

UNIVERZA V LJUBLJANI  
FAKULTETA ZA RAČUNALNIŠTVO IN INFORMATIKO

Vlada Semenova

**Ločevanje skupin elektromiografskih  
materničnih posnetkov s terminskim  
in prezgodnjim porodom z uporabo  
vzorčne entropije**

MAGISTRSKO DELO

ŠTUDIJSKI PROGRAM DRUGE STOPNJE  
RAČUNALNIŠTVO IN INFORMATIKA

MENTOR: prof. dr. Franc Jager

Ljubljana, 2016



Rezultati magistrskega dela so intelektualna lastnina avtorja in Fakultete za računalništvo in informatiko Univerze v Ljubljani. Za objavljanje ali izkoriščanje rezultatov magistrskega dela je potrebno pisno soglasje avtorja, Fakultete za računalništvo in informatiko ter mentorja.



## ZAHVALA

Iskreno se zahvaljujem svojemu mentorju, prof. dr. Francu Jagru, za vse strokovne nasvete in velikodušno vsestransko pomoč pri izdelavi magistrskega dela. Vedno je bil na razpolago in me znal pravilno usmeriti. Zahvaljujem se lektorici Aleksandri Gacič za lektoriranje teksta.

Zahvaljujem se tudi staršem, ki so mi omogočili študij in mi vedno stali ob strani.



# Kazalo

**Povzetek**

**Abstract**

<b>1</b>	<b>Uvod</b>	<b>1</b>
1.1	Pregled sorodnih del . . . . .	2
1.2	Cilji dela . . . . .	3
<b>2</b>	<b>Metode</b>	<b>5</b>
2.1	EMG - elektromiografija . . . . .	5
2.2	Podatkovna baza TPEHG DB . . . . .	5
2.3	Predobdelava posnetkov . . . . .	8
2.4	Vzorčna entropija . . . . .	11
2.5	Definicija problema . . . . .	14
2.6	Sintetično prevzorčevanje minoritetne množice (SMOTE) . . . . .	15
2.7	Analiza variance (ANOVA) . . . . .	16
2.8	Klasifikatorji . . . . .	18
2.9	Metrike zmogljivosti klasifikatorjev . . . . .	22
<b>3</b>	<b>Rezultati</b>	<b>27</b>
3.1	Rezultati analize variance (ANOVA) . . . . .	28
3.2	Rezultati vrednosti vzorčne entropije v odvisnosti od tedna posnetka . . . . .	30
3.3	Rezultati klasifikacije . . . . .	40

*KAZALO*

4 **Zaključek**

**63**



# Seznam uporabljenih kratic

kratica	angleško	slovensko
CA	classification accuracy	klasifikacijska točnost
Se	sensitivity	občutljivost
Sp	specificity	specifičnost
SVM	support vector machine	metoda podpornih vektorjev
<i>k</i> -NN	<i>k</i> -Nearest Neighbors algorithm	algoritm <i>k</i> najbližjih sosedov
LDA	Linear discriminant analysis	linearna diskriminantna analiza
QDA	Quadratic Discriminant Analysis	kvadratična diskriminantna analiza
EMG	electromyography	elektromiografija
PE	preterm early	prezgodnji zgodaj
TE	term early	terminski zgodaj
PL	preterm late	prezgodnji pozno
TL	term late	terminski pozno
ANOVA	Analysis of variance	analiza variance
SMOTE	Synthetic Mynority Oversampling Technique	sintetično prevzorčevanje minoritetne množice



# Povzetek

**Naslov:** Ločevanje skupin elektromiografskih materničnih posnetkov s terminskim in prezgodnjim porodom z uporabo vzorčne entropije

Napovedovanje prezgodnjega poroda je pereč in nerešen problem. V magistrskem delu sem se osredotočila na reševanje problema ločevanja in klasifikacije skupin elektromiografskih materničnih posnetkov s terminskim in prezgodnjim porodom, snemanih tako pred 26. kot po 26. tednu nosečnosti. Do sedaj so bile narejene raziskave, v katerih so ločevali ti dve skupini na frekvenčnem področju s spodnjo mejo od 0,08 Hz do 0,3 Hz ter zgornjimi mejami do 3 Hz ali 4 Hz. V magistrskem delu sem se osredotočila na področji med 0,08 Hz ter 5 Hz, saj ti predeli niso dobro raziskani. Uporabila sem vzorčno entropijo, kot eno od trenutno najbolj obetavnih tehnik in mednarodno referenčno podatkovno bazo TPEHG DB materničnih elektromiografskih posnetkov. Za klasifikacijo posnetkov sem testirala klasifikator  $k$  najbližjih sosedov ( $k$ -NN), klasifikatorja z linearno in kvadratično diskriminantno analizo (LDA, QDA), Naivni Bayes, metodo podpornih vektorjev ter odločitvena drevesa. Za oceno stopnje ločevanja skupin posnetkov sem uporabila statistično analizo variance (ANOVA). Zaradi neenakomerne porazdelitve med številom posnetkov, ki so bili prezgodnji ter terminski, sem uporabila metodo sintetičnega prevzorčevanja minoritetne množice (SMOTE), da bi s tem zagotovila resničnejše rezultate. Rezultat magistrskega dela je, da smo potrdili, da je za klasifikacijo med prezgodnjimi in terminskimi porodi na posnetkih, ki so bili posneti zgodaj, najboljše področje od 1 Hz - 5 Hz. Ugotovili smo tudi, da z višanjem frekvence ali širjenjem frekvenčnega območja, postanejo pre-

## KAZALO

zgodnji posnetki manj regularni in manj napovedljivi; terminski posnetki pa nasprotno postanejo bolj regularni ter bolj napovedljivi. Doseženi rezultati klasifikacije posnetkov s terminskim in prezgodnjim porodom so ob uporabi frekvenčnega področja od 1 Hz do 2,2 Hz in samo značilnik vzorčne entropije (občutljivost 88,8 %, specifičnost 81,8 %, klasifikacijska točnost 85,3 %) povsem primerljivi doseženim rezultatom klasifikacije drugih obstoječih študij (občutljivost 89 %, specifičnost 91 %, klasifikacijska točnost 90 %), ki pa so poleg značilnik vzorčne entropije vključevale še druge značilke signalov, značilke spektrov signalov, prav tako pa tudi dodatno klinično informacijo o nosečnostih.

**Ključne besede:** terminski porod, prezgodnji porod, podatkovna baza TPEHG DB, klasifikacija med posnetki s prezgodnjim in terminskim porodom, Butterworth-ov filter, vzorčna entropija.

# Abstract

**Title:** Separating sets of term and pre-term uterine electromyogram records using sample entropy

Predicting preterm labour is a serious and unresolved problem. In this master thesis I focused on resolving the problem of separation and classification of groups of uterine electromyographic recordings with the term and pre-term birth, which were recorded before 26th week and after 26th week of gestation. Until now, studies have been made where they separated the two groups in the frequency range with a lower limit of 0.08 Hz to 0.3 Hz and highest limit of 3 Hz or 4 Hz. In this master thesis, I focused on the area between 0.08 Hz and 5 Hz, since these areas are not well researched. I used the sample entropy as one of the currently most promising techniques and international reference database TPEHG DB of uterine electromyographic recordings. For the classification of recordings I tested the  $k$  nearest neighbors ( $k$ -NN) classifier, linear and quadratic discriminant analysis (LDA, QDA) classifiers, Naive Bayes, support vector machine method and decision trees. To assess the degree of separation of groups of recordings I used a statistical analysis of variance (ANOVA). Because of the uneven distribution of the number of recordings that were preterm and term, I used Synthetic Minority Over-sampling Technique (SMOTE), in order to ensure more real results. The result of the master's thesis is that it was confirmed that the classification between preterm and term births on the recordings that were recorded early the best area was from 1 Hz - 5 Hz. We have also found that by increasing of the frequency or by widening of the frequency area, preterm recordings

become less regular and less predictable; term recordings on the contrary, become more regular and more predictable. The achieved results of classification of recordings with term and preterm delivery using frequency band from 1 Hz and 2.2 Hz, and sample entropy features only, (Sensitivity 88.8 %, Specificity 81.8 %, Classification accuracy 85.3 %) are quite comparable to achieved results of classification of other existing studies (Sensitivity 89 %, Specificity 91 %, Classification accuracy 90 %) which, besides sample entropy features, also involved other signal features, signal spectra features, as well as additional clinical information about pregnancies.

**Keywords:** Term labour, Pre-term labour, TPEHG DB data base, Classification between sets of term and pre-term records, Butterworth filter, Sample entropy.

# Poglavje 1

## Uvod

Spontani prezgodnji porod je tisti porod, pri katerem se popadki začnejo med 22. in 37. tednom nosečnosti. Popadki lahko vodijo v prezgodnji porod pred 37. tednom, v približno 50 % pa prenehajo. Za novorojence so resno ogrožajoči prezgodnji porodi pred 32. tednom nosečnosti, govorimo o zelo prezgodnjem porodu, pred 28. tednom pa o ekstremno prezgodnjem porodu.

Incidenca prezgodnjih porodov v Sloveniji je 6 %, v ZDA 11,5 % in vedno bolj narašča. Od tega je ena tretjina porodov zelo prezgodnjih in ekstremno prezgodnjih (porod pred 32. oziroma pred 28. tednom nosečnosti). Zadnjih deset let se pri nas rodi dober odstotek otrok pred 32. tednom nosečnosti in 0,5 odstotka otrok pred 28. tednom nosečnosti. Razloga za to sta višanje starosti nosečnic in porast oploditev z biomedicinsko pomočjo [1].

Prezgodnji porod ima neželene posledice, kot je porast smrtnosti otrok ali zdravstvene težave pri otrocih. Napoved prezgodnjega poroda večinoma temelji na izračunu dejavnikov tveganja. Dejavniki tveganja so: sladkorna bolezen, kajenje in visok pritisk. Ena od najbolj obetavnih tehnik je analiza elektromiograma maternice. Z elektromiogramom maternice merimo njeno električno aktivnost. Električni signali v maternici so neke vrste ukaz za krče. Zanimivo je, da so te električne aktivnosti prisotne v času nosečnosti, tudi če ženska še ne rojeva [2]. Raven aktivnosti narašča proti porodu, najvišja aktivnost je še posebej opazna v zadnjih treh do štirih dneh pred porodom.

Da bi lahko napovedali nevarnost prezgodnjega poroda tako zgodaj, je zelo pomembno, da pravočasno ustrezno ukrepamo. Pri našem delu želimo dobiti čim boljši rezultat klasifikacije za posnetke prezgodnjega poroda, ki bi bili zajeti tudi pred 26. tednom nosečnosti.

## 1.1 Pregled sorodnih del

Večina dosedanjih raziskav za napovedovanje prezgodnjega poroda, ki analizirajo elektromiogram maternice, temelji na analizi individualnih popadkov [3, 4, 5], katerih močnostni spekter se analizira v frekvenčnem območju do 1 Hz. Ti sistemi so sposobni napovedati porod od nekaj dni pa do nekaj tednov (do dva) pred porodom. Drugi sistemi analizirajo 30-minutne posnetke, ki so zajeti zgodaj v nosečnosti in v celoti. Cilj je napovedati nevarnost prezgodnjega poroda že zgodaj, v 23. tednu nosečnosti. V [6] so avtorji s pomočjo različnih linearnih in nelinearnih tehnik analize signalov poskušali ločevati posnetke terminskega in prezgodnjega poroda. Za izračun cenilk so uporabili koren srednje vrednosti kvadratov signala, vrh in mediano močnostnega spektra signala, prehod preko ničle avtokorelacije, maksimalni Lyapunov eksponent, korelacijsko dimenzijo in vzorčno entropijo. Posebnost te raziskave je, da je bila izvedena na širših frekvenčnih področjih 0,08 Hz do 4 Hz, od 0,03 Hz do 3 Hz ter od 0,03 Hz do 4 Hz. Vzorčna entropija je ob uporabi najširšega frekvenčnega področja (0,08 Hz do 4 Hz) pokazala dobre rezultate za ločevanje obeh skupin posnetkov takrat, ko so ti zajeti že okrog 23. tedna nosečnosti. Manjša kot je vrednost vzorčne entropije, bolj je signal regularen ali napovedljiv, oziroma bolj se približuje porod. Podobne rezultate v smislu ločevanja skupin posnetkov so dosegli tudi v [2]. Tudi v tem delu se je vzorčna entropija pokazala kot ena izmed nelinearnih tehnik, kot obetavna metoda za klasifikacijo posnetkov, uporabljeno področje pa je bilo od 0,34 Hz in le do 1 Hz.

Zadnje raziskave ocenjevanja močnostnih spektrov signalov posnetkov mednarodne podatkovne baze TPEHG DB (Term Pre-term EHG DataBase)[6,



7], s terminskim in prezgodnjim porodom so pokazale, da se v frekvenčnem področju od 0.3 Hz do 4 Hz, 0,3 Hz do 3 Hz, 0,08 Hz do 4 Hz kažejo aktivnosti, ki so verjetno rezultat materničnih fizioloških mehanizmov in so povezane s popadki ter drugimi električnimi aktivnostmi maternice. Pričakujemo, da bo uporaba vzorčne entropije v višjih frekvenčnih področjih rezultirala v višjo točnost ločevanja skupin posnetkov ter višjo občutljivost in specifičnost klasifikacije posnetkov.

## 1.2 Cilji dela

Naši cilji so bili naslednji:

- pokazati, da uporaba vzorčne entropije v višjih frekvenčnih področjih nad 1 Hz rezultira v višjo točnost ločevanja skupin posnetkov ter višjo občutljivost in specifičnost klasifikacije;
- raziskati, kateri klasifikator daje najboljše rezultate (uporabili smo klasifikator k najbližjih sosedov ( $k$ -NN), klasifikator z linearno in kvadratično diskriminanto analizo (LDA, QDA), Naivni Bayes, odločitvena drevesa ter metodo podpornih vektorjev);
- pokazati, da so na področju od 1 Hz do 5 Hz prav tako zelo dobri rezultati klasifikacije in da je napoved na celem področju od 1 Hz - 5 Hz oziroma na ločenih področjih: 1 Hz - 2,2 Hz, 2,2 Hz - 3,5 Hz, 3,5 Hz - 5 Hz, boljša kot napoved na področju od 0,08 Hz do 1 Hz.



# Poglavje 2

## Metode

### 2.1 EMG - elektromiografija

Elektromiografija (EMG) je tehnika za merjenje in določanje električne aktivnosti, ki jo proizvajajo mišice. V raziskavah je bilo dokazano, da so te električne aktivnosti zelo povezane s materničnimi krči. Glede na to, da je aktivnost materničnih mišic veliko večja v času krčev, je bila večina študij osredotočenih na posnetke EMG na čas popadkov. Elektrohogram (EHG) je posnetek električne aktivnosti maternice. Za merjenje te aktivnosti elektrode nameščamo horizontalno ali vertikalno na razdalji 2.5 cm do 7 cm narazen. Zanimivo je, da te električne aktivnosti lahko zaznamo že zelo zgodaj, takrat, ko ženska še ni v pravem porodu, kar da dobro priložnost za analiziranje signalov in za napovedovanje že v zgodnjem obdobju, ali bo porod predčasen ali pravočasen. Moč aktivnosti narašča proti času poroda, posebej zadnje tri ali štiri dni pred porodom [2].

### 2.2 Podatkovna baza TPEHG DB

Pri magistrskem delu sem uporabila posnetke iz podatkovne baze TPEHG DB. Podatkovna baza vsebuje posnetke elektrohogramov, ki so bili posneti med leti 1997 - 2005 na Kliničnem centru v Ljubljani. Posnetki so bili posneti

okoli 22. tedna nosečnosti in okoli 32. tedna nosečnosti. V času te raziskave je bilo nabranih približno 1300 posnetkov.

Podatkovna baza TPEHG DB vsebuje 300 posnetkov [6, 7]:

- 262 pridobljenih posnetkov je bilo takih, pri katerih je bil porod pravočasen (čas nosečnosti  $> 37$  tednov)
  - 143 posnetkov je bilo posnetih pred 26. tednom nosečnosti (TE - Term Early)
  - 119 posnetkov je bilo posnetih v času ali po 26. tednu nosečnosti (TL - Term Late)
- 38 pridobljenih posnetkov je bilo takih, pri katerih je bil porod predčasen (čas nosečnosti  $< 37$  tedna)
  - 19 posnetkov je bilo posnetih pred 26. tednom nosečnosti (PE - Preterm Early)
  - 19 posnetkov je bilo posnetih v času ali po 26. tednu nosečnosti (PL - Preterm Late)


Pri izbiri posnetkov so bili odstranjeni posnetki, kjer je bil porod sprožen, in tisti posnetki, kjer je bil carski rez.

Vsak posnetek je dolg 30 minut in je sestavljen iz treh kanalov, ki so bili posneti s štirimi elektrodami. Elektrode so bile nameščene na način, kot je prikazan na sliki 2.1.

- **E1** Prva elektroda je bila nameščena 3,5 cm levo in 3,5 cm nad popkom.
- **E2** Druga elektroda je bila nameščena 3,5 cm desno in 3,5 cm nad popkom.
- **E3** Tretja elektroda je bila nameščena 3,5 cm desno in 3,5 cm pod popkom.
- **E4** Četrta elektroda je bila nameščena 3,5 cm levo in 3,5 cm pod popkom.

Razlike električnih potencialov, posnetih s 4 elektrodami, so tvorili 3 kanale.

- $S1 = E2 - E1$  (prvi kanal)
- $S2 = E2 - E3$  (drugi kanal)
- $S3 = E4 - E3$  (tretji kanal)



Slika 2.1: Prikaz postavitve elektrod

V prejšnjih raziskavah so ugotovili, da najboljši rezultat daje 3. kanal (horizontalni zgornji), najslabšega pa 2. kanal (vertikalni levi) [6]. V magistrskem delu bomo poskušali ugotoviti, ali to velja tudi pri nas.

Vsi posnetki so bili predhodno obdelani z analognim nizkoprepustnim filtrom z mejno frekvenco 5 Hz. Poleg originalnega signala imamo zapisano tudi vrednosti filtriranega signala na treh področjih:

- od 0,08 Hz do 4 Hz,
- od 0,3 Hz do 3 Hz,
- od 0,3 Hz do 4 Hz.

Signali so bili filtrirani z Butterworth-ovimi filtri 4. reda in dvakratno shemo filtriranja.

## 2.3 Predobdelava posnetkov

Preden lahko analiziramo in klasificiramo, je treba narediti predobdelavo signalov EHG za odstranjevanje šuma (pri posnetku imamo še druge električne aktivnosti, kot na primer delovanje srca), da izboljšamo kakovost rezultatov. Filtre uporabljamo zato, da izločimo določene frekvence iz signala [6, 16]. Tako smo uporabili štiripolni Butterworth-ov filter in dvakratno shemo filtriranja.

### 2.3.1 Butterworth-ov filter

Butterworth-ov filter je filter z neskončnim odzivom na enotin impulz in nelinearnim faznim zamikom. Ta filter računsko ni zahteven. Enačbi kvadriranih amplitudnih odzivov nizko in visoko prepustnega Butterworth-ovega filtra [8] sta naslednji:

$$|H(\Omega)|^2 = \frac{1}{1 + \left(\frac{\Omega}{\Omega_c}\right)^{2N}}, \quad (2.1)$$


$$|H(\Omega)|^2 = \frac{1}{1 + \left(\frac{\Omega_c}{\Omega}\right)^{2N}}, \quad (2.2)$$

kjer je  $\Omega$  frekvenca v časovno zveznem prostoru,  $\Omega_c$  je mejna frekvenca in  $N$  je red filtra. Amplitudni odziv nizko prepustnega Butterworth-ovega filtra je na sliki 2.2. Za implementacijo filtriranja z Butterworth-ovimi filtri smo uporabili funkcijo `butter` okolja MATLAB:

$$[b, a] = \text{butter}(\text{order}, [f1, f2])$$

kjer, je *order* red filtra, *f1* in *f2* sta mejni frekvenci pasovno prepustnega filtra, *b* in *a* pa sta vektorja koeficientov prenosne funkcije pripadajočega pasovno prepustnega filtra v časovno diskretnem prostoru:

$$H(z) = \frac{B(z)}{A(z)} = \frac{b(1) + b(2)z^{-1} + \dots + b(n+1)z^{-n}}{1 + a(2)z^{-1} + \dots + a(n+1)z^{-n}} \quad (2.3)$$



Slika 2.2: Amplitudni odziv nizko prepustnega Butterworth-ovega filtra

### 2.3.2 Dvakratno filtriranje

Velik problem pri filtriranju je fazni zamik, še posebej pri uporabi visokopasovnega filtra z nelinearnim faznim zamikom. Težavam se lahko izognemo na ta način, da celoten signal filtriramo dvakrat, filtriramo ga najprej v smeri naprej, obrnemo signal (zrcalimo po časovni osi) in nato ta signal še enkrat filtriramo. Tako dobljeni signal na koncu še enkrat obrnemo, oziroma ga zrcalimo po časovni osi. Na tak način dobimo dobro filtriran signal s faznim zamikom, ki je enak 0 [8, 13].

Opisano shemo filtriranja ponazorimo naslednje:

$$\begin{aligned}
 z_1(n) &= h(n) * x(n) \\
 z_2(n) &= h(n) * z_1(-n) \\
 s(n) &= z_2(-n)
 \end{aligned}
 \tag{2.4}$$

kjer je  $x(n)$  vhodni diskretni signal,  $h(n)$  je impulzni odziv filtra,  $*$  ponazarja konvolucijo v časovnem prostoru,  $z_1(n)$  je dobljeni signal po prvem filtriranju,  $z_2(n)$  je dobljeni signal po drugem filtriranju in  $s(n)$  je končni izhodni signal. Zapis 2.5 predstavlja formulo za diskretno časovno Fourierjevo transformacijo in Fourierjev par v primeru zrcaljenega časovno diskretnega signala:

$$\begin{aligned} X(e^{j\omega}) &= \sum_{n=-\infty}^{\infty} x(n)e^{-j\omega n} \\ x(-n) &\xleftrightarrow{F} X^*(e^{j\omega}) \end{aligned} \quad (2.5)$$

Izrazimo Fourierjevo transformacijo končnega izhodnega signala  $s(n)$ :

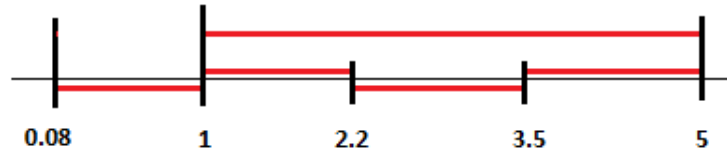
$$\begin{aligned} S(e^{j\omega}) &= Z_2^*(e^{j\omega}) \\ &= H^*(e^{j\omega}) \cdot Z_1(e^{j\omega}) \\ &= H^*(e^{j\omega}) H(e^{j\omega}) X(e^{j\omega}) \\ &= |H(e^{j\omega})|^2 \cdot X(e^{j\omega}) \end{aligned} \quad (2.6)$$

Rezultat kaže, da je učinek te sheme filtriranja kot, če bi vhodni signal filtrirali dva krat, oziroma je pripadajoči amplitudni odziv sheme filtriranja kar kvadrat amplitudnega odziva uporabljenega filtra, fazni zamik izhodnega signala po tako uporabljeni shemi filtriranja pa je enak 0.

### 2.3.3 Izbira frekvenčnih področij

Večina dosedanjih raziskav je osredotočenih na frekvenčno področje od 0,08 Hz do 1 Hz. Zanimivo področje se je nam zdelo od 1 Hz do 5 Hz. V magistrskem delu smo se še posebej osredotočili na to področje. V magistrskem delu smo prav tako pogledali, na katerih posameznih področjih znotraj tega področja lahko dobimo boljše rezultate z vzorčno entropijo in nato s klasifikacijo. Po predlogu mentorja smo področje od 1 Hz do 5 Hz razdelili na naslednje intervale (slika 2.3): 1 Hz- 2,2 Hz, 2,2 Hz - 3,5 Hz, 3,5 Hz - 5 Hz.





Slika 2.3: Prikaz izbire frekvenčnih področij

## 2.4 Vzorčna entropija

Vzorčna entropija je nelinearna tehnika za oceno kompleksnosti časovnih vrst. Ocenjuje stopnjo, do katere podatki ne prihajajo iz nekega naključnega procesa. S pomočjo vzorčne entropije želimo oceniti, koliko je signal napovedljiv. Manj napovedljiv signal ima višjo vzorčno entropijo [6, 10]. Dobra lastnost vzorčne entropije je, da je neodvisna od dolžine podatkov. Vzorčna entropija je negativen logaritem verjetnosti, ki pravi, da če se je znotraj časovne vrste že pojavilo dano podzaporedje te časovne vrste, dolžine  $m$ , potem se je pojavilo tudi podzaporedje te časovne vrste dolžine  $m - 1$  [11]. V dani časovni vrsti  $x(t)$  dolžine  $N$  imamo vzorce  $a_j(0, \dots, m - 1)$  dolžine  $m$ , pri čemer je  $m$  manjši od  $N$ . Vzorci  $a_j$  so vzeti kar iz časovne vrste  $x(t)$ ,  $a_j(i) = x(i + j)$ ,  $i = 0, \dots, m - 1$ ,  $j = 0, \dots, N - m$ .

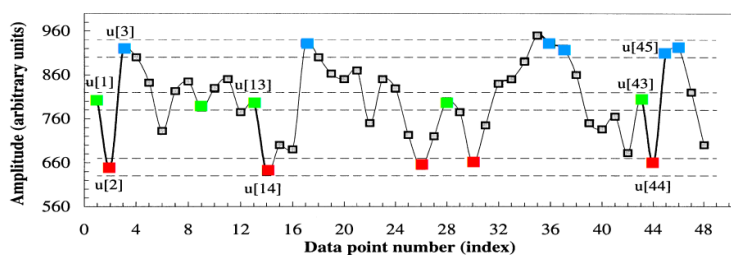
Del časovne vrste  $x(t)$  v času  $t = t_s$ ,  $x(t_s, \dots, t_{s+m-1})$  se smatra kot ujemanje za  $a_j$  takrat, ko velja naslednje:

$$|x(t_s + i) - a_j(i)| \leq r, \quad 0 \leq i < m \quad (2.7)$$

kjer je  $r$  prag odstopanja in tipično zavzame vrednosti med 10 % in 20 % razpona vrednosti amplitud vzorcev znotraj časovne vrste  $x(t)$ . Število ujemanj vzorcev  $c_m$  računamo za vsak  $m$ . Vzorčna entropija,  $sampEn$ , je definirana

kot [6] :

$$\begin{aligned} \text{samp}En_{m,r}(x) = & \\ & -\log(c_m/c_{(m-1)}) : c_m \neq 0 \wedge c_{m-1} \neq 0 \\ & -\log((N-m)/(N-m-1)) : c_m = 0 \vee c_{m-1} = 0 \end{aligned} \quad (2.8)$$

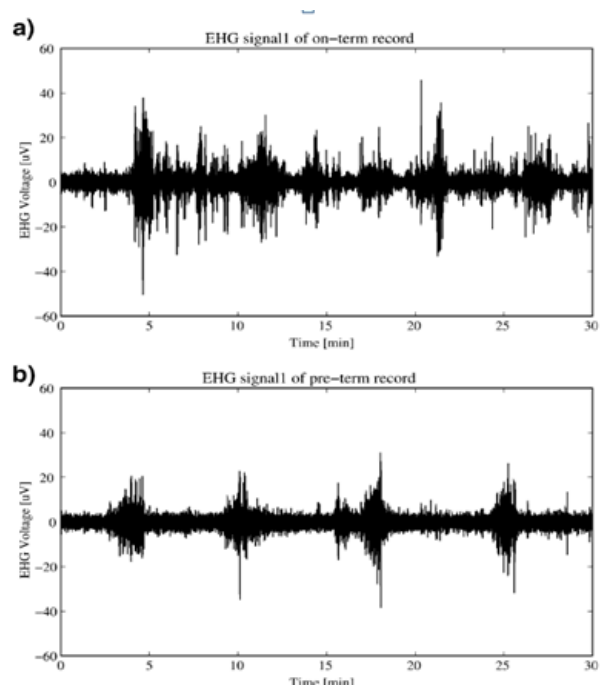


Slika 2.4: Delovanje vzorčne entropije

Slika 2.4 nam prikazuje potek dela izračuna vzorčne entropije. Prekinjene horizontalne linije okrog  $u[1]$ ,  $u[2]$  in  $u[3]$  predstavljajo  $u[1] \pm r$ ,  $u[2] \pm r$ ,  $u[3] \pm r$  [9].

Na sliki 2.5 pri zgornjem posnetku (s terminskim porodom) lahko vidimo, da je verjetno prisoten več kot le en fiziološki mehanizem; pri spodnjem posnetku (s prezgodnjim porodom) vidimo, da je verjetno prisoten en sam fiziološki mehanizem. Pri prezgodnjem porodu imamo signal, ki je bolj regularen ali napovedljiv, torej imamo opravka z nižjo vrednostjo vzorčne entropije.

V delu [6] se je vzorčna entropija pokazala kot obetavna tehnika, zato smo jo tudi uporabili pri svojem magistrskem delu. Ima pa ta tehnika tudi svoje slabosti, ker je zelo odvisna od parametrov  $m$  in  $r$ . Tako, kot so to ugotovili v delu [6], če je dolžna  $m$  prevelika ali  $r$  premajhen, potem v nekaterih časovnih vrstah signala sploh ne dobimo nobenega ujemanja. Zato smo se tudi pri svojem delu omejili na vrednosti  $m = 3$  in  $r = 0,15$ , ki sta pokazali dovolj dobre rezultate in sta predlagani v [6].



Slika 2.5: Signal za termiski ter prezgodnji porod

## 2.5 Definicija problema

V magistrski nalogi sem se osredotočila na problem ločevanja štirih skupin posnetkov, med katerimi smo želeli dobiti čim boljše rezultate klasifikacije. Skupine posnetkov so:

- (a) Terminski porodi, snemani zgodaj (okrog 23. tedna nosečnosti), TE (Term Early);
- (b) Terminski porodi, snemani pozno (okrog 32. tedna nosečnosti), TL (Term Late);
- (c) Prezgodnji porodi, snemani zgodaj (okrog 23. tedna nosečnosti), PE (Preterm Early);
- (d) Prezgodnji porodi, snemani pozno (okrog 32. tedna nosečnosti), PL (Preterm Late).

Na podlagi teh skupin smo definirali naslednje podprobleme:

1. Podproblem: PE - TE

Klasifikacija prezgodnjih ali terminskih porodov pri posnetkih, ki so bili zajeti zgodaj. V skupini PE smo imeli 19 posnetkov, v skupini TE pa 143 posnetkov. Po uporabi prevzorčevanja minoritetne množice (metoda SMOTE) je bilo v vsaki skupini 143 posnetkov.

2. Podproblem: PL - TL

Klasifikacija prezgodnjih ali terminskih porodov pri posnetkih, ki so bili zajeti pozno. V skupini PL imeli smo 19 posnetkov, v skupini TL pa 119 posnetkov. Po uporabi prevzorčevanja minoritetne množice (metoda SMOTE) je bilo v vsaki skupini 119 posnetkov.

3. Podproblem: PE - PL

Klasifikacija zgodnjih ali poznih posnetkov pri posnetkih prezgodnjih porodov. V vsaki skupini je bilo 19 posnetkov.

## 2.6. SINTETIČNO PREVZORČEVANJE MINORITETNE MNOŽICE (SMOTE)

	0.08 Hz - 1 Hz			1 Hz - 2.2 Hz			2.2 Hz - 3.5 Hz			3.5 Hz - 5 Hz			1 Hz - 5 Hz		
	kanal 1	kanal 2	kanal 3	kanal 1	kanal 2	kanal 3	kanal 1	kanal 2	kanal 3	kanal 1	kanal 2	kanal 3	kanal 1	kanal 2	kanal 3
posnetek 1	0.256377	0.234477	0.229483	0.576387	0.539084	0.741006	0.800755	0.870218	0.973427	0.916856	1.209392	0.878030	1.319893	1.329771	1.322280
posnetek 2	0.281077	0.291168	0.280403	0.719541	0.524546	0.652623	0.674620	0.906553	1.076054	1.060031	1.622903	0.956385	1.160534	1.547656	1.455022
.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.
.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.
.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.
posnetek 144	0.163776	0.207837	0.146868	0.527350	0.510465	0.495012	0.932274	1.004969	0.756693	0.828140	0.886747	1.317085	1.306895	1.255688	1.352548
posnetek 145	0.335843	0.299607	0.302548	0.401094	0.542270	0.584693	0.771662	1.593982	0.886472	0.714137	0.865449	1.803498	0.971908	1.271888	1.276195
.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.
.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.
posnetek 286	0.277190	0.274490	0.276027	0.720725	0.688516	0.653263	0.941611	0.802252	1.103821	1.766635	1.733555	0.964219	0.968875	1.190979	1.352579

Tabela 2.1: Primer za vhodne podatke za klasifikacijo PE - TE

### 4. Podproblem: TE - TL

Klasifikacija zgodnjih in poznih posnetkov pri posnetkih terminskih porodov. V skupini TE imeli smo 143 posnetkov, v skupini TL pa 119 posnetkov. Po uporabi prevzorčevanja minoritetne množice (metoda SMOTE) je bilo v vsaki skupini 143 posnetkov.

Vsak posnetek predstavlja po enega pacienta in vsebuje tri signale ter dodatne klinične informacije o nosečnici, ki pa niso bile upoštevane pri klasifikaciji. V tabeli 2.1 so prikazani vhodni podatki za klasifikatorje podproblema 1 (klasifikacija prezgodnjih in terminskih porodov snemanih zgodaj, problem PE - TE). Prvih 143 vrstic predstavlja vrednosti vzorčnih entropij za 143 posnetkov množice PE za vsako frekvenčno področje in za vsak kanal. Naslednjih 143 vrstic (od 144 do 286) pa predstavlja vrednosti vzorčnih entropij za 143 posnetkov množice TE za vsako frekvenčno področje in za vsak kanal. Vsak posnetek ima tri signale in je bil filtriran na petih frekvenčnih področjih. En stolpec torej predstavlja vhodni vektor za klasifikatorje pri obravnavi podproblema PE - TE za izbrano frekvenčno področje in za izbrani signal.

## 2.6 Sintetično prevzorčevanje minoritetne množice (SMOTE)

Večina standardnih tehnik strojnega učenja pričakuje uravnoteženo množico glede na razred. Pri dveh uravnoteženih množicah podatkov bo verjetnost napovedi za vsak razred enaka. Pri podatkovni bazi TPEHG DB je situacija

drugačna [12]. Glede na to, da imamo za terminski porod, ki je bil zajet pred 26. tednom, 143 posnetkov, za porod, ki je bil predčasen, in prav tako zajet pred 26. tednom, pa imamo samo 19 posnetkov, je velika verjetnost, da bodo pri klasifikaciji rezultati bolj naklonjeni k tisti množici, ki ima več primerov svojega razreda.

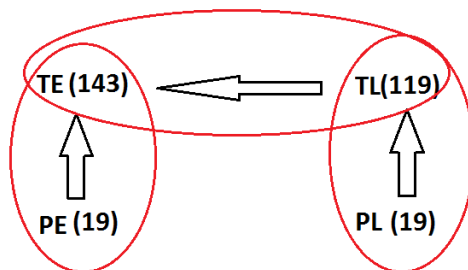
Klasifikatorji so bolj občutljivi na detektiranje večinskih razredov in manj občutljivi na razrede z manjšo količino podatkov. To lahko privede k pristranski klasifikaciji. Tako kot je navedeno v [2], če iz podatkovne baze vzamemo množico, bo verjetnost, da bodo klasifikatorji klasificirali porod kot terminskega, veliko višja (87,3 % - 262/300) kot verjetnost, da bo porod predčasen (12,6 % - 38/300). Zaradi teh težav so nastale različne tehnike, kako množico ponovno prevzorčimo. Tehnike vključujejo tako povečevanje manjšinskega razreda kot tudi pomanjševanje večinskega razreda. Pri izbiranju zmanjšamo število posnetkov iz večinskega razreda, da je enako manjšinskemu razredu. Pri dodajanju pa povečamo število vrednosti za manjšinski razred do velikosti večinskega razreda [2].

Pri magistrskem delu smo uporabili tehniko sintetičnega prevzorčevanja minoritetne množice (SMOTE). SMOTE je učinkovita metoda, ki pridobi uravnoteženo učno množico tako, da generira sintetične enote iz manjšega razreda in pri tem temelji na podobnosti med obstoječimi primeri manjšinskega razreda. Z uporabo metode  $k$  najbližjih sosedov ( $k$ -NN) najprej naključno izberemo enega izmed  $k$  najbližjih sosedov in tako povečamo pripadajoči vektor lastnosti ter ga pomnožimo z naključnim številom na intervalu 0 in 1 [12].

Pri magistrskem delu smo uporabili SMOTE v primeru PE - TE, TE - TL in PL - TL. Glej sliko 2.6.

## 2.7 Analiza variance (ANOVA)

Analiza variance (ANOVA) [14] je posplošeno ime za metodo, ki primerja povprečje večjega števila vzorcev. Ukvarja se z ugotovitvijo, ali vzorci spa-



Slika 2.6: uporaba SMOTE na skupinah

dajo v eno populacijo ali v različne populacije glede na ocenjene vrednosti cenilk. Običajno testiramo ničelno hipotezo, da so vsi vzorci vzeti iz iste populacije oz., da so vse srednje vrednosti vseh populacij med sabo enake [14, 15]. Če se srednje vrednosti med sabo razlikujejo, potem zavrnemo to hipotezo. ANOVA temelji na naslednjih predpostavkah [14]:

- vse metrike so normalno porazdeljene;
- variance v vzorcih so homogene;
- vzorci so izbrani naključno.

Pri magistrskem delu smo uporabili enosmerno varianco ANOVA, ki primerja aritmetični sredini vzorčnih sredin in pove, ali se skupini med sabo statistično razlikujeta. Uporabili smo metodo iz knjižnice MATLAB:

$$p = \text{anova1}(X, \text{group}, \text{'displayopt'})$$

Funkcija nam vrne vrednost  $p$  za ničelno hipotezo, tako da so vsi vzorci v  $X$  sestavljeni iz iste populacije. Če je ta vrednost bolj blizu vrednosti 0, to pomeni, da je ničelna hipoteza pod vprašajem in da obstaja vsaj en vzorec, ki se močno razlikuje od drugih vzorcev. Če je vrednost  $p$  manjša od 0,05, to pomeni, da se vzorci razlikujejo med sabo [14, 15].

## 2.8 Klasifikatorji

Eden najpogostejših postopkov strojnega učenja je klasifikacija. Naloga klasifikatorja za objekt, opisan z množico atributov, je določiti, kateremu izmed možnih razredov pripada. Atributi so lahko zvezne ali diskretne spremenljivke, s katerimi opisujemo objekte, razred pa je odvisna diskretna spremenljivka, ki ji določimo vrednost glede na vrednosti neodvisnih spremenljivk [16]. Zato, da lahko klasifikator določi razred, mora imeti na neki način predstavljeno diskretno funkcijo, ki preslika prostor atributov v razred. Ta funkcija je lahko podana vnaprej ali naučena, tako kot v našem primeru. Torej, naloga učnega algoritma je iz množice vzorcev z znanimi razredi zgraditi pravilo, ki ga lahko uporabimo za določevanje razredov v prihodnosti [16]. Cilj našega magistrskega dela je čim boljša napovedljivost prezgodnjega poroda, posebej v zgodaj zajetih posnetkih.

Klasifikatorji, ki sem jih uporabila so tipični klasifikatorji, kot so jih uporabili v sorodnih raziskavah [2] in to so: odločitveno drevo, naivni Bayesov klasifikator, klasifikator z najbližjimi sosedi, metoda podpornih vektorjev (SVM - support vector machine), klasifikator z linearno diskriminantno analizo (LDA) in klasifikator s kvadratično diskriminantno analizo (QDA). Uporabili smo že obstoječe funkcije orodja MATLAB. Pričakujemo, da bodo najboljše rezultati pri odločitvenih drevesih, in sicer glede na rezultate pri drugih sorodnih raziskavah.

### 2.8.1 Klasifikator z najbližjimi sosedi ( $k$ -NN)

Najpreprostejša različica algoritma najbližjih sosedov ( $k$ -NN) kot znanje uporablja kar množico vseh učnih primerov (učni algoritem si samo zapomni vse primere)[16]. Ko želimo napovedati razred  $r_x$ , novemu primeru  $u_x$  poiščemo med učnimi primeri  $k$  najbližjih  $u_1, \dots, u_k$  in pri klasifikaciji napovemo večinski razred, ki mu pripada največ izmed  $k$  najbližjih sosedov:

$$r_x = \operatorname{argmax}_{r \in \{V_1 \dots V_{n_0}\}} \sum_{i=1}^k \delta(r, r^{(i)}) \quad (2.9)$$



Ker učenja pri teh metodah skoraj ni, pravimo tej vrsti učenja tudi leno učenje.

Glavnina procesiranja je potrebna pri klasifikaciji novega primera in je zato časovna zahtevnost klasifikacije novega primera precej večja kot pri drugih metodah učenja. Pri tem je treba zaradi ustrezne metrike v prostoru atributov normalizirati vrednosti zveznih atributov in definirati razdaljo med vrednostmi vsakega diskretnega atributa [16]. Najboljša izbira  $k$  je odvisna od podatkov. Običajno večja vrednost  $k$  zmanjša vpliv šuma, vendar po drugi strani z večanjem števila  $k$  povečujemo možnost, da h klasifikaciji prispevajo tudi tisti učni primeri, ki niso dovolj podobni novemu primeru. Algoritem  $k$ -NN je občutljiv na izbrano metriko pri računanju razdalj med novimi primeri in učnimi primeri. Po navadi se uporablja evklidska razdalja [16]. Velja poudariti, da parameter  $k$  ne določa velikosti okolice novega primera, znotraj katere izbiramo učne primere, ampak se okolica dinamično spreminja v odvisnosti od gostote učnih primerov. S fiksno velikostjo okolice novega primera bi v nekaterih delih prostora lahko dobili preveč bližjih sosedov, v drugem delu pa nobenega [16]. V klasifikacijah, kjer imamo samo dva razreda, tako v našem magistrskem delu, je pametno izbrati  $k$  liho število.

## 2.8.2 Naivni Bayesov klasifikator

Naivni Bayesov klasifikator predvideva pogojno neodvisnost vrednosti različnih atributov pri danem razredu [16]. Če ima vsak primer v učni množici lastnosti  $r_{i...k}$  in pripada enemu iz množice med seboj tujih razredov, lahko za vse razrede izračunamo verjetnosti, da pripadajo danim razredom. Osnovna formula je:

$$P(r_k|V) = P(r_k) \prod_{i=1}^a \frac{P(r_k|v_i)}{P(r_k)} \quad (2.10)$$

Naloga učnega algoritma je s pomočjo učne množice podatkov aproksimirati apriorne verjetnosti razredov  $P(r_k)$ ,  $k = 1...n_0$  in pogojne verjetnosti razredov  $r_k$ ,  $k = 1...n_0$  pri dani vrednosti  $v_i$  atributa  $A_i$ ,  $i = 1...a$  :  $P(r_k|v_i)$  [16]. Za

ocenjevanje apriornih verjetnosti se uporablja Laplaceov zakon zaporednosti:

$$P(r_k) = \frac{N_k + 1}{N + n_0} \quad (2.11)$$

kjer je  $N_k$  število učnih primerov iz razreda  $r_k$  in  $N$  število vseh učnih primerov. Za ocenjevanje pogojnih verjetnosti se uporablja m-ocena:

$$P(r_k|v_i) = \frac{N_{k,i} + mP(r_k)}{N_i + m} \quad (2.12)$$

kjer je  $N_{k,i}$  število učnih primerov iz razreda  $r_k$  in z vrednostjo  $i$ -tega atributa  $v_i$  ter  $N_i$  število vseh učnih primerov z vrednostjo  $i$ -tega atributa  $v_i$ .

Naivni Bayesov klasifikator pri klasifikaciji uporabi vse attribute, katerih vrednosti so podane za dani primer, ki ga klasificiramo. Attribute, za katere vrednosti za naš primer niso podane, običajno ignoriramo. Ocenjevanje verjetnosti je relativno zanesljivo [16].

### 2.8.3 Klasifikator z linearno diskriminantno analizo - LDA

Je posplošitev Fisherjeve linearne diskriminante. Ta metoda je enostavna in daje dobre rezultate kot kompleksnejše metode klasifikacije. Metoda se uporablja v strojnem učenju za iskanje linearne kombinacije lastnosti, ki bi lahko ločila dva ali več razredov [17]. LDA je najbolj blizu analizi varianci ANOVA. Linearne funkcije imajo obliko :

$$G(V) = w_1v_1 + w_2v_2 + \dots + w_av_a + w_{a+1} \quad (2.13)$$

kjer je  $w_1 \dots w_{a+1}$  predstavljajo uteži.  $V = v_1, \dots, v_a$  je vektor vrednosti vseh atributov  $A_1, \dots, A_a$ . Linearne diskriminantne funkciji definirajo mejne hiperravnine:

$$G_{ij}(V) = g_i(V) - g_j(V) = 0 \quad (2.14)$$

$$(w_{i,1} - w_{j,1})v_1 + \dots + (w_{i,a} - w_{j,a})v_a + (w_{i,a+1} - w_{j,a+1})v_{j,a+1} = 0 \quad (2.15)$$

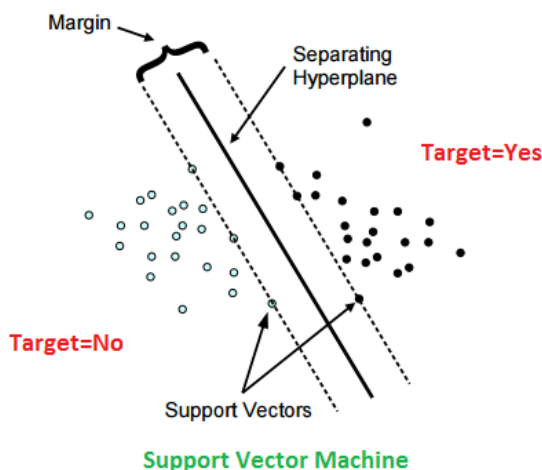
Če obstaja konsistentna množica mejnih hiperravnin med razredi, pravimo, da so razredi linearno ločljivi. Naloga učnega algoritma je v tem,

da mora za vsak razred določiti vektor uteži. Linearna Fisherjeva funkcija predpostavlja, da je porazdelitev znotraj razreda je normalna in zato maksimira razdaljo med povprečnim učnim primerom enega razreda in povprečnim učnim primerom drugega razreda [16].

#### 2.8.4 Klasifikator s kvadratično diskriminantno analizo - QDA

Uporablja se pri strojnem učenju za ločevanje dveh ali več razredov s pomočjo ploskve drugega reda. Ploskev drugega reda je poljubna  $n$ -razsežna hiperploskev v  $n-1$  prostoru, ki je geometrijsko mesto ničel kvadratnega polinoma. V primerjavi z linearno diskriminantno analizo, kvadratična analiza ne predvideva, da so kovariance vsakega razreda enake [18].

#### 2.8.5 Metoda podpornih vektorjev - SVM



Slika 2.7: Metoda podpornih vektorjev

SVM nam predstavlja metodo klasifikacije z iskanjem hiperravnine, ki ločuje predmete iz različnih razredov. SVM razdeli množico tako, da je pro-

stor med razredi čim širši. To široko prazno območje nam omogoča, da čim bolj zanesljivo uvrščamo tudi predmete, ki niso povsem enaki učnim primerom. Vsak predmet predstavimo kot vektor v hiperravnini. Podporni vektorji pa so tisti učni primeri, ki so najbližje hiperravnini in določijo rob okoli hiperravnine, glej sliko 2.7. SVM poišče dve najbližji točki dveh razredov, ki podpirajo najboljšo razdelitev ravnine [19].

### 2.8.6 Odločitveno drevo

Pri algoritmu odločitvenih dreves algoritem razbije množico podatkov na manjše in podobne podmnožice. Končni rezultat odločitvenih dreves so odločitvena vozlišča in končno vozlišče. Odločitveno drevo je sestavljeno iz notranjih vozlišč, vej in končnih vozlišč, ki predstavljajo razred. Ena pot od korenkega vozlišča do končnega vozlišča nam predstavlja eno odločitveno pravilo. Ključnega pomena pri algoritmu je izbira najboljšega atributa. Zgrajeno drevo lahko uporabimo za klasifikacijo novega učnega primera. Od korena potujemo proti končnemu vozlišču po ustreznih vejah. Končno vozlišče vsebuje informacijo o končnem številu učnih primerov iz posameznih razredov. Število vseh učnih primerov v končnem vozlišču predstavlja pomemben podatek za oceno zanesljivosti porazdelitve [16].

## 2.9 Metrike zmogljivosti klasifikatorjev

Pri magistrskem delu smo se osredotočili na klasifikacijo posnetkov v dva razreda, razred, kjer je prišlo do prezgodnjega poroda, in razred, kjer je bil porod terminski. Klasificirali smo med posnetki, ki so bili posneti zgodaj v nosečnosti in pozno v nosečnosti. Za našo magistrsko nalogo so najpomembnejši rezultati klasifikacij za posnetke s terminskim in prezgodnjim porodom, ki so bili posneti zgodaj.

Za ocenjevanje klasifikatorjev smo uporabili matriko zmogljivosti, s pomočjo katere smo izračunali klasifikacijsko točnost, specifičnost in občutljivost. Pri tej matriki velja, da je dogodek, ki ga napovedujemo, pozitiven, drugi pa

je negativen [20]. V našem primeru je bil pri klasifikaciji pozitiven dogodek prezgodnji porod, negativen dogodek pa je bil porod ob roku. V vsaki celici imamo zapisano za vsak dogodek, kam ga je uvrstil klasifikator, v pravi razred ali v napačen razred (glej sliko 2.8) [16, 20].

		klasifikator	
		Pozitiven	Negativen
referenca	Pozitiven	TP	FN
	Negativen	FP	TN

Slika 2.8: Matrika zmogljivosti

Tako imamo naslednje možnosti:

- *TP* (angl. true positive) število pravilno klasificiranih pozitivnih dogodkov v pozitivni razred;
- *FN* (angl. false negative) število napačno klasificiranih pozitivnih dogodkov v negativni razred;
- *TN* (angl. true negative) število pravilno klasificiranih negativnih dogodkov v negativni razred;
- *FP* (angl. false positive) število napačno klasificiranih negativnih dogodkov v pozitivni razred.

S pomočjo te matrike lahko izračunamo naslednje metrike zmogljivosti [16]:

- *Klasifikacijska točnost*

Rešitev vsakega primera klasifikacije je enolično določen razred. Uspešnost klasificiranja ocenjujemo s klasifikacijsko točnostjo. Enačba za klasifikacijsko točnost je

$$CA = \frac{TP + TN}{TP + TN + FP + FN} \quad (2.16)$$

Klasifikacijska točnost nam pove delež pravilno napovedanih dogodkov med vsemi dogodki.

- *Specifičnost*

Specifičnost nam pove odstotek pravilno klasificiranih negativnih dogodkov. V našem primeru je to odstotek vseh pravilno uvrščenih pravočasnih porodov. Enačba za specifičnost je

$$Sp = \frac{TN}{TN + FP} \quad (2.17)$$

- *Občutljivost*

Občutljivost nam pove odstotek pravilno klasificiranih pozitivnih dogodkov. V našem primeru je to odstotek vseh pravilno uvrščenih prezgodnjih porodov. Enačba za občutljivost je

$$Se = \frac{TP}{TP + FN} \quad (2.18)$$

### 2.9.1 Načini sestavljanja učne in testne množice

1. *Ocena delovanja po principu učna množica*

Takrat, ko ne moremo preveriti, kako deluje naš klasifikator na neznanih primerih, ga lahko uporabimo kar na podatkih, iz katerih se je učil. Na tak način bodo rezultati boljši, kot če bi ga uporabili na neznanih, kar smo tudi ugotovili pri rezultatih magistrskega dela. V tem primeru imamo testno in učno množico, ki sta med seboj enaki. Problem je v tem, da nam ne da ocene, kako dobro je klasifikator narejen in kako dobro bo klasificiral na neznanih primerih [21].

2. *Ocena delovanja po principu učno - testna množica (angl. holdout method)*

To je najenostavnejša metoda. Našo množico primerov razdelimo naključno v dve skupini, tj. učna in testna množica. Klasifikator

uporabimo za učenje na znanih primerih učne množice. Testno množico pa uporabimo za ocenjevanje, kako dober je naš klasifikator na neznanih primerih. Slabost te metode je v tem, da je ocenjevanje odvisno od tega, kako dobro smo razdelili množico primerov v učno ter testno množico. Pri nas smo uporabili 20% holdout [21].

3. *Ocena delovanja po principu križna validacija (angl. k-fold cross validation)*

Je izboljšana različica učno-testne množice. Množico primerov razdelimo v  $k$  podmnožic in nato ponovimo metodo učno-testne množice  $k$  krat. Pri tem vsakič eno od  $k$  podmnožic uporabimo kot testno množico in druge  $k - 1$  uporabimo kot učno množico. Prednost te metode je v tem, da je manj odvisna od tega, kako se množica primerov razdeli, ker bo vsak primer enkrat v testni in  $k - 1$  krat v učni množici. Slabost te metode je v časovni zahtevnosti, ker mora algoritem ponoviti  $k$ -krat metodo učno-testne množice. V magistrskem delu smo uporabili  $k = 5$  z eno ponovitvijo [21].

4. *Ocena delovanja po principu izpusti enega (angl. leave-one-out)*

Tukaj gre validacija v ekstrem. V tem primeru je  $k$  enak številu primerov  $N$ . To pomeni, da razdelimo množico  $N$ -krat. Klasifikator se uči na vseh primerih razen enega. Ta metoda je uporabna, ko nimamo dovolj primerov, ker na tak način klasifikatorju ponudimo dovolj veliko učno množico, na kateri se lahko nauči [21].





## Poglavje 3

### Rezultati

Pri magistrskem delu smo dobili zanimive rezultate in opazili zanimivo lastnost obnašanja entropije glede na to, na katerih frekvencah smo izvajali filtriranje, in na kako širokem frekvenčnem pasu.

Nato smo izvedli analizo variance ANOVA, da bi lahko primerjali, kakšni so rezultati ocenjevanja variance med posnetki, ki so bili zajeti zgodaj in je porod bil prezgodnji ter terminski (PE - TE). Nato smo tudi pogledali, kakšne rezultate dobimo pri ANOVI za posnetke, ki so bili zajeti pozno ter je porod ponovno bil predčasen in terminski (PL - TL).

Klasifikacijo smo izvedli na množicah posnetkov. Najprej smo želeli videti, kakšne rezultate dobimo, pri uvrstitvi posnetka med predčasnim in terminskim porodom. Najprej smo to izvedli na posnetkih, ki so bili zajeti zgodaj pred 26. tednom. Nato smo poskušali še na posnetkih, ki so bili zajeti kasneje po 26. tednu.

Na posnetkih, kjer je bil porod prezgodnji, smo poskušali ugotoviti tudi, ali je bil posnetek zajet zgodaj ali pozno v nosečnosti. Testirali smo vse tri kanale, da bi lahko videli, ali se razlikujejo od prejšnjih raziskav, pri čemer se je 3. kanal izkazal za najboljšega.

### 3.1 Rezultati analize variance (ANOVA)

V tabelah so krepko označeni tisti rezultati, katerih vrednost je  $p \leq 0.01$ .

#### 3.1.1 Posnetki, kjer je bil porod prezgodnji ali ob roku. Posnetki so bili zajeti zgodaj.

PE - TE	p-vrednost		
	1. kanal	2. kanal	3. kanal
0.08 Hz - 1 Hz	0.040116	0.733686	<b>0.000129</b>
1 Hz - 2,2 Hz	0.877494	0.877494	0.036882
2,2 Hz - 3,5 Hz	0.070616	0.566990	<b>0.010583</b>
3,5 Hz - 5 Hz	<b>0.000002</b>	0.032027	<b>0.006175</b>
1 Hz - 5 Hz	0.060828	<b>0.000011</b>	<b>0.000001</b>

Tabela 3.1: ANOVA PE - TE

Glede na rezultate, ki jih lahko vidimo v zgornji tabeli 3.1, lahko opazimo, da je najnižja p-vrednost pri 3. kanalu. Najslabši rezultati so pri 2. kanalu, kar nam lahko pove, da če želimo razlikovati med prezgodnjim posnetkom, ki je bil zajet zgodaj ter terminskim posnetkom, ki je bil zajet zgodaj, potem velja, da se na tretjem kanalu terminski in prezgodnji posnetki med sabo močno razlikujejo. Najslabši rezultat (oz. največja vrednost  $p$ ) je na frekvenčnem področju od 1 Hz do 2,2 Hz.

#### 3.1.2 Posnetki, kjer je bil porod prezgoden ali ob roku. Posnetki so bili zajeti pozno.

Glede na rezultate, ki jih lahko vidimo v spodnji tabeli 3.2, vidimo, da imajo rezultati p-vrednosti na posnetkih, ki so bili zajeti kasneje, najmanjše vrednosti p-ja na 1. kanalu. Kar pomeni, da če se porod približuje, lahko tudi boljše ločimo posnetke in vrednosti, ki so v 1. kanalu. Vidimo lahko tudi,

PL - TL	p-vrednost		
	1. kanal	2. kanal	3. kanal
0,08 Hz - 1 Hz	<b>0.004593</b>	0.239222	<b>0.000362</b>
1 Hz - 2,2 Hz	<b>0.012880</b>	0.462613	0.684962
2,2 Hz - 3,5 Hz	<b>0.001294</b>	0.176315	0.191566
3,5 Hz - 5 Hz	0.043392	0.984868	0.200245
1 Hz - 5 Hz	<b>0.003336</b>	<b>0.008442</b>	0.246094

Tabela 3.2: ANOVA PL - TL

da je na področju 1 Hz - 5 Hz manjša vrednost kot na posameznih krajših področjih.

### 3.1.3 Posnetki, kjer je bil porod ob roku. Posnetki so bili zajeti zgodaj ali pozno.

TE - TL	p-vrednost		
	1. kanal	2. kanal	3. kanal
0,08 Hz - 1 Hz	<b>0.001203</b>	<b>0.000000</b>	<b>0.002652</b>
1 Hz - 2,2 Hz	0.982129	<b>0.000063</b>	0.165175
2,2 Hz - 3,5 Hz	<b>0.007822</b>	0.154531	0.060305
3,5 Hz - 5 Hz	<b>0.006750</b>	<b>0.001443</b>	0.770377
1 Hz - 5 Hz	<b>0.000518</b>	<b>0.007598</b>	0.567120

Tabela 3.3: ANOVA TE - TL

V zgornji tabeli 3.3 vidimo, da smo na posnetkih, ki so bili terminski, poskusili pogledati, kako se razlikujejo glede na to, ali so bili posnetki zajeti zgodaj ali pozno. Pokazalo se je, da vrednost p-ja daje najboljše rezultate na 2. kanalu.

### 3.1.4 Posnetki, kjer je bil porod prezgoden. Posnetki so bili zajeti zgodaj ali pozno.

PE - PL	p-vrednost		
	1. kanal	2. kanal	3. kanal
0,08 Hz - 1 Hz	0.266594	0.047611	0.345196
1 Hz - 2,2 Hz	0.119436	0.188808	0.522129
2,2 Hz - 3,5 Hz	0.123222	0.172837	0.575905
3,5 Hz - 5 Hz	0.833058	0.887908	0.920845
1 Hz - 5 Hz	0.066844	<b>0.000209</b>	0.541895

Tabela 3.4: ANOVA PE - PL

V zgornji tabeli 3.4 lahko vidimo, da se vrednosti zelo malo razlikujejo med sabo razen pri drugem kanalu na področju od 1 Hz - 5 Hz. Razlog za to je zelo majhna količina podatkov, samo 38 posnetkov.

## 3.2 Rezultati vrednosti vzorčne entropije v odvisnosti od tedna posnetka

V magistrskem delu smo želeli tudi ugotoviti, kakšne rezultate vzorčne entropije dobimo v odvisnosti od tedna posnetka. Na grafih so srednje vrednosti s posnetkov, kjer smo uporabili SMOTE in srednje vrednosti brez metode SMOTE.

### 3.2.1 3. kanal

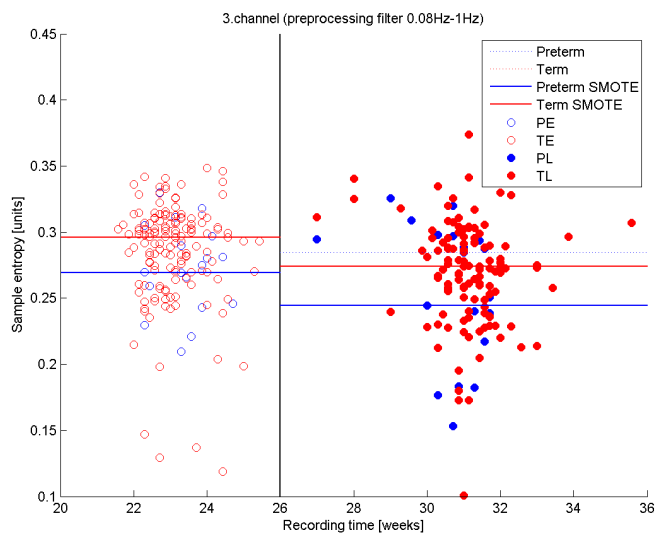
Slike od 3.1 do 3.5 prikazujejo vrednosti vzorčne entropije za 3. kanal. Lahko opazimo zanimivo obnašanje srednjih vrednosti vzorčnih entropij:

- Vzorčna entropija posnetkov s prezgodnjim porodom ob uporabi spodnjega frekvenčnega območja 0.08 Hz-1 Hz je višja od vzorčne entropije

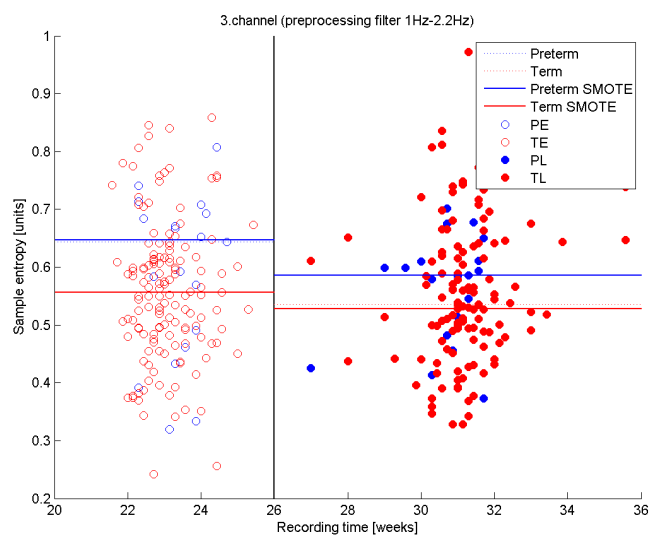
posnetkov s terminskim porodom. Zaključimo lahko, da so na tem frekvenčnem področju posnetki s prezgodnjim porodom bolj napovedljivi in kažejo večjo regularnost kot posnetki s terminskim porodom.

- Za posnetke, ki so bili filtrirani na frekvenčnem področju, ki je višje kot 1 Hz, velja naslednje: široko področje npr. 1 Hz - 5 Hz ima višjo vzorčno entropijo kot ožja frekvenčna območja. Iz tega lahko sledi nižja napovedljivost oz. je signal manj regularen. Drugi sklep pa je, da višje, ko je frekvenčno področje nad 1 Hz (1 Hz - 2,2 Hz, 2,2 Hz-3,5 Hz, 3,5 Hz-5 Hz), večja je tudi vrednost vzorčne entropije.
- Za posamezna frekvenčna področja, kjer je začetna frekvenca več od 1 Hz, velja, da se vrednosti vzorčne entropije za posnetke s prezgodnjim in terminskim porodom zamenjajo, vzorčna entropija posnetkov s prezgodnjim porodom postane višja od vzorčne entropije posnetkov s terminskim porodom, kar pomeni, da posnetki s prezgodnjim porodom, na višjih frekvencah filtriranja postanejo manj regularni, bolj kaotični in manj napovedljivi, posnetki s terminskim porodom pa ravno obratno - postanejo bolj predvidljivi in bolj regularni.


V spodnji sliki 3.1 imamo enaki srednji vrednosti z uporabo SMOTE in brez uporabe SMOTE za posnetke TE in TL.




Slika 3.1: 3. kanal, 0,08 Hz - 1 Hz




Slika 3.2: 3. kanal, 1 Hz - 2,2 Hz



Slika 3.3: 3. kanal, 2,2 Hz - 3,5 Hz



Slika 3.4: 3. kanal, 3,5 Hz - 5 Hz




Slika 3.5: 3. kanal, 1 Hz - 5 Hz


### 3.2.2 1. in 2. kanal

Pri prvem in drugem kanalu veljajo iste ugotovitve kot pri 3. kanalu. Slike 3.6 do 3.10 (kanal 1) in slike 3.11 do 3.15 (kanal 2) prikazujejo vrednosti vzorčnih entropij za kanal 1 in kanal 2.







Slika 3.6: 1. kanal, 0,08 Hz - 1 Hz




Slika 3.7: 1. kanal, 1 Hz - 2,2 Hz




Slika 3.8: 1. kanal, 2,2 Hz - 3,5 Hz



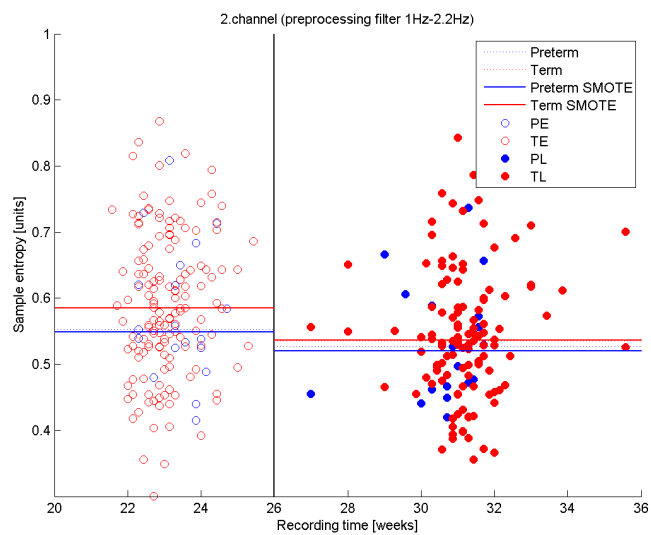
Slika 3.9: 1. kanal, 3,5 Hz - 5 Hz




Slika 3.10: 1. kanal, 1 Hz - 5 Hz



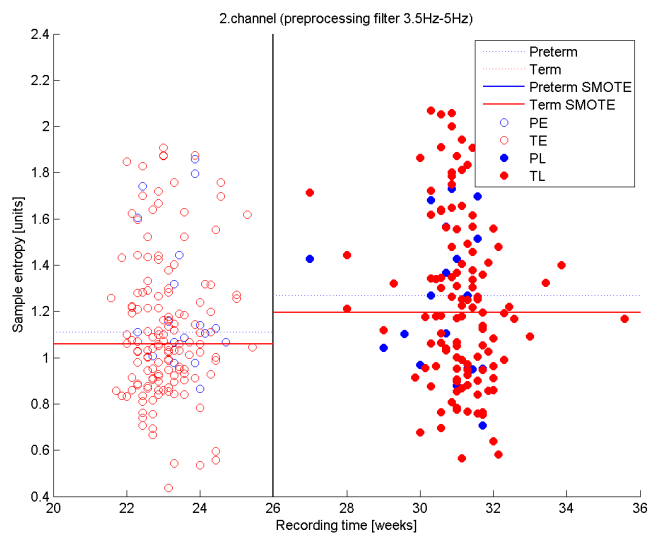
Slika 3.11: 2. kanal, 0,08 Hz - 1 Hz




Slika 3.12: 2. kanal, 1 Hz - 2,2 Hz



Slika 3.13: 2. kanal, 2,2 Hz - 3,5 Hz



Slika 3.14: 2. kanal, 3,5 Hz - 5 Hz



Slika 3.15: 2. kanal, 1 Hz - 5 Hz

### 3.3 Rezultati klasifikacije

Pri rezultatih klasifikacij smo preverili delovanje glede na način sestavljanja učne množice. Spodaj bomo prikazali rezultate za klasifikacijo poroda, ki je bil posnet zgodaj, pri čemer smo poskušali klasificirati, ali je bil predčasen ali terminski, in sicer na štiri načine sestavljanja učne množice:

1. Ocena delovanja po načelu učna množica.
2. Ocena delovanja po načelu učna in testna množica.
3. Ocena delovanja po načelu navzkrižna validacija.
4. Ocena delovanja po načelu izpusti enega.

Nato bomo za druge tri primere klasifikacije prikazali samo rezultate navzkrižne validacije, saj so se le ti izkazali kot najboljši, prav tako je bilo tudi v drugih virih zapisano, da je za testiranje klasifikatorja primerna.

Vse posnetke smo klasificirali glede na vrednost vzorčne entropije na vseh petih področjih, da bi tako tudi ugotovili, na katerem področju dobimo najboljše rezultate klasifikacije in kateri kanal nam da najboljše rezultate.

#### 3.3.1 Posnetki, ki so bili zajeti zgodaj, klasifikacija ali je bil porod predčasen ali ob terminu (PE - TE)

##### 3. kanal

PE - TE(3. channel)	učna množica(ang.training set)														
	0,08 Hz - 1 Hz			1 Hz - 2.2 Hz			2,2 Hz - 3,5 Hz			3,5 Hz - 5 Hz			1 Hz - 5 Hz		
	Se	Sp	CA	Se	Sp	CA	Se	Sp	CA	Se	Sp	CA	Se	Sp	CA
<i>k</i> -NN (št. sosedov: 3)	87,41	78,32	82,87	90,91	75,52	83,22	84,62	69,93	77,27	95,80	76,22	<b>86,01</b>	92,31	74,13	83,22
<i>k</i> -NN (št. sosedov: 4)	92,31	67,13	73,72	95,10	59,44	77,27	93,01	47,55	70,28	97,90	51,75	74,83	93,71	62,94	<b>78,32</b>
<i>k</i> -NN (št. sosedov: 5)	78,32	74,83	76,57	79,72	77,62	78,67	72,73	65,03	68,88	83,92	67,83	75,87	84,62	74,83	<b>79,72</b>
Bayes	75,52	58,74	67,13	55,94	67,13	61,54	44,76	67,83	56,29	41,26	77,62	59,44	86,71	50,35	<b>68,53</b>
LDA	58,04	69,32	63,64	65,73	55,94	60,84	57,34	60,84	59,09	45,45	67,83	56,64	79,02	59,44	<b>69,23</b>
QDA	75,52	58,74	67,13	55,94	67,13	61,54	44,76	67,83	56,29	41,26	77,62	59,44	86,71	50,35	<b>68,53</b>
SVM	67,83	68,53	68,18	60,84	60,84	60,84	56,64	62,94	59,79	53,15	53,15	53,15	79,02	59,44	<b>69,23</b>
Odločitveno drevo	91,61	83,92	87,76	93,01	83,92	88,46	85,31	85,31	85,31	92,31	83,92	88,11	96,50	81,82	<b>89,16</b>

Tabela 3.5: Učna množica, 3. kanal

PE - TE(3. kanal)	učna-testna množica(ang. holdout)														
	0,08 Hz - 1 Hz			1 Hz - 2,2 Hz			2,2 Hz - 3,5 Hz			3,5 Hz - 5 Hz			1 Hz - 5 Hz		
	Se	Sp	CA	Se	Sp	CA	Se	Sp	CA	Se	Sp	CA	Se	Sp	CA
<i>k</i> -NN (št. sosedov: 3)	67,86	57,72	59,65	72,41	50	61,40	42,86	41,38	42,11	75,86	53,57	64,91	65,52	71,43	<b>68,42</b>
<i>k</i> -NN (št. sosedov: 4)	75	41,38	57,89	79,31	32,14	56,14	67,86	34,48	50,88	79,31	46,43	63,16	89,66	46,63	<b>68,42</b>
<i>k</i> -NN (št. sosedov: 5)	60,71	62,07	61,40	72,41	39,29	56,14	62,94	51,75	57,34	68,97	46,63	57,89	86,21	46,43	<b>66,67</b>
Bayes	67,86	55,17	61,40	51,72	75	63,16	42,86	86,21	64,91	37,93	78,57	57,89	82,76	53,57	<b>68,42</b>
LDA	50	69,97	59,65	75,86	60,71	68,42	57,14	75,86	66,67	41,38	67,86	54,39	75,86	57,14	<b>66,67</b>
QDA	64,29	62,07	63,16	55,17	67,86	61,40	46,63	75,86	61,40	37,93	78,57	57,89	82,76	53,57	<b>68,42</b>
SVM	68,97	71,43	<b>70,18</b>	60,84	60,14	60,49	68,97	35,71	52,63	44,83	53,57	49,12	86,21	42,86	64,91
Odločitveno drevo	62,07	60,71	61,40	71,43	68,97	<b>70,18</b>	51,72	46,43	49,12	58,62	53,57	56,14	82,76	53,57	68,42

Tabela 3.6: Učno testna množica, 3. kanal

PE - TE(3. kanal)	k-fold navzkrižna validacija(ang. k-fold cross validation)														
	0,08 Hz - 1 Hz			1 Hz - 2,2 Hz			2,2 Hz - 3,5 Hz			3,5 Hz - 5 Hz			1 Hz - 5 Hz		
	Se	Sp	CA	Se	Sp	CA	Se	Sp	CA	Se	Sp	CA	Se	Sp	CA
<i>k</i> -NN (št. sosedov: 3)	64,34	65,73	65,03	62,94	63,64	63,29	61,54	48,25	54,90	73,43	53,15	63,29	72,73	63,64	<b>68,18</b>
<i>k</i> -NN (št. sosedov: 4)	78,32	46,85	62,59	83,22	44,76	63,99	76,92	33,57	55,24	84,62	44,06	64,34	86,71	54,55	<b>70,63</b>
<i>k</i> -NN (št. sosedov: 5)	65,03	63,64	64,64	73,43	62,24	67,83	62,94	51,75	57,34	72,73	53,85	63,29	78,32	65,03	<b>71,68</b>
Bayes	77,62	55,94	66,78	51,75	77,62	64,69	41,26	72,73	56,99	39,86	77,62	57,74	86,01	53,85	<b>69,93</b>
LDA	58,04	69,23	63,64	65,73	55,94	60,84	57,34	60,84	59,09	45,45	67,83	56,64	79,02	59,44	<b>69,23</b>
QDA	75,52	58,74	67,13	55,94	67,13	61,54	44,76	67,83	56,29	41,26	77,62	59,44	86,71	50,35	<b>68,53</b>
SVM	67,83	66,43	67,13	60,84	60,14	60,49	53,15	64,34	58,74	53,85	53,85	53,85	76,92	60,14	<b>68,53</b>
Odločitveno drevo	81,82	81,82	81,82	88,81	81,82	<b>85,31</b>	78,32	78,32	78,32	81,82	75,52	78,67	<b>88,81</b>	79,02	83,92

Tabela 3.7: Navzkrižna validacija, št.podmnožic = 5, 3. kanal

PE - TE(3. kanal)	izpusti enega(ang. leave one out)														
	0,08 Hz - 1 Hz			1 Hz - 2,2 Hz			2,2 Hz - 3,5 Hz			3,5 Hz - 5 Hz			1 Hz - 5 Hz		
	Se	Sp	CA	Se	Sp	CA	Se	Sp	CA	Se	Sp	CA	Se	Sp	CA
<i>k</i> -NN (št. sosedov: 3)	66,43	67,13	<b>66,78</b>	61,54	59,44	60,49	58,04	47,55	52,80	75,52	51,75	63,64	69,23	62,94	66,08
<i>k</i> -NN (št. sosedov: 4)	78,32	48,25	63,29	79,72	48,95	64,34	72,73	34,27	53,50	83,92	41,96	62,94	84,62	51,05	<b>67,83</b>
<i>k</i> -NN (št. sosedov: 5)	65,03	63,64	63,64	74,13	65,03	69,58	65,03	46,15	55,59	78,32	51,05	64,69	82,52	65,03	<b>71,68</b>
Bayes	77,62	55,94	66,78	51,75	77,62	64,69	41,26	72,73	56,99	39,86	77,62	58,74	86,01	53,85	<b>69,93</b>
LDA	58,04	69,23	63,64	65,73	55,94	60,84	57,34	60,84	59,09	45,45	67,83	56,64	79,02	59,44	<b>69,23</b>
QDA	75,52	58,74	67,13	55,94	67,13	61,54	55,94	61,54	58,37	41,26	77,62	59,44	86,71	58,35	<b>68,53</b>
SVM	67,83	68,53	<b>68,18</b>	60,84	59,44	60,14	55,94	61,54	58,76	52,45	52,45	52,45	78,32	58,04	<b>68,18</b>
Odločitveno drevo	81,82	81,82	81,82	88,81	81,82	<b>85,31</b>	78,32	78,32	78,32	81,82	75,52	78,67	88,81	79,02	83,92

Tabela 3.8: Izpusti enega, 3. kanal

- **Klasifikator z najbližjimi sosedi**

Če pogledamo vse štiri načine sestavljanja učno-testne množice, glej tabele 3.5, 3.6, 3.7, in 3.8, velja da pri tem klasifikatorju dobimo zelo dobre rezultate, če gre samo za učno množico. Drugi najboljši rezultat nam data navzkrižna validacija in metoda izpusti enega.

Najboljši rezultat, če primerjamo klasifikator glede števila sosedov, dobimo, ko imamo pet sosedov in je vrednost med vsemi načini sestavljanja učne množice okoli 70 %, razen pri samo učni množici, kjer imamo zmogljivost skoraj 80 %.

Če gledamo z vidika frekvenčnega področja, ugotovimo, da se je pri rezultatih samo učne množice izkazalo, da je v področju 3,5 Hz - 5 Hz maksimalna klasifikacijska točnost enaka 86 % v primeru treh sosedov. Vrednost specifičnosti med vsemi področji se je za tri sosede gibala med 70 % in 78 %, najboljša je bila na področju 0,08 Hz - 1 Hz. Občutljivost pa je bila zelo dobra, in sicer se je gibala med 72 % in 95 %. Najboljša je bila na področju 3,5 Hz - 5 Hz.

Pri navzkrižni validaciji se je izkazalo, da najboljšo specifičnost, občutljivost in vrednost klasifikacijske točnosti dobimo na področju med 1 Hz - 5 Hz. Vrednosti občutljivosti so bile med 62 % in 86 %. Najslabše rezultate smo dobili na področju od 2,2 Hz - 3,5 Hz. Vrednost specifičnosti se je gibala med 33 % ter 65 %. Najboljša vrednost je bila na področju 0,08 Hz - 1 Hz za primer, ko imamo tri sosede, medtem ko so za štiri in pet sosedov najboljše vrednosti na področju 1 Hz - 5 Hz.

Pri učno-testni množici je najboljši rezultat dajalo večinoma področje med 1 Hz - 5 Hz. Vrednosti klasifikacijske točnosti so se gibale med 42 % ter 68 %. Najslabša klasifikacijska točnost je na področju 2,2 Hz - 3,5 Hz, in sicer je zelo blizu 50 %. Specifičnost se je gibala med 32 % in 71 %. Pri tem področju 1 Hz - 2,2 Hz je imela najnižjo vrednost, ki je bila enaka 32%. Občutljivost se je v tem primeru gibala med 42 % in 89 %.



Pri načinu sestavljanja učne množice izpusti enega je bila klasifikacijska točnost najboljša na področju 1 Hz - 5 Hz ter najslabša na področju 2,2 Hz - 3,5 Hz. Maksimalna vrednost je bila 71 % in minimalna vrednost je bila enaka 52 %. Specifičnost se je gibala med 34 % in 67 % ter je bila spet najslabša na področju 2,2 Hz - 3,5 Hz. Občutljivost se je gibala 58 % in 84 %. Najslabša je bila spet na področju 2,2 Hz - 3,5 Hz.

- **Naivni Bayesov klasifikator**

Pri načinu sestavljanja učne množice se je najboljša klasifikacijska točnost pokazala na področju 1 Hz - 5 Hz in sicer je enaka 68 %. Najslabši rezultat za klasifikacijsko točnost je bil na področju 2,2 Hz - 3,5 Hz in sicer je bila enaka 56 %. Specifičnost se je gibala med vrednostmi 50 % in 77 %. Pri tem se je najslabši rezultat pokazal na področju 1 Hz - 5 Hz in najboljši rezultat na področju 3,5 Hz - 5 Hz. Pri tem je zanimivo, da je bila občutljivost najslabša na področju od 3,5 Hz - 5 Hz in je bila enaka 41 %, najboljša občutljivost pa je bila na področju 1 Hz - 5 Hz in sicer enaka 86 %.

Pri načinu navzkrižne validacije je bila vrednost klasifikacijske točnosti najboljša na področju od 1 Hz - 5 Hz in je bila enaka 69 %, najslabši rezultat je bil na področju 2,2 Hz - 3,5 Hz in je bila enaka 56 %. Občutljivost je bila najboljša na področju 1 Hz - 5 Hz in je bila enaka 86 % ter najslabša na 2,2 Hz - 3,5 Hz. Pri tem je bila specifičnost najslabša na področju 1 Hz - 5 Hz 53% in najboljša na 1 Hz - 2,2 Hz in sicer 77 %.

Pri načinu ocenjevanja učno-testne množice so bile najboljše vrednosti na področju 1 Hz - 5 Hz. Klasifikacijska točnost je bila enaka 68 %, občutljivost pa 82 %. Najboljša vrednost specifičnosti je bila na področju 2,2 Hz - 3,5 Hz in je enaka 86 %.

Pri načinu izpusti enega se je področje 1 Hz - 5 Hz spet izkazalo z najboljšimi vrednostmi klasifikacijske točnosti in občutljivosti, vrednosti

katerih so bile 69 % ter 86 %. Najslabše vrednosti so bili na področju od 2,2 Hz - 3,5 Hz. Specifičnost pa je bila najnižja na področju 1 Hz - 5 Hz in najboljša na področjih 1 Hz - 2,2 Hz in 3,5 Hz - 5 Hz.

- **Klasifikator z linearno diskriminantno analizo**

Pri vseh načinih ločevanja se je izkazalo, da daje ta klasifikator najboljše rezultate na področju 1 Hz - 5 Hz, in sicer je klasifikacijska točnost enaka 69 %.

- **Klasifikator s kvadratno diskriminantno analizo**

Tako kot pri linearni diskriminantni analizi lahko vidimo, da so najboljši rezultati na področju od 1 Hz - 5 Hz in sicer se maksimalna klasifikacijska točnost giblje med 60 % in 68 %, občutljivost pa med 82% in 86 %.

- **Metoda podpornih vektorjev**

Ta metoda je pokazala, da je najboljša klasifikacijska točnost na področju 1 Hz - 5 Hz, in sicer se vrednosti gibljejo med 49 % in 69 %, pri občutljivosti se gibljejo med 76 % v primeru navzkrižne validacije in 86 % v primeru učno-testne množice.

- **Odločitvena drevesa**

Najboljši rezultat občutljivosti so pokazala na področju 1 Hz - 5 Hz in sicer so se gibali med 68 % in 89 %. Specifičnost pa je bila zelo dobra na področju 1 Hz - 2,2 Hz pri metodi izpusti enega in navzkrižni validaciji in sicer je bila enaka 81 %. Občutljivost pa je bila tudi najboljša na tem področju, in sicer je bila enaka 88 %.

Če povzamemo rezultate na 3. kanalu za vse načine ločevanja množic, lahko vidimo, da so bili najboljši rezultati specifičnosti, občutljivosti in klasifikacijske točnosti na področju 1 Hz - 5 Hz. Najslabše rezultate vseh klasifikatorjev je v večini primerov dajalo področje 1 Hz - 2,2 Hz. Če naredimo izpusti enega ali navzkrižno validacijo, so vrednosti med sabo primerno enake.

## 2. kanal

Pri drugem kanalu bomo prikazali samo rezultate navzkrižne validacije za vse klasifikatorje na vseh področjih v tabeli 3.9.

PE - TE(2. kanal)	k-fold križna validacija(ang. k-fold cross validation)														
	0,08 Hz - 1 Hz			1 Hz - 2,2 Hz			2,2 Hz - 3,5 Hz			3,5 Hz - 5 Hz			1 Hz - 5 Hz		
	Se	Sp	CA	Se	Sp	CA	Se	Sp	CA	Se	Sp	CA	Se	Sp	CA
<i>k</i> -NN (št. sosedov: 3)	52,45	49,65	51,05	70,63	55,94	63,29	62,24	62,94	62,59	60,14	74,83	<b>67,48</b>	65,73	60,84	63,29
<i>k</i> -NN (št. sosedov: 4)	74,83	39,16	56,99	80,42	41,96	61,19	76,22	49,65	62,94	67,83	61,54	64,69	83,22	53,85	<b>68,53</b>
<i>k</i> -NN (št. sosedov: 5)	65,73	52,45	59,09	65,03	55,24	60,14	69,23	57,34	63,29	57,34	75,52	66,43	71,33	62,24	<b>66,78</b>
Bayes	56,64	38,46	47,55	75,52	34,97	55,24	84,62	30,07	57,34	58,04	46,85	52,45	86,01	45,45	<b>65,73</b>
LDA	53,15	40,56	46,85	63,64	51,05	57,34	73,43	39,86	56,64	63,64	29,37	46,50	60,84	57,34	<b>59,09</b>
QDA	69,23	25,17	47,20	75,52	33,57	54,55	83,22	29,37	56,29	48,95	71,33	60,14	86,01	44,76	<b>56,38</b>
SVM	53,15	58,04	55,59	69,23	39,86	54,55	68,53	37,76	53,15	44,06	70,63	57,34	81,82	50,35	<b>66,08</b>
Odločitveno drevo	81,12	75,52	78,32	90,91	76,22	<b>83,57</b>	76,22	87,41	81,82	80,42	85,31	82,87	90,21	74,83	82,52

Tabela 3.9: Navzkrižna validacija, št.podmnožic = 5, 2. kanal

- **Klasifikator z najbližjimi sosedi**

Najboljše vrednosti klasifikacijske točnosti in občutljivosti lahko vidimo na področju 1 Hz - 5 Hz, in sicer je vrednost klasifikacijske točnosti na področju 1 Hz - 5 Hz in je enaka 68 %, najslabša pa je na področju 0,08 Hz - 1 Hz in je enaka 51 %. Vrednost občutljivosti je maksimalna in enaka 83 % na področju 1 Hz - 5 Hz ter najslabša na področju 0,08 Hz - 1 Hz 52 %. Specifičnost pa je najboljša na področju 3,5 Hz - 5 Hz in je enaka 75 % ter najslabša na področju 0,08 Hz - 1 Hz in je enaka 39 %.

- **Naivni Bayesov klasifikator**

Najboljše vrednosti klasifikacijske točnosti in občutljivosti je na področju 1 Hz - 5 Hz in je enaka 86 %, 65 %. Najslabše vrednosti so na področju od 0,08 Hz - 1 Hz za občutljivost in klasifikacijsko točnost. Specifičnost nam je pokazala dobre rezultate na območju 3,5 Hz - 5 Hz. in sicer 46 %, kar pomeni, da je v bistvu dovolj nizka.

- **Klasifikator z linearno diskriminantno analizo**

Najboljše vrednosti klasifikacijske točnosti in specifičnosti imamo na področju 1 Hz - 5 Hz. Specifičnost je enaka 57 %, klasifikacijska točnost

pa je enaka 59 %. Najboljši rezultat občutljivosti imamo na področju 2,2 Hz - 3,5 Hz in je enaka 73 %.

- **Klasifikator s kvadratno diskriminantno analizo**

V primerjavi z linearno diskriminantno analizo ima večje vrednosti specifičnosti, in sicer je 71 %. Najvišja vrednost občutljivosti je enaka 86%, je pa klasifikacijska točnost manjša kot pri linearni diskriminanti analizi in je enaka 56 %.

- **Metoda podpornih vektorjev**

Pri metodi podpornih vektorjev so bile vrednosti občutljivosti najvišje na področju 1 Hz - 5 Hz ter enaka 81 %, pri specifičnosti pa je bila najvišja vrednost na področju 3,5 Hz - 5 Hz in je bila enaka 70 %. Maksimalna klasifikacijska točnost je bila na področju 1 Hz - 5 Hz in enaka 66%.

- **Odločitvena drevesa**

Pri odločitvenih drevesih imamo najboljše vrednosti občutljivosti in klasifikacijske točnosti na območju 1 Hz - 2,2 Hz, in sicer občutljivost 90% in klasifikacijska točnost 83%. Najboljša specifičnost pa je na področju 2,2 Hz - 3,5 Hz in je enaka 87 %.

## 1. kanal

Za 1. kanal lahko vidimo rezultate v tabeli 3.10

PE - TE(1. kanal)	k-fold križna validacija(ang. k-fold cross validation)														
	0,08 Hz - 1 Hz			1 Hz - 2,2 Hz			2,2 Hz - 3,5 Hz			3,5 Hz - 5 Hz			1 Hz - 5 Hz		
	Se	Sp	CA	Se	Sp	CA	Se	Sp	CA	Se	Sp	CA	Se	Sp	CA
<i>k</i> -NN (št. sosedov: 3)	89,51	62,94	76,22	58,74	60,84	59,79	52,45	49,65	51,05	69,23	67,83	68,53	81,12	74,13	<b>77,62</b>
<i>k</i> -NN (št. sosedov: 4)	96,50	55,94	76,22	72,73	44,76	58,74	70,63	43,36	56,99	80,42	55,94	68,18	90,91	65,03	<b>77,97</b>
<i>k</i> -NN (št. sosedov: 5)	83,22	59,44	71,33	65,03	62,24	63,64	55,94	62,24	59,09	65,73	67,13	66,43	83,92	73,43	<b>78,67</b>
Bayes	9,79	84,62	47,20	40,56	76,22	58,39	79,72	43,36	61,54	81,12	48,95	<b>65,03</b>	51,75	73,43	62,59
LDA	51,05	67,13	59,09	49,65	43,36	46,50	55,24	56,64	55,94	67,13	51,75	59,44	73,43	60,14	<b>66,78</b>
QDA	9,79	83,22	46,50	44,06	69,93	56,99	76,92	50,35	63,64	81,82	48,95	<b>65,38</b>	76,92	50,35	63,64
SVM	73,43	42,66	58,04	48,25	68,53	58,39	74,13	49,65	61,89	79,72	53,15	<b>66,43</b>	74,13	49,65	61,89
Odločitveno drevo	97,20	77,62	<b>87,41</b>	79,02	85,31	82,17	79,02	81,82	80,42	81,82	87,41	84,62	79,02	81,82	80,42

Tabela 3.10: Navzkrižna validacija, št.podmnožic = 5, 1. kanal

- **Klasifikator z najbližjimi sosedi**

Najboljše rezultate, tako kot tudi pri prejšnjih kanalih, je pokazalo področje 1 Hz - 5 Hz za specifičnost in klasifikacijsko točnost, kjer je maksimalna vrednost Sp=74 % CA=78 %. Vrednost občutljivosti pa je bila na področju 0,08 Hz - 1 Hz najboljša, in sicer 96 %.

- **Naivni Bayesov klasifikator**

Klasifikacijska točnost je bila maksimalna na področju 3,5 Hz - 5 Hz in je bila enaka 65 %. Tudi občutljivost je bila na tem področju najvišja in je bila enaka 81 %. Specifičnost pa je bila najboljša na področju 0,08 Hz - 1 Hz in je bila enaka 84 %.

- **Klasifikator z linearno diskriminantno analizo**

Klasifikacijska točnost je bila maksimalna na področju 1 Hz - 5 Hz in je bila enaka 66 %. Tudi občutljivost je bila na tem področju najvišja in je bila enaka 73 %. Specifičnost pa je bila najboljša na področju 0,08 Hz - 1 Hz in je imela vrednost 67 %.

- **Klasifikator s kvadratno diskriminantno analizo**

Klasifikacijska točnost je bila maksimalna na področju 3,5 Hz - 5 Hz in je bila enaka 65 %. Tudi občutljivost je bila na tem področju najvišja

in je bila enaka 81 %. Specifičnost pa je bila najboljša na področju 0,08 Hz - 1 Hz in je imela vrednost 83 %.

- **Metoda podpornih vektorjev**

Klasifikacijska točnost je bila maksimalna na področju 3,5 Hz - 5 Hz in je bila enaka 66 %. Tudi občutljivost je bila na tem področju najvišja in je bila enaka 79 %. Specifičnost pa je bila najboljša na področju 1 Hz - 2,2 Hz in je imela vrednost 68 %.

- **Odločitvena drevesa**

Klasifikacijska točnost je bila maksimalna na področju 0,08 Hz - 1 Hz in je bila enaka 87 %. Tudi občutljivost je bila na tem področju najvišja in je bila enaka 97 %. Specifičnost pa je bila najboljša na področju 3,5 Hz - 5 Hz in je imela vrednost 87 %.

Če povzamemo vse tri kanale, vidimo, da so bili rezultati za občutljivost in klasifikacijsko točnost najboljši na področju 1 Hz - 5 Hz, vrednosti, ki so bile na 3.kanal, pa so bile najvišje v primerjavi z drugima dvema kanaloma. Prav tako lahko vidimo, da smo najboljši rezultat dobili pri odločitvenih drevesih, saj so tam vrednosti bile višje od 80 %. Najslabše vrednosti klasifikacijske točnosti so bile na področju 1 Hz - 2,2 Hz in v drugem kanalu.

### **3.3.2 Posnetki, ki so bili zajeti pozno, klasifikacija, ali je bil porod predčasen ali ob terminu (PL - TL)**

#### **3. kanal**

Spodnja tabela 3.11 nam prikazuje rezultate križne validacije za 3. kanal.

- **Klasifikator z najbližjimi sosedi**

Klasifikacijska točnost je bila maksimalna na področju 2,2 Hz - 3,5 Hz in je bila enaka 74 %. Tudi občutljivost je bila najvišja na tem področju in je bila enaka 86 %. Specifičnost pa je bila najvišja na področju 1 Hz - 2,2 Hz in je imela vrednost 68 %.

PL - TL(3. kanal)	k-fold križna validacija(ang. k-fold cross validation)														
	0,08 Hz - 1 Hz			1 Hz - 2,2 Hz			2,2 Hz - 3,5 Hz			3,5 Hz - 5 Hz			1 Hz - 5 Hz		
	Se	Sp	CA	Se	Sp	CA	Se	Sp	CA	Se	Sp	CA	Se	Sp	CA
<i>k</i> -NN (št. sosedov: 3)	73,11	64,71	68,91	72,27	68,91	70,59	80,67	67,23	<b>73,95</b>	67,23	59,66	63,45	70,59	61,34	65,97
<i>k</i> -NN (št. sosedov: 4)	84,03	57,98	71,01	77,31	60,50	68,91	86,55	63,03	<b>74,79</b>	71,43	50,42	60,92	72,27	57,98	65,13
<i>k</i> -NN (št. sosedov: 5)	78,15	63,87	71,01	76,47	66,39	<b>71,43</b>	80,67	59,66	70,17	73,95	60,50	67,23	66,39	68,07	67,23
Bayes	45,38	75,63	<b>60,50</b>	71,43	41,18	56,30	62,18	30,25	46,22	78,99	35,29	57,14	88,24	35,29	61,76
LDA	54,62	65,55	60,08	63,87	55,46	59,66	63,03	62,18	<b>62,61</b>	36,13	59,66	47,90	53,78	46,22	50
QDA	46,22	75,63	60,92	67,23	39,50	53,36	58,82	36,13	47,48	64,71	49,58	57,14	88,24	36,13	<b>62,18</b>
SVM	42,86	74,79	58,82	67,23	50,42	58,82	60,50	40,34	50,42	69,75	43,70	56,72	84,87	42,86	<b>63,87</b>
Odlčitveno drevo	79,83	85,71	82,77	87,39	84,03	<b>85,71</b>	81,51	58,71	83,61	84,03	82,35	83,19	85,71	78,99	82,35

Tabela 3.11: Navzkrižna validacija, št.podmnožic = 5, 3. kanal

- Naivni Bayesov klasifikator

Klasifikacijska točnost je bila maksimalna na področju 0,08 Hz - 1 Hz in je bila enaka 60 %. Specifičnost je bila najvišja na tem področju in je bila enaka 75 %. Občutljivost pa je bila najboljša na področju 1 Hz - 5 Hz in je imela vrednost 88 %.

- Klasifikator z linearno diskriminantno analizo

Klasifikacijska točnost je bila maksimalna na področju 2,2 Hz - 3,5 Hz in je bila enaka 62 %. Tudi občutljivost je bila najvišja na tem področju in je bila enaka 63 %. Specifičnost pa je bila najboljša na področju 0,08 Hz - 1 Hz in je imela vrednost 65 %.

- Klasifikator s kvadratno diskriminantno analizo

Klasifikacijska točnost je bila maksimalna na področju 1 Hz - 5 Hz in je bila enaka 62 %. Tudi občutljivost je bila najvišja na tem področju in je bila enaka 88 %. Specifičnost pa je bila najboljša na področju 0,08 Hz - 1 Hz in je imela vrednost 75 %.

- Metoda podpornih vektorjev

Klasifikacijska točnost je bila maksimalna na področju 1 Hz - 5 Hz in je bila enaka 63 %. Tudi občutljivost je bila najvišja na tem področju in je bila enaka 84 %. Specifičnost pa je bila najboljša na področju 0,08 Hz - 1 Hz in je imela vrednost 74 %.

- **Odločitvena drevesa**

Klasifikacijska točnost je bila maksimalna na področju 1 Hz - 2,2 Hz in je bila enaka 85 %. Tudi občutljivost je bila najvišja na tem področju in je bila enaka 87 %. Specifičnost pa je bila najboljša na področju 0,08 Hz - 1 Hz in je imela vrednost 85 %.

## 2. kanal

PL - TL(2. kanal)	k-fold križna validacija(ang. k-fold cross validation)														
	0,08 Hz - 1 Hz			1 Hz - 2,2 Hz			2,2 Hz - 3,5 Hz			3,5 Hz - 5 Hz			1 Hz - 5 Hz		
	Se	Sp	CA	Se	Sp	CA	Se	Sp	CA	Se	Sp	CA	Se	Sp	CA
<i>k</i> -NN (št. sosedov: 3)	59,66	56,30	57,98	53,78	55,46	54,62	80,67	68,07	<b>74,37</b>	59,66	73,11	66,39	65,55	57,14	61,34
<i>k</i> -NN (št. sosedov: 4)	68,07	44,54	56,30	65,55	47,06	56,30	84,87	63,87	<b>74,37</b>	68,07	60,50	64,29	66,39	51,26	58,82
<i>k</i> -NN (št. sosedov: 5)	60,50	52,94	56,72	51,26	53,78	52,52	82,35	63,87	<b>73,11</b>	62,18	68,07	65,13	57,14	56,30	56,72
Bayes	31,09	71,43	51,26	78,15	31,93	55,04	83,19	33,61	58,40	44,54	68,91	56,72	76,53	46,22	<b>60,92</b>
LDA	36,13	52,10	44,12	57,14	46,22	51,68	48,74	42,86	45,80	45,38	44,54	44,96	61,34	57,14	<b>59,24</b>
QDA	31,09	73,95	52,52	78,15	31,39	55,04	87,39	34,45	<b>60,92</b>	42,02	73,95	57,98	75,63	46,22	<b>60,92</b>
SVM	41,18	66,39	53,78	63,87	32,77	48,32	72,27	36,97	54,62	46,22	56,30	51,26	76,47	43,70	<b>60,08</b>
Odločitveno drevo	88,24	71,43	79,83	77,31	79,83	78,57	94,12	78,15	<b>86,13</b>	78,15	85,71	81,93	89,08	74,79	81,93

Tabela 3.12: Navzkrižna validacija, št.podmnožic = 5, 2. kanal

- **Klasifikator z najbližjimi sosedi**

Klasifikacijska točnost je bila maksimalna na področju 2,2 Hz - 3,5 Hz in je bila enaka 74 %. Tudi občutljivost je bila najvišja na tem področju in je bila enaka 84 %. Specifičnost pa je bila najboljša na področju 3,5 Hz - 5 Hz in je imela vrednost 73 %.

- **Naivni Bayesov klasifikator**

Klasifikacijska točnost je bila maksimalna na področju 1 Hz - 5 Hz in je bila enaka 60 %. Občutljivost je bila najvišja na področju 2,2 Hz - 3,5 Hz in je bila enaka 83 %. Specifičnost pa je bila najboljša na področju 0,08 Hz - 1 Hz in je imela vrednost 71 %.

- **Klasifikator z linearno diskriminantno analizo**

Klasifikacijska točnost je bila maksimalna na področju 1 Hz - 5 Hz in je bila enaka 59 %. Občutljivost je bila na istem področju najvišja in



je bila enaka 61 %, prav tako je bila tudi specifičnost najboljša na tem področju in je imela vrednost 57 %.

- **Klasifikator s kvadratno diskriminantno analizo**

Klasifikacijska točnost je bila maksimalna na področjih 1 Hz - 5 Hz in 2,2 Hz - 3,5 Hz, njena vrednost je bila enaka 60 %. Občutljivost je bila najvišja na področju 2,2 Hz - 3,5 Hz in je bila enaka 87 %. Specifičnost pa je bila najboljša na področjih 0,08 Hz - 1 Hz in je imela vrednost 73 %.

- **Metoda podpornih vektorjev**

Klasifikacijska točnost je bila maksimalna na področju 1 Hz - 5 Hz in je bila enaka 60 %. Tudi občutljivost je bila najvišja na tem področju in je bila enaka 76 %. Specifičnost pa je bila najboljša na področju 0,08 Hz - 1 Hz in je imela vrednost 66 %.

- **Odločitvena drevesa**

Klasifikacijska točnost je bila maksimalna na področju 2,2 Hz - 3,5 Hz in je bila enaka 86 %. Tudi občutljivost je bila najvišja na tem področju in je bila enaka 94 %. Specifičnost pa je bila najboljša na področju 3,5 Hz - 5 Hz in je imela vrednost 79 %.

## 1. kanal

PL - TL(1. kanal)	k-fold križna validacija(ang. k-fold cross validation)														
	0,08 Hz - 1 Hz			1 Hz - 2,2 Hz			2,2 Hz - 3,5 Hz			3,5 Hz - 5 Hz			1 Hz - 5 Hz		
	Se	Sp	CA	Se	Sp	CA	Se	Sp	CA	Se	Sp	CA	Se	Sp	CA
<i>k</i> -NN (št. sosedov: 3)	66,39	56,30	61,34	69,75	57,98	63,87	68,07	75,63	<b>71,85</b>	64,71	69,75	67,23	64,71	59,66	62,18
<i>k</i> -NN (št. sosedov: 4)	78,15	44,54	61,34	73,95	54,62	64,29	75,63	76,47	<b>76,05</b>	75,63	61,34	68,49	72,27	53,78	63,03
<i>k</i> -NN (št. sosedov: 5)	66,39	58,52	62,61	66,39	63,03	64,71	67,23	79,83	<b>73,53</b>	63,87	67,23	65,55	67,23	64,71	65,97
Bayes	59,66	63,87	61,76	73,95	48,74	61,34	46,22	75,63	60,92	52,10	85,71	<b>68,91</b>	85,71	41,18	63,45
LDA	59,66	61,34	60,50	54,62	59,66	57,14	57,14	71,43	<b>64,29</b>	7,14	56,30	56,72	71,43	52,94	62,18
QDA	58,82	67,23	63,03	68,91	45,38	57,14	46,22	75,63	60,92	52,10	82,53	67,23	85,71	42,02	<b>63,87</b>
SVM	59,66	61,34	60,50	73,11	42,02	57,56	48,74	74,79	61,16	49,58	84,03	<b>66,81</b>	78,99	43,70	61,34
Odlučitveno drevo	85,71	74,79	80,25	82,35	80,67	81,51	83,19	90,76	<b>86,97</b>	81,51	79,83	80,67	82,35	58,71	84,03

Tabela 3.13: Navzkrižna validacija, št. podmnožic = 5, 1. kanal

- **Klasifikator z najbližjimi sosedi**

Klasifikacijska točnost je bila maksimalna na področju 2,2 Hz - 3,5 Hz in je bila enaka 76 %. Na istem področju je bila najboljša tudi specifičnost ter je imela vrednost 79 %. Občutljivost je bila najvišja na področjih 1 Hz - 5 Hz in 2,2 Hz - 3,5 Hz, njena vrednost je bila enaka 78 %.

- **Naivni Bayesov klasifikator**

Klasifikacijska točnost je bila maksimalna na področju 3,5 Hz - 5 Hz in je bila enaka 68 %. Občutljivost je bila najvišja na 1 Hz - 5 Hz in je bila enaka 85 %. Specifičnost pa je bila najboljša na področju 3,5 Hz - 5 Hz in je imela vrednost 85 %.

- **Klasifikator z linearno diskriminantno analizo**

Klasifikacijska točnost je bila maksimalna na področju 2,2 Hz - 3,5 Hz in je bila enaka 64 %. Tudi specifičnost je bila najboljša na tem področju in je imela vrednost 71 %. Občutljivost je bila najvišja na 1 Hz - 5 Hz in je bila enaka 71 %.

- **Klasifikator s kvadratno diskriminantno analizo**

Klasifikacijska točnost je bila maksimalna na področju 1 Hz - 5 Hz in je bila enaka 63 %. Tudi občutljivost je bila najvišja na tem področju

in je bila enaka 85 %. Specifičnost pa je bila najboljša na področju 3,5 Hz - 5 Hz in je imela vrednost 82 %.

- **Metoda podpornih vektorjev**

Klasifikacijska točnost je bila maksimalna na področju 3,5 Hz - 5 Hz in je bila enaka 66 %. Tudi specifičnost je bila najboljša na tem področju in je imela vrednost 84 %. Občutljivost je bila najvišja na 1 Hz - 5 Hz in je bila enaka 78 %.

- **Odločitvena drevesa**

Klasifikacijska točnost je bila maksimalna na področju 2,2 Hz - 3,5 Hz in je bila enaka 86 %. Tudi specifičnost je bila najboljša na tem področju in je imela vrednost 90 %. Občutljivost je bila najvišja na 0,08 Hz - 1 Hz in je bila enaka 85 %.

Če povzamemo za vse tri kanale, lahko zapišemo, da imamo za klasifikacijsko točnost dobre rezultate na področju 1 Hz - 5 Hz za 2. kanal in 2,2 Hz - 3,5 Hz za 1. in 3. kanal, in sicer za klasifikacijo posnetkov, ki so bili zajeti pozno, v razred, ali bo porod predčasen ali terminski.

### **3.3.3 Klasifikacija, ali je bil posnetek zajet zgodaj ali pozno PE - PL. Posnetki so s prezgodnjim porodom.**

#### **3. kanal**

- **Klasifikator z najbližjimi sosedi**

Klasifikacijska točnost je bila maksimalna na področjih 0,08 Hz - 1 Hz in 1 Hz - 2,2 Hz, njena vrednost je bila enaka 55 %. Občutljivost je bila najvišja na področjih 2,2 Hz - 3,5 Hz in 1 Hz - 5 Hz, njena vrednost je bila enaka 78 %. Specifičnost pa je bila najboljša na področju 2,2 Hz - 3,5 Hz in je imela vrednost 57 %.

PE - PL(3. kanal)	k-fold križna validacija(ang. k-fold cross validation)														
	0,08 Hz - 1 Hz			1 Hz - 2,2 Hz			2,2 Hz - 3,5 Hz			3,5 Hz - 5 Hz			1 Hz - 5 Hz		
	Se	Sp	CA	Se	Sp	CA	Se	Sp	CA	Se	Sp	CA	Se	Sp	CA
<i>k</i> -NN (št. sosedov: 3)	57,89	47,37	52,63	57,89	52,63	<b>55,26</b>	26,23	52,63	39,47	43,37	47,37	47,37	31,58	42,11	36,84
<i>k</i> -NN (št. sosedov: 4)	73,68	36,84	<b>55,26</b>	73,68	31,58	52,63	78,95	26,32	52,63	63,16	36,84	50	78,95	26,32	52,63
<i>k</i> -NN (št. sosedov: 5)	47,37	52,63	50	57,89	52,63	<b>55,26</b>	42,11	57,89	50	42,11	47,37	44,74	42,11	47,37	44,74
Bayes	68,42	47,37	57,89	47,37	73,68	<b>60,53</b>	31,58	89,47	<b>60,53</b>	21,05	84,21	52,63	31,58	84,21	57,89
LDA	63,16	47,37	55,26	63,16	36,84	50	52,63	52,63	52,63	63,16	26,12	44,74	73,68	52,63	<b>63,13</b>
QDA	78,95	31,58	55,26	57,89	73,68	<b>65,79</b>	31,58	89,47	60,53	31,58	73,68	52,63	42,11	68,42	55,26
SVM	68,42	47,37	57,89	57,89	78,95	<b>68,42</b>	47,37	63,16	55,26	31,58	68,42	50	52,63	52,63	52,63
Odločitveno drevo	78,95	68,42	73,68	73,68	78,95	76,32	57,89	84,21	71,05	100	47,37	73,68	89,47	73,68	<b>81,58</b>

Tabela 3.14: Navzkrižna validacija, št. podmnožic = 5, 3. kanal

- **Naivni Bayesov klasifikator**

Klasifikacijska točnost je bila maksimalna na področjih 1 Hz - 2,2 Hz in 2,2 Hz - 3,5 Hz, njena vrednost je bila enaka 60 %. Občutljivost je bila najvišja na 0,08 Hz - 1 Hz in je bila enaka 68 %. Specifičnost pa je bila najboljša na področju 2,2 Hz - 3,5 Hz in je imela vrednost 89 %.

- **Klasifikator z linearno diskriminantno analizo**

Klasifikacijska točnost je bila maksimalna na področju 1 Hz - 5 Hz in je bila enaka 63 %. Občutljivost je bila na istem področju najvišja in je bila enaka 73 %, prav tako je tudi specifičnost bila najboljša na tem področju in je imela vrednost 52 %.

- **Klasifikator s kvadratno diskriminantno analizo**

Klasifikacijska točnost je bila maksimalna na področju 1 Hz - 2,2 Hz in je bila enaka 65 %. Specifičnost je bila najboljša na področju 2,2 Hz - 3,5 Hz in imela vrednost 89 %. Občutljivost je bila najvišja na 0,08 Hz - 1 Hz in je bila enaka 78 %.

- **Metoda podpornih vektorjev**

Klasifikacijska točnost je bila maksimalna na področju 1 Hz - 2,2 Hz in je bila enaka 68 %. Specifičnost je bila najboljša na istem področju in imela vrednost 78 %. Občutljivost je bila najvišja na 0,08 Hz - 1 Hz področju in je bila enaka 68 %.

- **Odločitvena drevesa**

Klasifikacijska točnost je bila maksimalna na področju 1 Hz - 5 Hz in je bila enaka 81 %. Občutljivost je bila najvišja na 3,5 Hz - 5 Hz in je bila enaka 100 %. Specifičnost je bila najboljša na področju 2,2 Hz - 3,5 Hz in je imela vrednost 84 %.

## 2. kanal

PE - PL(2. kanal)	k-fold križna validacija(ang. k-fold cross validation)														
	0,08 Hz - 1 Hz			1 Hz - 2,2 Hz			2,2 Hz - 3,5 Hz			3,5 Hz - 5 Hz			1 Hz - 5 Hz		
	Se	Sp	CA	Se	Sp	CA	Se	Sp	CA	Se	Sp	CA	Se	Sp	CA
<i>k</i> -NN (št. sosedov: 3)	68.42	52.63	60.53	26.32	26.32	36.84	42.11	63.16	52.63	36.84	68.42	52.63	73.68	68.42	<b>71.05</b>
<i>k</i> -NN (št. sosedov: 4)	73.68	21.05	47.37	52.63	26.32	39.47	84.21	15.79	50.00	63.16	31.58	47.37	71.05	68.42	<b>73.68</b>
<i>k</i> -NN (št. sosedov: 5)	52.63	52.63	52.63	39.47	47.37	47.37	52.63	47.37	50.00	47.37	73.68	65.79	78.95	78.95	<b>78.95</b>
Bayes	26.32	84.21	55.26	42.11	63.16	52.63	47.37	52.63	50	21.05	73.68	47.37	84.21	73.68	<b>78.95</b>
LDA	52.63	73.68	63.16	42.11	63.16	52.63	36.84	68.42	52.63	68.42	52.63	60.53	84.21	78.95	<b>81.58</b>
QDA	63.16	84.21	57.89	42.11	68.42	55.26	26.32	78.95	52.63	68.42	68.42	60.53	84.21	78.95	<b>81.58</b>
SVM	26.32	84.21	55.26	31.58	68.42	50.00	73.68	57.89	65.79	73.68	52.63	63.16	68.42	78.95	<b>73.68</b>
Odločitveno drevo	73.68	73.68	73.68	89.47	47.37	68.42	84.21	78.95	81.58	73.68	84.21	78.95	73.68	94.74	<b>84.21</b>

Tabela 3.15: Navzkrižna validacija, št. podmnožic = 5, 2. kanal

- **Klasifikator z najbližjimi sosedi**

Klasifikacijska točnost je bila maksimalna na področju 1 Hz - 5 Hz in je bila enaka 78 %. Občutljivost je bila najvišja na 2,2 Hz - 3,5 Hz področju in je bila enaka 84 %. Tudi specifičnost je bila najboljša na istem področju ter je imela vrednost 78 %.

- **Naivni Bayesov klasifikator**

Klasifikacijska točnost je bila maksimalna na področju 1 Hz - 5 Hz in je bila enaka 78 %. Občutljivost je bila najvišja na listem področju in je bila enaka 84 %. Specifičnost je bila najboljša na področju 0,08 Hz - 1 Hz in je imela vrednost 84 %.

- **Klasifikator z linearno diskriminantno analizo**

Klasifikacijska točnost je bila maksimalna na področju 1 Hz - 5 Hz in je bila enaka 81 %. Občutljivost je bila na istem področju najvišja in

je bila enaka 84 %, prav tako je tudi specifičnost bila najboljša na tem področju in je imela vrednost 78 %.

- **Klasifikator s kvadratno diskriminantno analizo**

Klasifikacijska točnost je bila maksimalna na področju 1 Hz - 5 Hz in je bila enaka 81 %. Tudi specifičnost je bila najvišja na istem področju in je bila enaka 84 %. Specifičnost je bila najboljša na področju 0,08 Hz - 1 Hz in je imela vrednost 84 %.

- **Metoda podpornih vektorjev**

Klasifikacijska točnost je bila maksimalna na področju 1 Hz - 5 Hz in je bila enaka 73 %. Specifičnost pa je bila najboljša na 0,08 Hz - 1 Hz in je imela vrednost 84 %. Občutljivost je bila najvišja na področjih 2,2 Hz - 3,5 Hz in 3,5 Hz - 5 Hz, njena vrednost je bila enaka 73 %.

- **Odločitvena drevesa**

Klasifikacijska točnost je bila maksimalna na področju 1 Hz - 5 Hz in je bila enaka 84 %. Tudi specifičnost je bila najboljša na istem področju in je imela vrednost 94 %. Občutljivost je bila najvišja na 1 Hz - 2,2 Hz področju in je bila enaka 89 %.

## 1. kanal

PE - PL(1. kanal)	k-fold križna validacija(ang. k-fold cross validation)														
	0,08 Hz - 1 Hz			1 Hz - 2,2 Hz			2,2 Hz - 3,5 Hz			3,5 Hz - 5 Hz			1 Hz - 5 Hz		
	Se	Sp	CA	Se	Sp	CA	Se	Sp	CA	Se	Sp	CA	Se	Sp	CA
<i>k</i> -NN (št. sosedov: 3)	68.42	73.68	<b>71.05</b>	57.89	57.89	57.89	76.32	42.11	36.84	52.63	63.16	57.89	57.89	63.16	60.53
<i>k</i> -NN (št. sosedov: 4)	84.21	84.21	<b>68.42</b>	68.42	36.84	52.63	42.11	26.32	34.21	78.95	52.63	65.79	78.95	47.37	63.16
<i>k</i> -NN (št. sosedov: 5)	84.21	63.16	<b>73.68</b>	57.89	63.16	60.53	36.84	63.16	50.00	52.63	68.42	63.16	68.42	52.63	60.53
Bayes	78.95	68.42	<b>73.68</b>	47.37	84.21	65.79	50.00	73.68	60.53	42.11	42.11	65.79	26.32	84.21	55.26
LDA	73.68	57.89	65.79	57.89	63.16	60.53	57.89	73.68	<b>73.68</b>	57.89	47.37	52.63	52.63	78.95	65.79
QDA	57.89	68.42	<b>63.16</b>	47.37	78.95	<b>63.16</b>	47.37	78.95	<b>63.16</b>	36.84	89.47	<b>63.16</b>	26.32	84.21	55.26
SVM	73.68	57.89	<b>65.79</b>	47.37	78.95	63.16	47.37	73.68	60.53	31.58	73.68	52.63	52.63	47.37	50.00
Odločitveno drevo	84.21	78.95	<b>81.58</b>	78.95	73.68	76.32	57.89	57.89	71.05	84.21	68.42	76.32	84.21	78.95	<b>81.58</b>

Tabela 3.16: Navzkrižna validacija, št. podmnožic = 5, 1. kanal

- **Klasifikator z najbližjimi sosedi**

Klasifikacijska točnost je bila maksimalna na področju 0,08 Hz - 1 Hz in je bila enaka 73 %. Občutljivost je bila na istem področju najvišja in je bila enaka 84 %, prav tako je tudi specifičnost bila najboljša na tem področju in je imela vrednost 84 %.

- **Naivni Bayesov klasifikator**

Klasifikacijska točnost je bila maksimalna na področju 0,08 Hz - 1 Hz in je bila enaka 73 %. Občutljivost je bila najvišja na istem področju in je bila enaka 78 %. Specifičnost pa je bila najboljša na področju 1 Hz - 5 Hz in je imela vrednost 84 %.

- **Klasifikator z linearno diskriminantno analizo**

Klasifikacijska točnost je bila maksimalna na področju 2,2 Hz - 3,5 Hz in je bila enaka 73 %. Tudi specifičnostt je bila najboljša na istem področju in je imela vrednost 78 %. Občutljivost je bila najvišja na 0,08 Hz - 1 Hz in je bila enaka 73 %.

- **Klasifikator s kvadratno diskriminantno analizo**

Klasifikacijska točnost je bila maksimalna na vseh področji razen na področju 1 Hz - 5 Hz in je bila enaka 63 %. Specifičnost pa je bila najboljša na 3,5 Hz - 5 Hz področju in je imela vrednost 89 %. Občutljivost je bila najvišja na 0,08 Hz - 1 Hz in je bila enaka 57 %.

- **Metoda podpornih vektorjev**

Klasifikacijska točnost je bila maksimalna na področju 0,08 Hz - 1 Hz in je bila enaka 65 %. Tudi občutljivost je bila najvišja na istem področju in je bila enaka 73 %. Specifičnost je bila najboljša na področju 1 Hz - 2,2 Hz in je imela vrednost 78 %.

- **Odločitvena drevesa**

Klasifikacijska točnost je bila maksimalna na področjih 0,08 Hz - 1 Hz in 1 Hz - 5 Hz, njena vrednost je bila enaka 81 %. Občutljivost je bila

enaka 84 %. Specifičnost pa je bila najboljša na področjih 0,08 Hz - 1 Hz in 1 Hz - 5 Hz, njena vrednost je bila 78 %.

### 3.3.4 Klasifikacija, ali je bil posnetek zajet zgodaj ali pozno TE - TL. Posnetki so s terminskim porodom.

#### 3. kanal

TE - TL(3. kanal)	k-fold križna validacija(ang. k-fold cross validation)														
	0,08 Hz - 1 Hz			1 Hz - 2,2 Hz			2,2 Hz - 3,5 Hz			3,5 Hz - 5 Hz			1 Hz - 5 Hz		
	Se	Sp	CA	Se	Sp	CA	Se	Sp	CA	Se	Sp	CA	Se	Sp	CA
<i>k</i> -NN (št. sosedov: 3)	61,54	58,74	60,14	55,24	54,55	54,90	55,24	48,95	52,10	62,24	62,24	<b>62,24</b>	48,25	66,43	57,43
<i>k</i> -NN (št. sosedov: 4)	69,93	44,76	57,34	70,63	35,66	53,15	76,22	39,16	57,69	73,43	48,25	<b>60,84</b>	65,03	49,65	57,34
<i>k</i> -NN (št. sosedov: 5)	58,04	58,04	58,04	53,15	52,45	52,80	52,45	48,95	50,70	57,34	60,84	<b>59,09</b>	51,05	65,73	58,39
Bayes	66,43	58,04	<b>62,24</b>	50,35	59,44	54,90	36,36	76,22	56,29	23,08	86,01	54,55	69,93	39,16	54,55
LDA	67,13	55,94	<b>61,54</b>	53,85	58,74	56,29	51,75	63,64	57,69	60,14	48,25	54,20	48,25	58,74	53,50
QDA	66,43	58,04	<b>62,24</b>	55,24	57,34	56,29	44,76	67,83	56,29	36,36	66,43	51,40	69,23	37,76	53,50
SVM	67,13	55,94	<b>61,54</b>	53,15	56,64	54,90	46,15	60,84	53,50	35,66	51,75	43,71	61,54	41,26	51,40
Odločitveno drevo	79,72	81,12	<b>80,42</b>	78,32	75,52	76,92	<b>81,12</b>	76,22	78,67	80,42	77,62	79,02	71,33	83,92	77,62

Tabela 3.17: Navzkrižna validacija, št. podmnožic = 5, 3. kanal

- **Klasifikator z najbližjimi sosedi**

Klasifikacijska točnost je bila maksimalna na področju 3,5 Hz-5 Hz in je bila enaka 62 %. Občutljivost je bila najvišja na 2,2 Hz - 3,5 Hz in je bila enaka 76 %. Specifičnost pa je bila najboljša na 1 Hz - 5 Hz in je imela vrednost 66 %.

- **Naivni Bayesov klasifikator**

Klasifikacijska točnost je bila maksimalna na področju 0,08 Hz - 1 Hz in je bila enaka 62 %. Občutljivost je bila najvišja na 1 Hz - 5 Hz in je bila enaka 69 %. Specifičnost pa je bila najboljša na področju 3,5 Hz - 5 Hz in je imela vrednost 86 %.

- **Klasifikator z linearno diskriminantno analizo**

Klasifikacijska točnost je bila maksimalna na področju 0,08 Hz - 1 Hz in je bila enaka 61 %. Občutljivost je bila najvišja na istem področju



in je bila enaka 67 %. Specifičnost pa je bila najboljša na 2,2 Hz - 3,5 Hz področju in je imela vrednost 63 %.

- **Klasifikator s kvadratno diskriminantno analizo**

Klasifikacijska točnost je bila maksimalna na področju 0,08 Hz - 1 Hz in je bila enaka 62 %. Občutljivost je bila najvišja na 1 Hz - 5 Hz in je bila enaka 69 %. Specifičnost pa je bila najboljša na 2,2 Hz - 3,5 Hz področju in je imela vrednost 67 %.

- **Metoda podpornih vektorjev**

Klasifikacijska točnost je bila maksimalna na področju 0,08 Hz - 1 Hz in je bila enaka 61 %. Tudi občutljivost je bila najvišja na tem področju in je bila enaka 67 %. Specifičnost pa je bila najboljša na 2,2 Hz - 3,5 Hz in je imela vrednost 60 %.

- **Odločitvena drevesa**

Klasifikacijska točnost je bila maksimalna na področju 0,08 Hz - 1 Hz in je bila enaka 80 %. Občutljivost je bila najvišja na 2,2 Hz - 3,5 Hz in je bila enaka 81 %. Specifičnost pa je bila najboljša na 1 Hz - 5 Hz področju in je imela vrednost 83 %.

## 2. kanal

TE - TL(2. kanal)	k-fold križna validacija(ang. k-fold cross validation)														
	0,08 Hz - 1 Hz			1 Hz - 2,2 Hz			2,2 Hz - 3,5 Hz			3,5 Hz - 5 Hz			1 Hz - 5 Hz		
	Se	Sp	CA	Se	Sp	CA	Se	Sp	CA	Se	Sp	CA	Se	Sp	CA
<i>k</i> -NN (št. sosedov: 3)	62,94	67,13	<b>65,03</b>	55,94	62,94	59,44	51,05	48,95	50	55,94	52,45	54,20	55,24	55,24	55,24
<i>k</i> -NN (št. sosedov: 4)	76,22	53,85	<b>56,03</b>	72,73	51,75	62,24	69,23	34,97	52,10	72,73	39,16	55,94	67,13	37,06	52,10
<i>k</i> -NN (št. sosedov: 5)	65,03	69,93	<b>67,48</b>	60,14	65,73	62,94	51,75	51,75	51,75	58,74	53,85	56,29	50,35	60,14	55,24
Bayes	83,92	53,85	<b>68,88</b>	44,06	79,72	61,89	69,23	44,76	56,99	77,62	43,36	60,49	69,93	36,36	53,15
LDA	74,83	60,84	<b>67,83</b>	55,94	69,23	62,59	42,66	62,24	52,45	65,73	51,05	58,39	58,04	53,15	55,59
QDA	82,52	53,15	<b>67,83</b>	45,45	78,32	61,89	48,25	57,34	52,80	74,83	43,36	59,09	62,24	46,15	54,20
SVM	80,42	53,15	<b>67,83</b>	51,05	69,93	60,49	72,73	38,46	55,59	67,13	52,45	59,79	60,14	50,35	55,24
Odločitveno drevo	80,42	55,94	68,18	75,52	81,12	<b>78,32</b>	76,92	76,92	76,92	83,92	72,73	<b>78,32</b>	78,32	76,92	77,62

Tabela 3.18: Navzkrižna validacija, št. podmnožic = 5, 2. kanal

- **Klasifikator z najbližjimi sosedi**

Klasifikacijska točnost je bila maksimalna na področju 0,08 Hz - 1 Hz in je bila enaka 67 %. Občutljivost je bila na istem področju najvišja in je bila enaka 76 %, prav tako je tudi specifičnost bila najboljša na tem področju in je imela vrednost 69 %.

- **Naivni Bayesov klasifikator**

Klasifikacijska točnost je bila maksimalna na področju 0,08 Hz - 1 Hz in je bila enaka 68 %. Tudi občutljivost je bila najvišja na tem področju in je bila enaka 83 %. Specifičnost pa je bila najboljša na 1 Hz - 2,2 Hz in je imela vrednost 79 %.

- **Klasifikator z linearno diskriminantno analizo**

Klasifikacijska točnost je bila maksimalna na področju 0,08 Hz - 1 Hz in je bila enaka 67 %. Tudi občutljivost je bila najvišja na tem področju in je bila enaka 74 %. Specifičnost pa je bila najboljša na 1 Hz - 2,2 Hz in je imela vrednost 69 %.

- **Klasifikator s kvadratno diskriminantno analizo**

Klasifikacijska točnost je bila maksimalna na področju 0,08 Hz - 1 Hz in je bila enaka 67%. Tudi občutljivost je bila najvišja na tem področju in je bila enaka 82%. Specifičnost pa je bila najboljša na 1 Hz - 2,2 Hz in je imela vrednost 78%.

- **Metoda podpornih vektorjev**

Klasifikacijska točnost je bila maksimalna na področju 0,08 Hz - 1 Hz in je bila enaka 67 %. Tudi občutljivost je bila najvišja na tem področju in je bila enaka 80 %. Specifičnost pa je bila najboljša na 1 Hz - 2,2 Hz področju ter imela vrednost 69 %.

- **Odločitvena drevesa**

Klasifikacijska točnost je bila maksimalna na področjih 1 Hz - 2,2 Hz in 3,5 Hz - 5 Hz in je bila enaka 78 %. Tudi občutljivost je bila najvišja

na tem področju in je bila enaka 83 %. Specifičnost pa je bila najboljša na 1 Hz - 2,2 Hz in je imela vrednost 81 %.

## 1. kanal

TE - TL(1. kanal)	k-fold križna validacija(ang. k-fold cross validation)														
	0,08 Hz - 1 Hz			1 Hz - 2,2 Hz			2,2 Hz - 3,5 Hz			3,5 Hz - 5 Hz			1 Hz - 5 Hz		
	Se	Sp	CA	Se	Sp	CA	Se	Sp	CA	Se	Sp	CA	Se	Sp	CA
<i>k</i> -NN (št. sosedov: 3)	65,73	57,34	<b>61,54</b>	52,45	55,94	54,20	45,45	59,44	52,45	55,24	55,24	55,24	58,74	62,94	60,84
<i>k</i> -NN (št. sosedov: 4)	77,62	43,36	<b>60,49</b>	67,13	39,86	53,50	67,83	38,46	53,15	71,33	41,96	56,64	68,53	47,55	58,04
<i>k</i> -NN (št. sosedov: 5)	62,94	55,24	59,09	56,64	52,45	54,55	46,85	60,14	53,50	55,24	60,84	58,04	53,85	67,13	<b>60,49</b>
Bayes	68,53	53,15	<b>60,84</b>	32,17	74,83	53,50	49,65	65,03	57,34	67,83	43,36	55,59	49,65	64,34	56,99
LDA	68,53	51,05	59,79	56,64	47,55	52,10	57,34	61,54	59,44	62,24	48,25	55,24	63,64	60,13	<b>61,89</b>
QDA	70,63	51,05	<b>60,84</b>	34,97	67,83	51,40	58,04	61,54	59,44	68,53	43,36	55,94	55,24	62,94	59,09
SVM	67,83	54,55	<b>61,19</b>	38,46	66,43	52,45	51,05	58,74	54,9	47,55	56,64	52,10	60,14	60,84	60,49
Odločitveno drevo	84,62	77,62	<b>81,12</b>	74,83	79,77	77,27	80,42	77,62	79,02	75,52	77,62	76,57	76,92	77,62	77,27

Tabela 3.19: Navzkrižna validacija, št. podmnožic = 5, 1. kanal

- **Klasifikator z najbližjimi sosedi**

Klasifikacijska točnost je bila maksimalna na področju 0,08 Hz - 1 Hz in je bila enaka 61 %. Tudi občutljivost je bila najvišja na tem področju in je bila enaka 77 %. Specifičnost pa je bila najboljša na 1 Hz - 5 Hz ter imela vrednost 67 %.

- **Naivni Bayesov klasifikator**

Klasifikacijska točnost je bila maksimalna na področju 0,08 Hz - 1 Hz in je bila enaka 60 %. Tudi občutljivost je bila najvišja na tem področju in je bila enaka 68 %. Specifičnost pa je bila najboljša na 1 Hz - 2,2 Hz in je imela vrednost 74 %.

- **Klasifikator z linearno diskriminantno analizo**

Klasifikacijska točnost je bila maksimalna na področju 1 Hz - 5 Hz in je bila enaka 61 %. Občutljivost je bila najvišja na 0,08 Hz - 1 Hz področju in je bila enaka 68 %. Specifičnost pa je bila najboljša na 2,2 Hz - 3,5 Hz in je imela vrednost 61 %.

- **Klasifikator s kvadratno diskriminantno analizo**

Klasifikacijska točnost je bila maksimalna na področju 0,08 Hz - 1 Hz in je bila enaka 60 %. Tudi občutljivost je bila najvišja na tem področju in je bila enaka 70 %. Specifičnost pa je bila najboljša na 1 Hz - 2,2 Hz in je imela vrednost 67 %.

- **Metoda podpornih vektorjev**

Klasifikacijska točnost je bila maksimalna na področju 0,08 Hz - 1 Hz in je bila enaka 61 %. Tudi občutljivost je bila najvišja na tem področju in je bila enaka 67 %. Specifičnost pa je bila najboljša na 1 Hz - 2,2 Hz in je imela vrednost 66 %.

- **Odločitvena drevesa**

Klasifikacijska točnost je bila maksimalna na področju 0,08 Hz - 1 Hz in je bila enaka 81 %. Tudi občutljivost je bila najvišja na tem področju in je bila enaka 84 %. Specifičnost pa je bila najboljša na 1 Hz - 2,2 Hz in je imela vrednost 79 %.

Če povzamemo rezultate vsih klasifikacij med tremi kanali, lahko opazimo, da je klasifikacijska točnost bila v večini primerov najboljša na področju 0,08 Hz - 1 Hz, njene maksimalne vrednosti so se gibale med 56 % in 67 %, pri klasifikatorju odločitvenih dreves pa je bila okoli 81 %. Tudi občutljivost je bila v večini primerov najboljša na področju 0,08 Hz - 1 Hz. Njene maksimalne vrednosti so se gibale med 58 % in 84 %. Vrednost specifičnosti pa smo imeli v večini primerov na področju 1 Hz - 2,2 Hz, katerih vrednosti so bile med 66 % in 81 %. Najboljši rezultat pa je imel 2. kanal pri določevanju, ali je bil posnetek posnet zgodaj. Če primerjamo med vsemi tremi kanali in vsemi področji, je najslabše vrednosti doseglo področje 2,2 Hz - 3,5 Hz.

# Poglavje 4

## Zaključek

Ključne ugotovitve magistrskega dela so:

- Vzorčna entropija posnetkov s prezgodnjim porodom, ob uporabi spodnjega frekvenčnega območja 0.08 Hz - 1 Hz, je nižja od vzorčne entropije posnetkov s terminskim porodom. To velja tako za posnetke, zajete zgodaj, in za posnetke, zajete pozno v nosečnosti (glej sliki 3.1 in 3.6). Zaključimo lahko, da so na tem frekvenčnem področju posnetki s prezgodnjim porodom bolj napovedljivi in kažejo večjo regularnost kot posnetki s terminskim porodom.
- Za posnetke, ki so bili analizirani na frekvenčnem področju, višjem od 1 Hz, velja, da ima širše frekvenčno področje (od 1 Hz do 5 Hz) višjo vzorčno entropijo kot pa ožja frekvenčna področja. Iz tega sledi nižja napovedljivost oz. da je signal manj regularen. Drugi zaključek je, da višje ko je frekvenčno področje nad 1 Hz (1 Hz - 2,2 Hz, 2,2 Hz - 3,5 Hz, 3,5 Hz - 5 Hz), tudi vrednost vzorčne entropije narašča.
- Za posamezna frekvenčna področja, kjer je začetna frekvenca višja od 1 Hz, se vrednosti vzorčne entropije za posnetke s prezgodnjim in terminskim porodom zamenjajo. Vzorčna entropija posnetkov s prezgodnjim porodom postane višja kot vzorčne entropije posnetkov s terminskim

porodom. To velja tako za posnetke, zajete zgodaj, kot tudi za posnetke, zajete pozno v nosečnosti (glej sliki 3.1 in 3.2). To pomeni, da posnetki s prezgodnjim porodom, na višjih frekvencah filtriranja, postanejo manj regularni in bolj kaotični ter manj napovedljivi; posnetki s terminskim porodom pa ravno nasprotno - postanejo bolj napovedljivi in regularnejši.

- Statistična metoda ANOVA se je pokazala kot uporabno orodje, saj ta statistična metoda lepo pokaže, kateri razredi (kanali, frekvenčna področja, podatki) se bodo med seboj dobro klasificirali.
- Rezultati klasifikacij so pokazali naslednje:

#### 1. PE - TE:

- **3. kanal** Kot najboljši klasifikator se je izkazal odločitveno drevo, ki je čez vsa področja imel najvišjo vrednost. Kot najboljše frekvenčno področje za klasifikacijo bi bilo 1 Hz - 5 Hz, kjer je bila največkrat dosežena najvišja vrednost klasifikacijske točnosti. Vrednosti so se gibale med 68 % in 89 %. Tudi odločitveno drevo je tukaj doseglo zelo visoko vrednost 89 %.
- **2. kanal** Tudi v drugem kanalu se je kot najboljši klasifikator izkazal odločitveno drevo, pri katerem je bila maksimalna klasifikacijska točnost 83 %. Kot najboljša področja se je izkazalo 1 Hz - 5 Hz.
- **1. kanal** Odločitveno drevo je bil najboljši klasifikator in najboljši področji sta 3,5 Hz - 5 Hz in 1 Hz - 5 Hz, ki sta dali tudi najboljši rezultat klasifikacijske točnosti. Maksimalna vrednost je bila 87 %.

#### 2. PL - TL:

- **3. kanal** Kot najboljši klasifikator se je izkazalo odločitveno drevo, ki je čez vsa področja imelo najvišjo vrednost. Kot najboljši področji za klasifikacijo sta bili področji 2,2 Hz - 3,5

Hz in 1 Hz - 5 Hz, kjer je bila največkrat dosežena najvišja vrednost klasifikacijske točnosti. Ta se je gibala med 62 % in 74 %. Odločitveno drevo je tukaj doseglo vrednost 85 %.

- **2. kanal** Tudi v drugem kanalu se je kot najboljši klasifikator izkazal odločitveno drevo, ki je dobilo tudi maksimalno klasifikacijsko točnost vrednosti 86 %. Kot najboljše področje se je izkazalo področje 1 Hz - 5 Hz.
- **1. kanal** Odločitveno drevo je bil najboljši klasifikator, področje 2,2 Hz - 3,5 Hz in 1 Hz - 5 Hz pa sta dali najboljši rezultat klasifikacijske točnosti. Maksimalna vrednost je bila 86 %.

### 3. PE - PL:

- **3. kanal** Kot najboljši klasifikator se je izkazal odločitveno drevo, ki je čez vsa področja imel najvišjo vrednost. Kot najboljše frekvenčno področje za klasifikacijo je bilo področje 1 Hz - 2,2 Hz, kjer je bila največkrat dosežena največja vrednost klasifikacijske točnosti. Vrednosti se gibale med 55 % in 68%.
- **2. kanal** Tudi v drugem kanalu se je kot najboljši klasifikator izkazal odločitveno drevo, ki je dobilo maksimalno klasifikacijsko točnost vrednosti 84 %. Kot najboljše frekvenčno področje je bilo področje 1 Hz - 5 Hz, kjer je bila najvišja vrednost klasifikacijske točnosti.
- **1. kanal** Odločitveno drevo je bilo najboljši klasifikator, področje 0,08 Hz - 1 Hz pa ima najvišji rezultat klasifikacijske točnosti. Maksimalna vrednost je bila 81 %.

### 4. TE - TL:

- **3. kanal** Kot najboljši klasifikator se je izkazal odločitveno drevo, ki je čez vsa področja imel najvišjo vrednost. Kot najboljše frekvenčno področje za klasifikacijo je bilo področje 0,08 Hz - 1 Hz, kjer je bila največkrat dosežena največja vre-

dnost klasifikacijske točnosti. Vrednosti so se gibale med 59 % in 80%.

- **2. kanal** Tudi v drugem kanalu se je kot najboljši klasifikator izkazal odločitveno drevo, ki je tu dobil tudi maksimalno klasifikacijsko točnost vrednosti 78 %. Kot najboljše frekvenčno področje za klasifikacijo je bilo področje 0,08 Hz - 1 Hz, kjer je bila največkrat dosežena najvišja vrednost klasifikacijske točnosti. Vrednosti so se gibale med 65 % in 68 %.
- **1. kanal** Odločitveno drevo je bil najboljši klasifikator in področje 0,08 Hz - 1 Hz ima najboljši rezultat klasifikacijske točnosti. Maksimalna vrednost je bila 81 %.

Iz tega lahko sklepamo, da je najboljše področje za ločevanje tistih posnetkov, ki so bili posneti zgodaj, s prezgodnjim ali terminskim porodom, področje 1 Hz - 5 Hz, za večino klasifikatorjev in za tretji kanal. Klasifikator odločitveno drevo je dal najboljše rezultate na področju 1 Hz - 2,2 Hz. Najslabše področje je 2,2 Hz - 3,5 Hz. Za ločevanje tistih posnetkov, ki so bili posneti pozno in s prezgodnjim ali terminskim porodom, pa je najboljše območje 2,2 Hz - 3,5 Hz, kar je, zanimivo, ravno nasprotno kot pri posnetkih, ki so bili posneti zgodaj. Pri klasifikaciji, ali je bil posnetek zajet zgodaj ali pozno, sta se na posnetkih s terminskim porodom najbolje izkazala področje 0,08 Hz - 1 Hz in 2. kanal. Pri klasifikaciji, ali je bil posnetek zajet zgodaj ali pozno, na posnetkih s prezgodnjim porodom, pa se je za najboljšega izkazal 2. kanal.

- Klasifikator odločitveno drevo se je izkazal kot najboljši rezultati med vsemi klasifikatorji.

V drugih obstoječih tovrstnih študijah za klasifikacijo posnetkov podatkovne baze TPEHG DB s terminskim in prezgodnjim porodom so se avtorji osredotočili na frekvenčno področje od 0,34 Hz do 1,0 Hz [2] in na frekvenčno področje od 0,3 Hz do 3 Hz [22] ter poleg vzorčne entropije uporabili še druge značilke signalov in dodatno klinično informacijo o nosečnostih.



V delu [2] so avtorji poleg značilnk vzorčne entropije za klasifikacijo uporabili še naslednje značilke: srednjo kvadratno vrednost signala, frekvenco vrha močnostnega spektra in mediano frekvenco močnostnega spektra. Doseženi rezultati klasifikacije z uporabo odločitvenega drevesa so bili: občutljivost 90.4 % in specifičnost 82.7 %. Ob uporabi še dodatne klinične informacije o nosečnostih (starost, število predhodnih nosečnosti, predhodni splavi, teža, pritisk, sladkorna bolezen, krvavenje v prvem in drugem trimesstru, položaj ploda, koničenje cerviksa in kajenje) so bili rezultati klasifikacije višji: občutljivost 96.7 % in specifičnost 90.0 %.

V delu [22] so avtorji prav tako poleg vzorčne entropije uporabili še druge značilke: srednjo kvadratno vrednost signala, frekvenco vrha močnostnega spektra, mediano frekvenco močnostnega spektra ter dodatno klinično informacijo o nosečnostih. Dinamična nevronska mreža je rezultirala v naslednje zmogljivosti: občutljivost 89 %, specifičnost 91 % in klasifikacijska točnost 90 %.

V našem magistrskem delo smo se namenoma osredotočili na značilke vzorčne entropije in frekvenčno področje od 1 Hz do 5 Hz, saj smo želeli preveriti vpliv in pomembnost tega področja na potek nosečnosti. Doseženi rezultati klasifikacije (odločitveno drevo) posnetkov s terminskim in prezgodnjim porodom so ob uporabi tega frekvenčnega področja (od 1 Hz do 2,2 Hz) in samo vzorčne entropije, brez uporabe drugih značilnk signalov ter brez uporabe dodatne klinične informacije o nosečnostih naslednji: občutljivost 88,8 %, specifičnost 81,8 % in klasifikacijska točnost 85,3 % (glej tabelo 4.1).

Ti rezultati klasifikacije so povsem primerljivi doseženim rezultatom klasifikacij sorodnih raziskav [22, 2].

Večina raziskovalcev, z redkimi izjemami [6, 22], uporablja za klasifikacijo posnetkov s terminskim in prezgodnjim porodom frekvenčno področje od 0,3Hz do 1 Hz. Naši rezultati kažejo, da daje frekvenčno področje nad 1Hz boljše rezultate klasifikacije. V frekvenčnem področju od 0.08Hz do 1Hz smo namreč dosegli nižje zmogljivosti klasifikacije (občutljivost 81,8 %, spe-

PE - TE(3. kanal)	k-fold navzkrižna validacija(ang. k-fold cross validation)														
	0,08 Hz - 1 Hz			1 Hz - 2,2 Hz			2,2 Hz - 3,5 Hz			3,5 Hz - 5 Hz			1 Hz - 5 Hz		
	Se	Sp	CA	Se	Sp	CA	Se	Sp	CA	Se	Sp	CA	Se	Sp	CA
<i>k</i> -NN (št. sosedov: 3)	64,34	65,73	65,03	62,94	63,64	63,29	61,54	48,25	54,90	73,43	53,15	63,29	72,73	63,64	<b>68,18</b>
<i>k</i> -NN (št. sosedov: 4)	78,32	46,85	62,59	83,22	44,76	63,99	76,92	33,57	55,24	84,62	44,06	64,34	86,71	54,55	<b>70,63</b>
<i>k</i> -NN (št. sosedov: 5)	65,03	63,64	64,64	73,43	62,24	67,83	62,94	51,75	57,34	72,73	53,85	63,29	78,32	65,03	<b>71,68</b>
Bayes	77,62	55,94	66,78	51,75	77,62	64,69	41,26	72,73	56,99	39,86	77,62	57,74	86,01	53,85	<b>69,93</b>
LDA	58,04	69,23	63,64	65,73	55,94	60,84	57,34	60,84	59,09	45,45	67,83	56,64	79,02	59,44	<b>69,23</b>
QDA	75,52	58,74	67,13	55,94	67,13	61,54	44,76	67,83	56,29	41,26	77,62	59,44	86,71	50,35	<b>68,53</b>
SVM	67,83	66,43	67,13	60,84	60,14	60,49	53,15	64,34	58,74	53,85	53,85	53,85	76,92	60,14	<b>68,53</b>
Odločitveno drevo	81,82	81,82	81,82	88,81	81,82	<b>85,31</b>	78,32	78,32	78,32	81,82	75,52	78,67	<b>88,81</b>	79,02	83,92

Tabela 4.1: Navzkrižna validacija, št. podmnožic = 5, 3. kanal

cificnost 81,8 % in klasifikacijska točnost 81,8 %) od tistih v frekvenčnem področju od 1 Hz do 2,2 Hz (glej tabelo 4.1).

Rezultati tega dela nakazujejo, da se v frekvenčnem področju od 1 Hz do 5 Hz verjetno skriva še en fiziološki mehanizem maternice, ki pomembno vpliva na potek nosečnosti. Ocenjujemo, da odsotnost tega fiziološkega mehanizma povečuje nevarnost prezgodnjega poroda.

# Literatura

- [1] Dostopno na: [www.medenosrce.net/component/attachments/download/5057](http://www.medenosrce.net/component/attachments/download/5057)
- [2] Fergus P, Cheung P, Hussain A, Al-Jumeily D, Dobbins C and Iram S (2013) Prediction of preterm deliveries from EHG signals using machine learning. PLoS ONE, 8(10):e77154.
- [3] Maner WL, Garfield RE, Maul H, Olson G and Saade G (2003) Predicting term and preterm delivery with transabdominal uterine electromyography. Obstet Gynecol, 101(6):1254–1260.
- [4] de Lau H, Rabotti C, Bijloo R, Rooijackers MJ, Mischi M and Oei SG (2013) Automated conduction velocity analysis in the electrohysterogram for prediction of imminent delivery: a preliminary study. Comput Math Method M, 2013:627976, 7 pages.
- [5] Rabotti C, Mischi M, Oei SG and Bergmans JWM (2010) Noninvasive estimation of the electrohysterographic action-potential conduction velocity. IEEE Trans Biomed Eng 57(9):2178-2187.
- [6] Fele-Žorž G, Kavšek G, Novak-Anatolič Ž and Jager F (2008) A comparison of various linear and non-linear signal processing techniques to separate uterine EMG records of term and pre-term delivery groups. Med Biol Eng Comput, 46(9):911–22.
- [7] Goldberger AL, Amaral LAN, Glass L, Hausdorff JM, Ivanov PC, Mark RG, Mietus JE, Moody GB, Peng C-K and Stanley HE (2000) Physi-

- oBank, PhysioToolkit, and PhysioNet: components of a new research resource for complex physiologic signals. *Circulation* 101(23):e215-e220.
- [8] Proakis JG, Manolakis DK, Digital signal processing, fourth edition, 2014, Pearson Education limited
- [9] Costa MD, Peng C-K and Goldberger AL (2008) Multiscale Analysis of Heart Rate Dynamics: Entropy and Time Irreversibility Measures. *Cardiovasc Eng* 8:88–93.
- [10] Dostopno na: [https://en.wikipedia.org/wiki/Sample\\_entropy](https://en.wikipedia.org/wiki/Sample_entropy)
- [11] Fele-Žorž G (2010) Nelinearna analiza signalov elektromiograma maternice za napovedovanje prezgodnjega poroda. Doktorska disertacija
- [12] Dostopno na: <http://www.dlib.si/stream/URN:NBN:SI:DOC-88WDYLDL/fdfe2c6b-9078-4197-9286-ab38aadfe6fa/PDF>
- [13] F.Jager Electromyogram and predicting pre-term delivery, Predavanje
- [14] Dostopno na: <http://www.statistik.si/storitve/statisticne-analize-testi/anova-analiza-variance/>
- [15] Dostopno na: <http://radio.feld.cvut.cz/matlab/toolbox/stats/anova1.html>
- [16] Igor Kononenko (2005) Strojno učenje. ISBN 961-6209-52-3
- [17] Dostopno na: [https://en.wikipedia.org/wiki/Linear\\_discriminant\\_analysis](https://en.wikipedia.org/wiki/Linear_discriminant_analysis)
- [18] Dostopno na: [https://en.wikipedia.org/wiki/Quadratic\\_classifier](https://en.wikipedia.org/wiki/Quadratic_classifier)
- [19] Dostopno na: [https://en.wikipedia.org/wiki/Support\\_vector\\_machine](https://en.wikipedia.org/wiki/Support_vector_machine)

- 
- [20] Dostopno na: [https://en.wikipedia.org/wiki/Classification\\_rule](https://en.wikipedia.org/wiki/Classification_rule)
- [21] Dostopno na: <https://www.cs.cmu.edu/~schneide/tut5/node42.html>
- [22] Hussain AJ, Fergus P, Al-Askar H, Al-Jumeily D and Jager F (2015) Dynamic neural network architecture inspired by the immune algorithm to predict preterm deliveries in pregnant women. *Neurocomputing*, 151:963–974.