




Geneze, význam a zpracování kardiotokogramu

Analýza signálů II

Michal Huptych, Jiří Spilka

14. 3. 2022

Srdeční oběh



Fyziologie plodu



- vývoj plodu trvá zhruba 40 týdnů
- vývoj komplexních systému: kardiovaskulární atd.
- srdce začíná fungovat zhruba od 4 týdnů (65 BPM)
 - v průběhu těhotenství srdeční frekvence roste
 - po porodu začíná klesat




Jiří Spilka: Zpracování a analýza KTG

Energetický metabolismus




- Placenta
 - výměna O₂ a CO₂
 - překvapivě málo je známo, např. o autonomní funkci placenty
- Aerobní a anaerobní metabolismus



Hypoxemie a reakce na ni



- Efektivnější využívání kyslíku
 - zvýšení počtu erytrocytů).
- Redukce pohybové aktivity.
- Omezení růstu pokud přetrvává delší čas (týdny)




Jiří Spilka: Zpracování a analýza KTG

Hypoxie a reakce na ni



- Redistribuce krve
 - centralizace oběhu.
- Aktivace sympatiku a vyplavení stresových hormonů.
- Centrální orgány jsou v bezpečí
 - žádné poškození (několik hodin).




Jiří Spilka: Zpracování a analýza KTG

Asfyxie a reakce na ni



- Nejtěžší a kritický stupeň.
- Hrozí selhání centrálních orgánů.
- Produkce energie je nedostatečná.
- Plod je schopen kompenzovat řádově minuty
 - nutnost zákroku
 - Císařský řez




Jiří Spilka: Zpracování a analýza KTG

Kardiotokogram





- Srdeční frekvence plodu (FHR), kontrakcí dělohy (TOCO)
- Odráží změny chování plodu, reakce na hypoxii atd.



Jiří Spilka: Zpracování a analýza KTG

Měření FHR


- interní/externí měření
 - externí (ultrazvuk)
 - interní (skalpová elektroda)



Kardiotokogram – abdominální




- Měření pomocí elektrod na břicho matky
- Signál je směsí
 - mateřského EKG
 - fetálního EKG
 - kontrakcí dělohy





- Hodnocení do skupin
 - Normální
 - Suspektní
 - Patologický
- Velká inter- a intra observer variabilita
- Inter- shoda na hodnocení mezi doktory 70%
- intra- shoda opakovaného hodnocení záznamu jedním doktorem - 80%
- Hodnocení KTG je subjektivní
 - záleží na zkušenostech doktorů
 - záleží na případech, které viděli (pouze normální porody)

Vizuální analýza KTG




Lukáš Hruban, Václav Chudáček: Využití metod umělé inteligence pro zpracování dat v porodnictví

Hodnocení v klinické praxi



- Hodnocení KTG společně s klinickými informacemi



Hodnocení v klinické praxi



- ❖ FHR je měřeno jednou ze dvou metod: USG nebo fECG
- ❖ Sledovány znaky hypoxie
- ❖ Rozhodnutí prováděno na základě FHR a klinických dat
- ❖ Výstup:
 - ❖ Zdravé dítě
 - ❖ Správně použitá intervence císařského řezu (20-50% v ČR)
 - ❖ Opomenuté "patologie" (1-3%) → závažné případy mohou způsobit neurologické poškození, jako je mozková obrna atd.

Klasifikace FIGO 1986




	Fyziologický	Suspektní	Patologický
Bazální frekvence (tepy/minutu)	110 - 150	150 – 170 100 – 110	> 170 < 100
Variabilita (tepy/minutu)	10 – 25	5 – 10 po dobu ≥ 40 min > 25	< 5 tepů/min po dobu ≥ 40 minut Sinusoida po dobu ≥ 20 minut
Decelerace (tepy/minutu)	Časné decelerace (v pozdní fázi I. doby porodní, které nemají větší amplitudu než 50 tepů/min.)	- Variabilní decelerace – pokles o méně než 60 tepů/min. v trvání méně než 60 s - Přejídná krátkodobá bradykardie (pod 100 tepů/min. v trvání 3 min., pod 80 tepů/min. v trvání 2 minut)	- Závažné opakující se rané decelerace (o amplitudě více než 50 tepů/min.) - Závažné variabilní decelerace, pozdní decelerace
Akcelerace	≥ 2 během 20 minut	Nepřítomny po dobu ≥ 40 minut	


KTG FIGO features



- Oficiální porodnické směrnice pro hodnocení KTG
- Definice Akcelerací/Decelerací
- Detekce Baseline na základě hodnocení histogramu



Anotátor KTG



Hodnocení KTG, věrohodné?



- ❖ Hodnocení do skupin: normální, suspektní, patologický
- ❖ Velká inter- a intra observer variabilita
- ❖ inter- shoda na hodnocení mezi doktory - 70%
- ❖ intra- shoda opakovaného hodnocení záznamu jedním doktorem - 80%
- ❖ hodnocení KTG je subjektivní
 - ◆ záleží na zkušenostech doktorů
 - ◆ záleží na případech, které viděli (pouze normální porody)

Hodnocení KTG, věrohodné?



- ❖ Žaloby za zanedbání péče
- ❖ V USA několik mimosoudních vyrovnání: \$200 000 000
 - ◆ obrovská eskalace operativních porodů (císařských řezů)
 - ◆ snaha "něco" udělat s hodnocením KTG
- ❖ Konzervativní: zachovat současný stav
- ❖ Na hraně: opustit loď (KTG)
- ❖ Možné zlepšení:
 - ◆ Vylepšit doporučení pro hodnocení KTG (snížit variabilitu)
 - ◆ Lepší edukaci lékařů
 - ◆ **Automatické hodnocení KTG**


Automatické hodnocení KTG



- ❖ Identifikace plodu s rizikem acidózi.
- ❖ Snížení variability hodnocení lékařů.
- ❖ Snížení falešně pozitivních rozhodnutí
 - ◆ Zbytečné operativní zákroky
- ❖ Definovat zdroj dat a metodiku automatického zpracování
- ❖




Počítačová analýza - metodika



Václav Chudáček, Automatic Analysis of Intrapartum Fetal Heart Rate, Doctoral thesis, Faculty of Electrical Engineering, CTU in Prague, 2011

CTU-UHB database



- ❖ Data z Ob&Gyn kliniky FN Brno
- ❖ USG a STAN data
- ❖ Pouze donošené plody (gest. týden > 34)
- ❖ První open-access CTG database
- ❖ společný základ pro porovnání algoritmů
- ❖ 508 normálních: $\text{pH} > 7.05$
- ❖ 44 patologických: $\text{pH} \leq 7.05$

Výsledky klasifikace



Feature set	All in [%]	NaiveBayes	SVM	C4.5 Tree
FIGO-like	Sensitivity	66.0	50.0	55.3
	Specificity	68.3	79.7	65.9
	Precision	61.4	65.3	55.3
	F-measure	63.6	56.6	55.3
	AUC	0.70	0.65	0.60
HRV-based	Sensitivity	44.7	30.0	59.6
	Specificity	82.1	93.5	69.9
	Precision	65.6	77.8	60.2
	F-measure	53.2	43.1	59.9
	AUC	0.71	0.60	0.60
Nonlinear	Sensitivity	68.1	66.0	77.7
	Specificity	78.0	79.7	64.2
	Precision	70.3	71.3	62.4
	F-measure	69.2	68.5	69.2
	AUC	0.77	0.73	0.67
FS-Complete	Sensitivity	71.3	69.1	73.4
	Specificity	78.0	76.4	66.7
	Precision	71.4	69.1	62.7
	F-measure	71.3	69.1	67.6
	AUC	0.76	0.73	0.68

Databáze, Lyon, FR





- ❖ Spolupráce:
 - ◆ Muriel Doret (HFME, Lyon, FR)
 - ◆ Patrice Abry (ENS Lyon, FR)
- ❖ Záznamy z každodenní klinické praxe, Lyon, Francie
- ❖ Unikátní: velikost, dokumentace a kvalita záznamů
 - ◆ 1251 – normálních: $\text{pH} > 7.05$
 - ◆ 37 – patologických: $\text{pH} \leq 7.05$
- ❖ Klinický benchmark

	Sensitivita (SE)	Specifita (SP)
fetální hypoxia	.49	.78

Předzpracování





- ❖ Převzorkování: neekvidistantní na ekvidistantní
- ❖ RR intervaly: časová vzdálenost jednotlivých beatů
- ❖ RR intervaly: $T_k = t_k - t_{k-1}$ [ms]
- ❖ Beat-per-Minute časová řada: $X(t) = \text{interp}(t_k; 60000/T_k)$



Předzpracování



- ❖ Obecně 10-20 % signálu artefakty
- ❖ Nejvíce ke konci porodu (pohybové artefakty)
- ❖ spline interpolace mezer – pouze chybějící úseky $t < 5s$



Klinické (morfologické příznaky)




❖ bazální srdeční frekvence – baseline

- detekce pomocí filtrace
- detekce pomocí histogramu

❖ akcelpace

❖ decelerace



Klinické (morfologické příznaky)




❖ Baseline:

- plovoucí baseline $B(t)$
- lokální charakterizace v průběhu 20 min. $B(t) \approx \beta_0 + \beta_1 t$

❖ Decelerace:

- $MAD_{dtrd} = MAD(X(t) - B(t))$





❖ Lineární:

- statistické momenty (průměr, std, šikmost, špičatost)
- krátkodobá a dlouhodobá variabilita
- spektrální analýza
- Hurstův parameter (spolupráce Patrice Abry)


❖ Nelineární:

- Entropie (spolupráce S. Roux, N. Garnier) Entropie
 - Scattering transform (spolupráce S. Mallat)
 - Multifraktální analýza (s Patrice Abry) MF
 - p-leaders (s Roberto Leonarduzzi)
- snaha analyzovat FHR do detailu a najít vhodný popis FHR, který se zatím nepoužívá v praxi

Analýza jednotlivých příznaků



- Výpočet příznaků z posledních 20 minut před porodem
- Korelace příznaků



Analýza jednotlivých příznaků



- ❖ Statistické testování
- ❖ ROC křivka
 - ❖ stanovení cut-off hodnoty
- ❖ Dobré výsledky pro MAD_{dtrd} , H , nebo c_1
- ❖ Velmi malá specifická
- ❖ Kombinace ve strojovém učení


name	AUC	SE	SP
β_0	.65	.70	.58
$\#acc$	.52	.70	.19
$\#dec$	.57	.70	.40
MAD_{dtrd}	.73	.70	.63
E_{LF}	.56	.70	.30
E_{HF}	.52	.70	.30
H	.71	.70	.60
h_{min}	.68	.70	.52
c_1	.70	.70	.54
c_2	.61	.70	.38
benchmark		.49	.78

(vybraných 10 příznaků)

Support Vector Machines (SVM)




- Jeden z nejlepších algoritmů současnosti
- Snadné použití, dobrá první volba klasifikátoru
- SVM hledá $\mathbf{w}$ pro danou třídu y_i a příznaky $\mathbf{x}_i$, $i = 1; \dots; N$
- Pouze zlomek N je použit jako support vektor – řídkost (sparsity)



Support Vector Machines (SVM)



$$(\hat{\mathbf{w}}, \hat{b}) \in \arg \min_{\mathbf{w} \in \mathbb{R}^p, b \in \mathbb{R}} \|\mathbf{w}\|_2^2 + C \sum_{i=1}^N \max(0, 1 - y_i(\mathbf{w}^\top \mathbf{x}_i + b))$$






❖ Problémy

- Velký překryv normálních a patologických případů
- řídkost v datech
- Interpretace obtížná
- Jaké příznaky přispívají ke klasifikaci? Všechny!
Protože $|w_j| > 0; \forall j$
- $\mathbf{w} \sim$ Normální rozdělení
- Vyměníme řídkost v datech za řídkost v příznakovém prostoru

$$(\hat{\mathbf{w}}, \hat{b}) \in \arg \min_{\mathbf{w} \in \mathbb{R}^p, b \in \mathbb{R}} \|\mathbf{w}\|_1 + C \sum_{i=1}^N \max(0, 1 - y_i(\mathbf{w}^\top \mathbf{x}_i + b))^2$$



- 20 minut před porodem
- Výsledky pro různé hodnoty regularizujícího parametru C




- Optimal výsledky pro $C = 2^{-8.5}$ (zvětšení C snížení sparsity)
 - **SE = .73, SP = .75** vs SE = .49, SP = .78 (benchmark)
- Příznaky MAD_{dtrd} , H a β_0
 - typické příznaky používané v klinické praxi

Trajektorie v příznakovém prostoru



- $\mathbf{w}$; b – použito z posledních 20 min.
- 120 min. před porodem
- 20 min. plovoucí okna t_k s 5 min. překryvem
- Vzdálenost k rozdělovací nadrovině:
$$d(t_k) = y(\mathbf{w}^T \mathbf{x}(t_k) + b)$$
 - $d(t_k) < 0$ – normální oblast
 - $d(t_k) > 0$ – patologická oblast
 - r – čas strávený mimo normální oblast


$$r = \sum_t d(t_k)$$



Normální a patologický případ




■ Normální případ



(normální oblast, patologická oblast)

■ Patologický případ





- Kompletní metodologický postup:
 - Data (CTU-UHB (open access), Lyon, France)
 - Předzpracování
 - Návrh příznaků (zachycení charakteristických vlastností)
 - Analýza příznaků
 - Strojové učení (např. Sparse SVM)
 - Evaluace výsledků