzkrižna validacija	0.3 - 3	8%	90%	98%	2	18	22	158
Izpuсти enega	0.3 - 3	4%	88%	92%	1	22	23	154
Test na učni množici	0.3 - 4	100%	100%	200%	24	0	0	176
Navzkrižna validacija	0.3 - 4	8%	82%	90%	2	32	22	144
Izpuсти enega	0.3 - 4	13%	84%	97%	3	28	21	148

Tabela C.23: Rezultati klasifikacije posnetkov, zajetih pred 26. tednom nosečnosti, z odločitvenimi drevesi z uporabo PCA na posnetkih, kjer je bil porod prezgoden,

Metoda testiranja	Filter	<i>Se</i>	<i>Sp</i>	<i>Se + Sp</i>	<i>TP</i>	<i>FP</i>	<i>FN</i>	<i>TN</i>
Test na učni množici	0.08 - 2.5	89%	100%	189%	17	0	2	24
Navzkrižna validacija	0.08 - 2.5	37%	46%	83%	7	13	12	11
Izpusti enega	0.08 - 2.5	26%	63%	89%	5	9	14	15
Test na učni množici	0.08 - 3	100%	100%	200%	19	0	0	24
Navzkrižna validacija	0.08 - 3	42%	25%	67%	8	18	11	6
Izpusti enega	0.08 - 3	26%	50%	76%	5	12	14	12
Test na učni množici	0.08 - 4	100%	100%	200%	19	0	0	24
Navzkrižna validacija	0.08 - 4	32%	38%	69%	6	15	13	9
Izpusti enega	0.08 - 4	26%	33%	60%	5	16	14	8
Test na učni množici	0.3 - 2.5	100%	100%	200%	19	0	0	24
Navzkrižna validacija	0.3 - 2.5	58%	50%	108%	11	12	8	12
Izpusti enega	0.3 - 2.5	47%	50%	97%	9	12	10	12
Test na učni množici	0.3 - 3	95%	100%	195%	18	0	1	24
Navzkrižna validacija	0.3 - 3	58%	75%	133%	11	6	8	18
Izpusti enega	0.3 - 3	63%	71%	134%	12	7	7	17
Test na učni množici	0.3 - 4	100%	100%	200%	19	0	0	24
Navzkrižna validacija	0.3 - 4	42%	50%	92%	8	12	11	12
Izpusti enega	0.3 - 4	53%	50%	103%	10	12	9	12

Tabela C.24: Rezultati klasifikacije posnetkov, zajetih pred 26. tednom nosečnosti, z odločitvenimi drevesi z uporabo PCA na posnetkih, kjer je bil porod ob roku,

Metoda testiranja	Filter	<i>Se</i>	<i>Sp</i>	<i>Se + Sp</i>	<i>TP</i>	<i>FP</i>	<i>FN</i>	<i>TN</i>
Test na učni množici	0.08 - 2.5	26%	100%	126%	42	0	121	176
Navzkrižna validacija	0.08 - 2.5	33%	66%	98%	53	60	110	116
Izpusti enega	0.08 - 2.5	87%	22%	108%	141	138	22	38
Test na učni množici	0.08 - 3	18%	100%	118%	30	0	133	176
Navzkrižna validacija	0.08 - 3	30%	73%	103%	49	48	114	128
Izpusti enega	0.08 - 3	13%	90%	103%	22	18	141	158
Test na učni množici	0.08 - 4	24%	100%	124%	39	0	124	176
Navzkrižna validacija	0.08 - 4	33%	61%	94%	53	68	110	108
Izpusti enega	0.08 - 4	11%	82%	93%	18	31	145	145
Test na učni množici	0.3 - 2.5	29%	100%	129%	48	0	115	176
Navzkrižna validacija	0.3 - 2.5	21%	82%	103%	34	31	129	145
Izpusti enega	0.3 - 2.5	12%	86%	99%	20	24	143	152
Test na učni množici	0.3 - 3	20%	100%	120%	33	0	130	176
Navzkrižna validacija	0.3 - 3	25%	80%	105%	40	35	123	141
Izpusti enega	0.3 - 3	14%	88%	102%	23	22	140	154
Test na učni množici	0.3 - 4	26%	100%	126%	42	0	121	176
Navzkrižna validacija	0.3 - 4	17%	84%	101%	28	28	135	148
Izpusti enega	0.3 - 4	15%	87%	102%	24	23	139	153

DODATEK D

Izjava

Spodaj podpisani Gašper Fele-Žorž, univ. dipl. inž. računalništva in informatike,
z vpisno številko 63990188,
sem avtor doktorske disertacije z naslovom
Nelinearna analiza signalov elektromiograma maternice za napovedovanje prezgodnjega po-
roda.

S svojim podpisom zagotavljam, da:

- sem doktorsko disertacijo izdelal samostojno pod vodstvom mentorja prof. dr. Franca Jagra.
- so elektronska oblika doktorske disertacije, naslov (slov., angl.), povzetek (slov., angl.) ter ključne besede (slov., angl.) identični s tiskano obliko doktorske disertacije
- in soglašam z javno objavo elektronske oblike doktorske disertacije v zbirki „Dela FRI“.

V Ljubljani, dne 4. 1. 2010

Gašper Fele-Žorž, univ. dipl. inž. rač. in inf.

SEZNAM LITERATURE

- [1] EURO-PERISTAT. The european perinatal health report (data from 2004), 2008. URL <http://www.europeristat.com>.
- [2] Verdenik I. Multilayer prediction model for preterm delivery. Ph.D. thesis, University of Ljubljana, Medical faculty, Ljubljana, 2002.
- [3] Iams JD. Prediction and early detection of preterm labor. The American College of Obstetricians and Gynecologists 2003;101(2):402–412.
- [4] Meekai ST, Alfirovic Z, Heath VCF, Cicero S, Cacho AM, Williamson PR, Kypros HN. Cervical cerclage for prevention of preterm delivery in women with short cervix: randomised controlled trial. The Lancet 2004;363:1849–1853.
- [5] Jager F, Smrdel A. Metabolni in prirojeni dejavniki reproduktivnega zdravja, porod - letno poročilo za leto 2004/05 in plan dela za leto 2005/06 skupine: 1539 univerza v ljubljani. Technical report, Fakulteta za računalništvo in informatiko, 2005.
- [6] Leman H, Marque C, Gondry J. Use of the electrohysterogram signal for characterization of contractions during pregnancy. IEEE Transactions on Biomedical Engineering Oct 1999;46(10):1222–1229. Clinical Trial.
- [7] Maner WL, Garfield RE. Identification of human term and preterm labor using artificial neural networks on uterine electromyography data. Ann Biomed Eng Jan 2007; 35(3):465–473.
- [8] Garfield RE, Maner WL, MacKay LB, Schlembach D, Saade GR. Comparing uterine electromyography activity of antepartum patients versus term labor patients. American Journal of Obstetrics Gynecology Jul 2005;193(1):23–29.

- [9] Devedeux D, Marque C, Mansour S, Germain G, Duchene J. Uterine electromyography: a critical review. *American Journal of Obstetrics Gynecology* Dec 1993;169(6):1636–1653.
- [10] Maul H, Maner WL, Olson G, Saade GR, Garfield RE. Non-invasive transabdominal uterine electromyography correlates with the strength of intrauterine pressure and is predictive of labor and delivery. *J Matern Fetal Neonatal Med* May 2004;15(5):297–301.
- [11] Kavšek G. Electromyographic activity of the uterus in threatened preterm delivery. Master's thesis, University of Ljubljana, Medical faculty, Ljubljana, 2001.
- [12] Verdenik I, Pajntar M, Leskošek B. Uterine electrical activity as predictor of preterm birth in women with preterm contractions. *European Journal of Obstetrics Gynecology and Reproductive Biology* Apr 2001;95(2):149–153.
- [13] Maner WL, MacKay LB, Saade GR, Garfield RE. Characterization of abdominally acquired uterine electrical signals in humans, using a non-linear analytic method. *Medical Biological Engineering Computing* Mar 2006;44(1-2):117–123.
- [14] Lake DE, Richman JS, Griffin MP, Moorman JR. Sample entropy analysis of neonatal heart rate variability. *American Journal of Physiology* 2002;283(3).
- [15] Costa M, Goldberger AL, Peng CK. Multiscale entropy analysis of physiologic time series. *Physical Review Letters* 2002;89:062102.
- [16] Skinner J, Carpegnani C, Landisman C, Fulton K. Correlation dimension of heartbeat intervals is reduced in conscious pigs by myocardial ischemia. *Circulation Research* 1991;68:966–976.
- [17] Mansour S, Devedeux D, Germain G, Marque C, Duchene J. Uterine EMG spectral analysis and relationship to mechanical activity in pregnant monkeys. *Medical Biological Engineering Computing* Mar 1996;34(2):115–121.
- [18] Buhimschi C, Boyle MB, Garfield RE. Electrical activity of the human uterus during pregnancy as recorded from the abdominal surface. *Obstet Gynecol* 1997;90:102–111.
- [19] Dunn P, Hicks J. John Braxton Hicks (1823-97) and painless uterine contractions. *Arch Dis Child Fetal Neonatal Ed* Sep 1999;81:F157–158.

- [20] Wray S, Jones K, Kupittayanant S, Li Y, Matthew A, Monir-Bishty E, Noble K, Pierce SJ, Quenby S, Shmygol AV. Calcium signaling and uterine contractility. *J Soc Gynecol Investig* Jul 2003;10:252–264.
- [21] Nakanishi H, McLean J, Wood C, Burnstock G. The role of sympathetic nerves in control of the nonpregnant and pregnant uterus. *Journal of Reproductive Medicine* 1969;2:20–33.
- [22] Akay M. Nonlinear Biomedical Signal Processing, volume II, Dynamic Analysis and Modeling. IEEE Inc., 2001.
- [23] Fele-Žorž G. Characterization of EMG data. In Rudel D, Oberžan D (eds.), 1st International workshop on pregnant uterine smooth muscle EMG activity, 15-15. Institute of biomedical informatics, University of Ljubljana, July 2006; .
- [24] Khalil M, Duchêne J. Uterine EMG analysis: A dynamic approach for change detection and classification. *IEEE Transactions on Biomedical Engineering* June 2000;47(6):748–756.
- [25] Gondry J, Marque C, Duchene J, Cabrol D. Electrophysiology during pregnancy: preliminary report. *Biomedical Instrumentation Technology* Jul 1993;27(4):318–324.
- [26] Bloom S, Casey B, Schaffer J, McIntire D, Leveno K. A randomized trial of coached versus uncoached maternal pushing during the second stage of labor. *American Journal of Obstetrics Gynecology* Jan 2006;194:10–13.
- [27] Young R. Tissue-level signaling and control of uterine contractility: the action potential–calcium wave hypothesis. *Journal of the Society for Gynecologic Investigation* 2000;7:146–152.
- [28] Kao C. Biology of the uterus. 2 edition. Plenum Medical Book Company, 1989; 403–54.
- [29] Csapo AI. Contractile proteins and muscle. Mercel Dekker, 1971; 413–482.
- [30] Živa Novak-Antolič. Študij mediatorskih sistemov v humanem miometriju. Ph.D. thesis, University of Ljubljana, Medical faculty, Ljubljana, 1989.
- [31] Živa Novak-Antolič. Študij mediatorskih sistemov v miometriju podgane. Master's thesis, Medicinska fakulteta, Inštitut za patološko fiziologijo, Ljubljana, 1977.

- [32] Inoue Y, Nakao K, Okabe K. Some electrical properties of human pregnant myometrium. *American Journal of Obstetrics Gynecology* 1990;162:1090–1098.
- [33] McLean M, Smith R. Corticotrophin-releasing hormone and human parturition. *Reproduction* 2001;121(4):493–501.
- [34] Pajntar M, Verdenik I, Pusenjak S, Rudel D, Leskošek B. Activity of smooth muscles in human cervix and uterus. *European Journal of Obstetrics Gynecology and Reproductive Biology* Aug 1998;79(2):199–204.
- [35] Hon EHG, Davis CD. Cutaneous and uterine electrical potentials in labor—an experiment. *Obstetrics Gynecology* July 1958;12:47–53.
- [36] Marque C, Duchene J, Leclercq S, Panczer G, Chaumont J. Uterine EHG processing for obstetrical monitoring. *IEEE Transactions on Biomedical Engineering* Dec 1986; 33:1182–1187.
- [37] Chen PBS, Kuo CT. Stability analysis of digital filters under finite word-length effects. *IEE Proceedings August* 1989;136:167–172.
- [38] Oppenheim AV, Schafer RW, Buck JR. Discrete-Time Signal Processing. 2 edition. Prentice Hall, 1998; 731–746.
- [39] Jezewski J, Horoba K, Matonia A, Wrobel J. Quantitative analysis of contraction patterns in electrical activity signal of pregnant uterus as an alternative to mechanical approach. *Physiological Measurement* Oct 2005;26(5):753–767.
- [40] Rosenstein M, Collins J, De Luca CJ. A practical method for calculating largest Lyapunov exponent from small data sets,. Technical report, Boston University, NeuroMuscular research center, Boston, 1992.
- [41] Nagarajan P, Eswaran H, Wilson J, Murphy P, Lowery C, Preisl H. Analysis of uterine contractions: a dynamical approach. *The Journal of Maternal Fetal and Neonatal Medicine* 2003;14:8–20.
- [42] Takens F. Detecting strange attractors in turbulence. *Dynamical Systems and Turbulence* 1981;366–381. URL <http://dx.doi.org/10.1007/BFb0091924>.

- [43] Haase P, Schlink U, Richter M. Critical reconsideration of phase space embedding and local non-parametric prediction of ozone time series. *Water Air Soil Pollution Focus* Sep 2002;2(5-6):513–524. ISSN 1567-7230.
- [44] Maner WL, Garfield RE, Maul H, Olson G, Saade GR. Predicting term and preterm delivery with transabdominal uterine electromyography. *Obstetrics Gynecology Jun* 2003;101(6):1254–1260. Clinical Trial.
- [45] Iams JD, Johnson FF, O'Shaughnessy RW, West LC. A prospective random trial of home uterine activity monitoring in pregnancies at increased risk of preterm labor. *Am J Obstet Gynecol Sep* 1987;157:638–643.
- [46] Vrhovec J. Vrednotenje elektromiograma materničnega telesa in materničnega vratu z metodami entropije. Master's thesis, Univerza v Ljubljani, fakulteta za elektrotehniko, 2003.
- [47] Pugh W. Skip lists: A probabilistic alternative to balanced trees, 1990. URL <ftp://ftp.cs.umd.edu/pub/skipLists/skiplists.pdf>.
- [48] Staff of Research Max Fogiel, Education Association. The Statistics Problem Solver. Research & Education Association., Piscataway (New Jersey), 1996.
- [49] Demšar J, Zupan B. Orange: From experimental machine learning to interactive data mining. White paper, Faculty of Computer and Information Science, University of Ljubljana, 2004. URL <http://www.ailab.si/orange>.
- [50] Demšar J, Zupan B, Kattan MW, Beck JR, Bratko I. Naive Bayesian-based nomogram for prediction of prostate cancer recurrence. *Medical informatics Europe* 1999;436–441.
- [51] Quinlan JR. Induction of decision trees. *Machine Learning* 1986;1:81–106.
- [52] Egan JP. Signal Detection Theory and ROC Analysis. Academic Press Series in Cognition and Perception. Academic Press, 1975.
- [53] Hong-gunang M, Chong-zhao H. Selection of embedding dimension and delay time in phase space reconstruction. *Front Electr Electron Eng China* 2006;1:111–114.
- [54] Efron B. Bootstrap methods: Another look at the jackknife. *The Annals of Statistics* 1979;7(1):1–26.

-
- [55] Moody GB. WFDB Programmer's Guide. Tenth edition (revised and with additions for wfdb library version 10.4.24) edition. Harvard-MIT Division of Health Sciences and Technology, October 2009.
 - [56] Vrhovec J, Maček-Lebar A, Rudel D. Evaluating uterine electrohysterogram with entropy. In Jarm T, Kramar P, Županič A (eds.), IFMBE proceedings, volume 16. 11th Mediterranean Conference on Medical and Biological Engineering and Computing 2007, New York: Springer: International Federation for Medical and Biological Engineering, June 2007; 144–147.