



Biosignály a jejich zpracování

Strojové učení s příklady

ČVUT, 2016

Proces zpracování



Předzpracování – odstranění

šumu

Detekce artefaktů

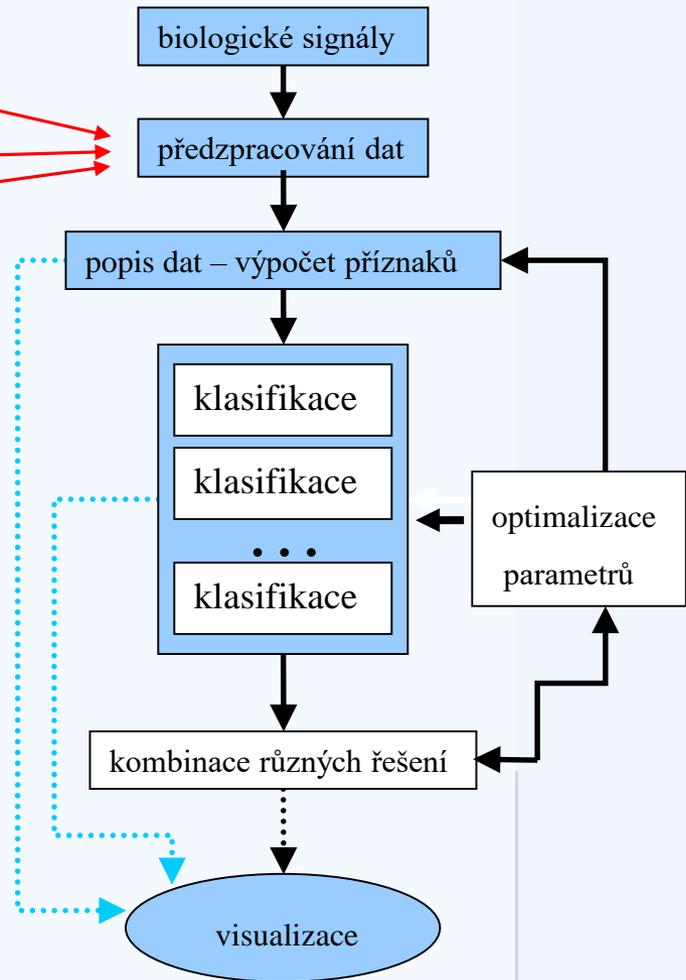
Segmentace signálu

Transformace

Extrakce příznaků

Klasifikace

Shlukování



Příznaky



- ❖ Příznakový nebo strukturní popis rozpoznávaných (klasifikovaných) objektů – obecně hovoříme o vytváření symbolických popisů objektů
 - ◆ nazýváme popisem objektů jejich **obrazy**.
- ❖ Tedy: **Obraz objektu = symbolický popis objektu**
- ❖ Stejně jako metody rozlišujeme i obrazy (symbolické popisy objektů)
 - ◆ tvořené příznaky (vektory příznaků)
 - ◆ strukturní
- ❖ Obsahují-li obrazy objektů n složek, pak všechny rozpoznávané (klasifikované) obrazy tvoří obrazový prostor úlohy.
- ❖ Jednotlivé klasifikační třídy objektů získáme rozkladem obrazového prostoru úlohy na R klasifikačních tříd.

Příznakové rozpoznávání

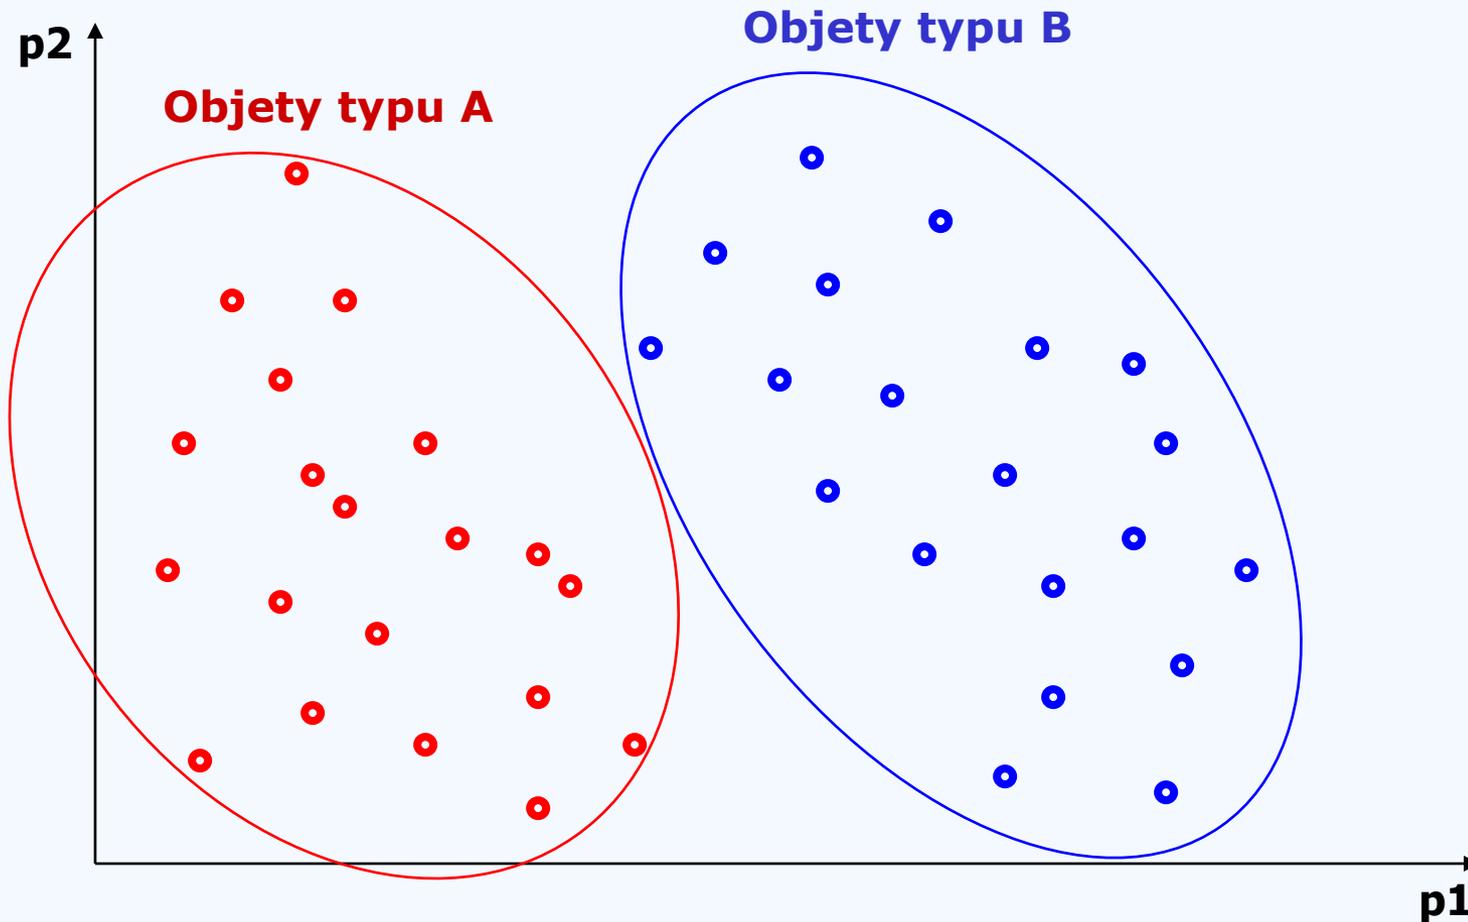


- ❖ Objekt typu A a objekt typu B jsou popsány množinou příznaků $P = \{p_1, p_2\}$
- ❖ Počet objektů typu A i B je 10
- ❖ Tzn. množina P má 2 položky a máme 20 měření

- ❖ Úloha je odlišit objekt A od objektu B
- ❖ Zajímá nás vzájemné uspořádání objektů A a B tj. závislost příznaků z množiny objektů typu A a z množiny objektů typu B.

Příznakové rozpoznávání

❖ Graficky se tato závislost dá znázornit takto:



Rozpoznávání a klasifikace

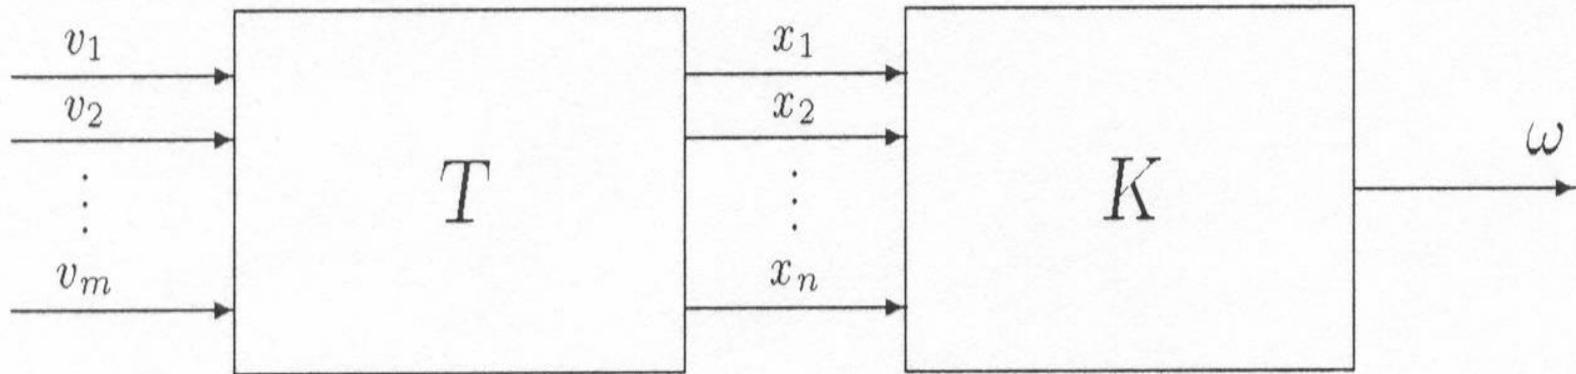


- ❖ *Rozpoznávání* chápeme jako úlohu, při které objekty zařazujeme do tříd podle jejich společných vlastností tak, že objekty vzájemně si podobné zařazujeme do stejné třídy.
- ❖ Rozlišujeme:
 - ◆ klasifikaci – zařazujeme do předem známého, pevného počtu tříd
 - ◆ rozpoznávání – počet tříd není předem znám a třídy identifikujeme až během vlastního rozpoznávání

Rozpoznávání a klasifikace



❖ Obecná klasifikační úloha



T ... transformace vstupních charakteristik – vytvoření obrazu

K ... klasifikátor

\mathbf{v} ... vektor vstupních charakteristik

\mathbf{x} ... obraz (symbolický popis) objektu

ω ... indikátor třídy

Klasifikace



- ❖ V praxi se takto ideální případ nevyskytuje
- ❖ Běžný popis obsahuje desítky až stovky příznaků
- ❖ Je třeba příznaky selektovat
- ❖ Důležitý je výběr typu klasifikátoru
- ❖ Celý proces je iterační

Nejdůležitější podmínkou výstupu je nalezení co **nejobecnějších** pravidel (klasifikačních parametrů)

Rozhodovací pravidlo



- ❖ Rozhodovací pravidlo
 - ◆ klasifikátor přiřazuje obraz do klasifikační třídy
- ❖ Můžeme obecně definovat jako skalární funkci vektorového argumentu

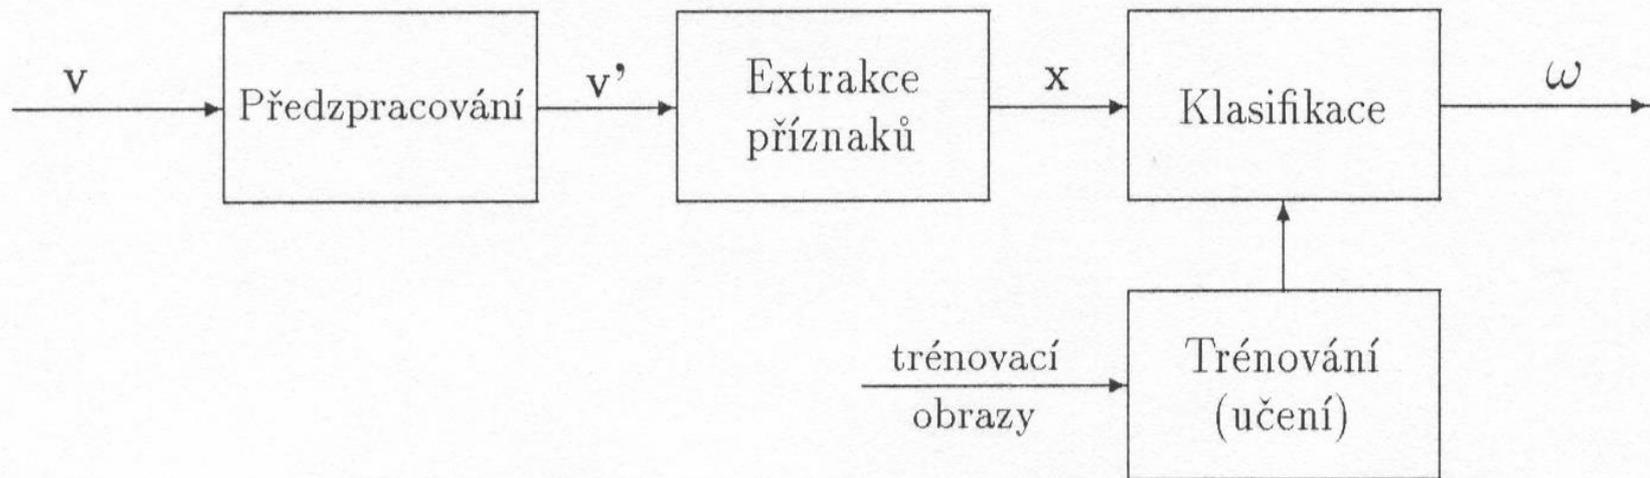
$$\omega = d(\mathbf{x})$$

- ❖ Přesnější vyjádření rozhodovacího pravidla, které zohledňuje i nastavení klasifikátoru \mathbf{q}

$$\omega = d(\mathbf{x}, \mathbf{q})$$

- ❖ Nastavení klasifikátoru se provádí trénováním neboli učením.
- ❖ Rozlišujeme učení s učitelem, kdy klasifikátoru předkládáme obrazy, u nichž známe jejich příslušnost k třídě, a učení bez učitele, kdy správné zařazení do klasifikačních tříd neznáme.

Příznakové metody rozpoznávání



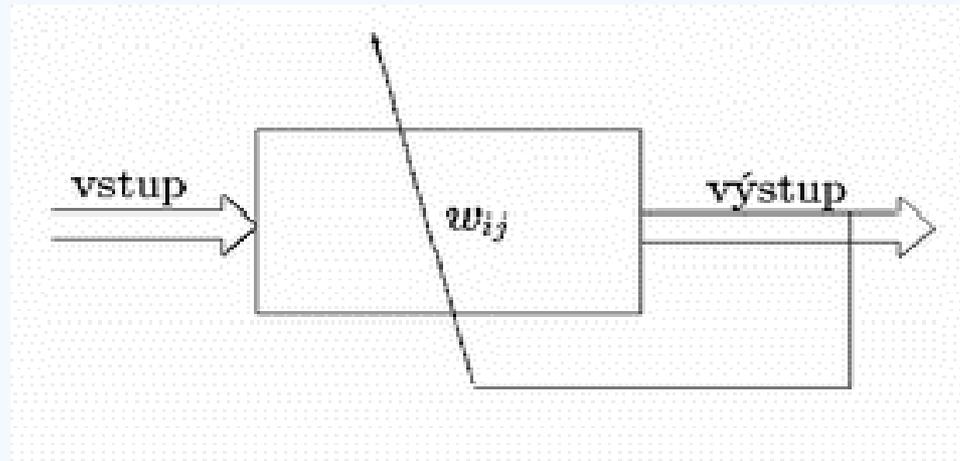
- ❖ Obrazy objektů reprezentovány vektory příznaků x , zařazování obrazů do tříd
- ❖ klasifikace deterministickým nebo stochastickým rozhodovacím pravidlem ve tvaru

$$\omega = d(x), \text{ resp. } \omega = d(x, q),$$

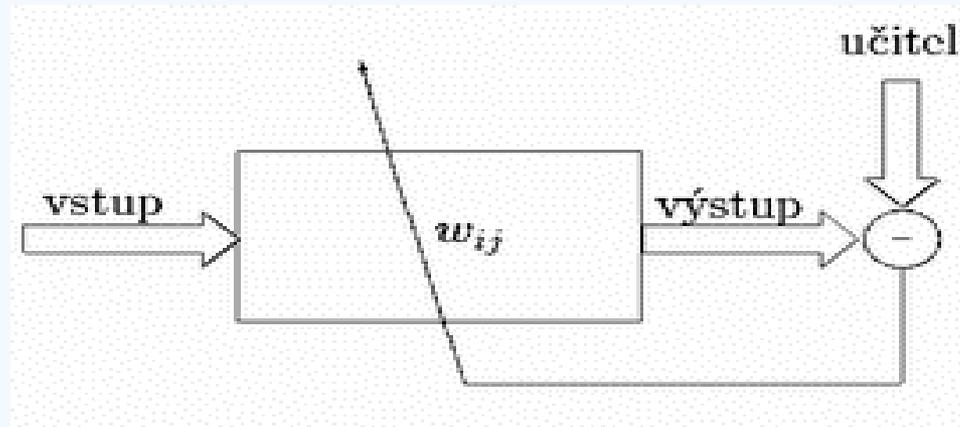
- ◆ kde x je klasifikovaný obraz objektu,
- ◆ q je vektor nastavení klasifikátoru.

Učení

❖ Bez učitele



❖ S učitelem



Nastavení klasifikátoru učním



- ❖ Máme k dispozici trénovací množinu
 - ❖ Apriorní pravděpodobnost $P(w_i)$ lze nahradit relativní četností výskytu vektoru příznaků z jednotlivých tříd v trénovací množině
 - ❖ Při odhadu hustoty pravděpodobnosti máme dva případy
 - ◆ Známe tvar hustoty, ale neznáme některé parametry
 - ◆ Neznáme tvar hustoty pravděpodobnosti
 - ❖ Vycházíme-li ze známého tvaru hustoty pravděpodobnosti a odhadujeme pouze parametry mluvíme o *parametrických metodách*
 - ❖ Ve druhém případě mluvíme o *neparametrických metodách*
- ❖ <http://home.zcu.cz/~friesl/hpsb/ml.html>

Trénovací a testovací množina



❖ Trénovací množina

- ◆ Množina objektů, u kterých zná klasifikátor správné přiřazení ke třídám
- ◆ Učení probíhá iterativně.
- ◆ Klasifikátoru jsou předkládány vzory z této množiny dokud nedosáhne jisté předem definované trénovací přesnosti klasifikace.

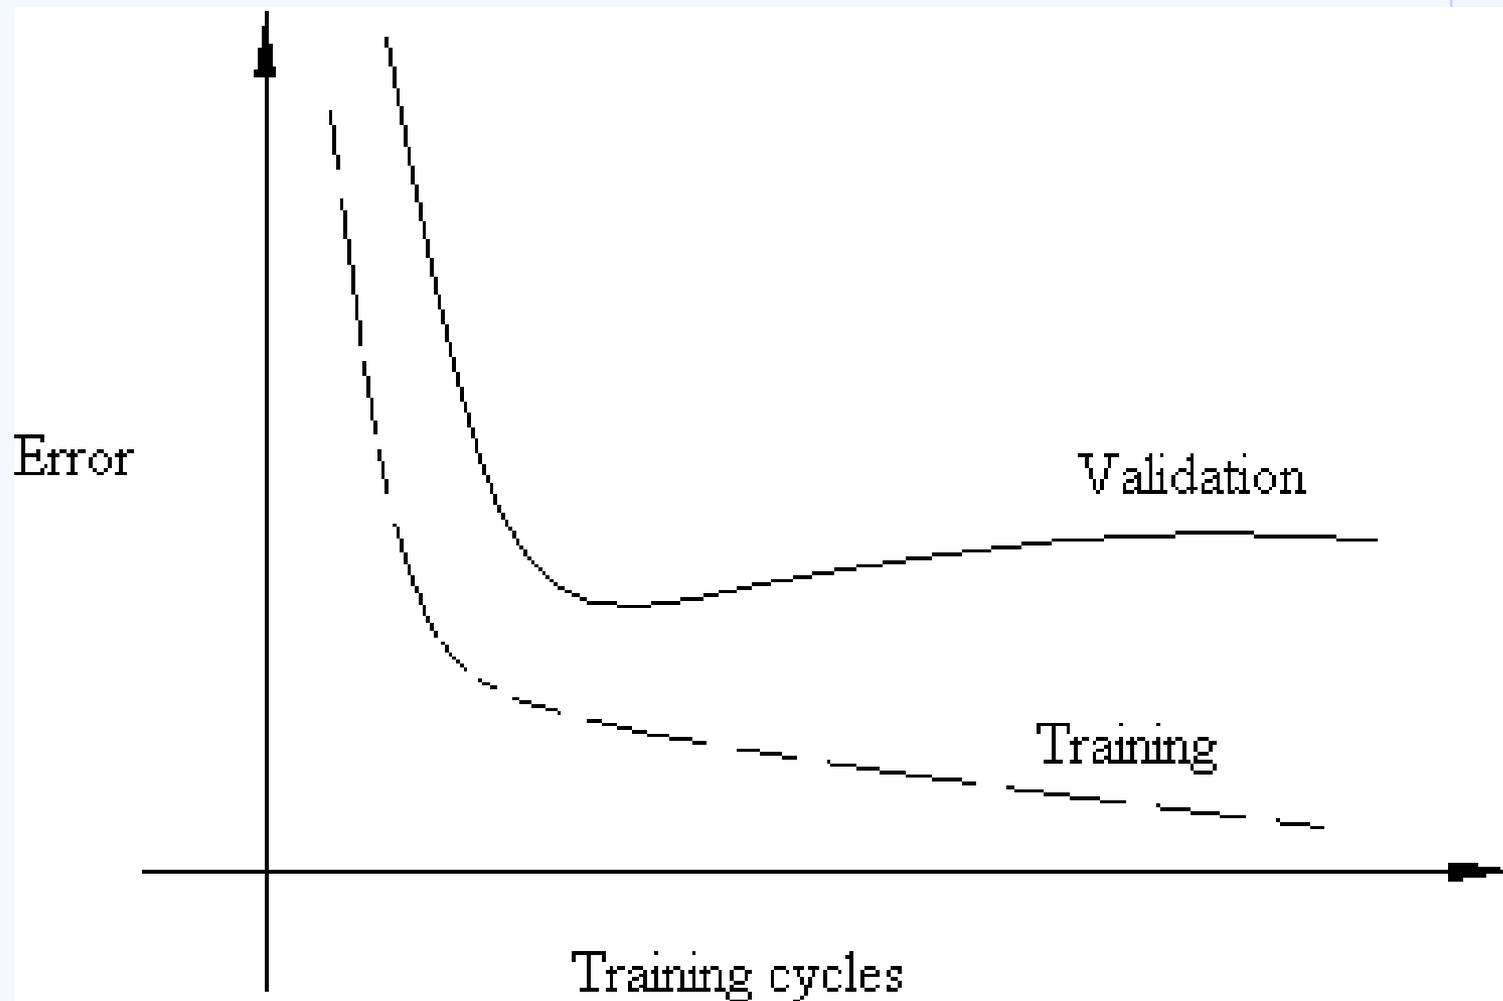
❖ Testovací množina

- ◆ Množina objektů, u kterých klasifikátor nezná správné přiřazení.
- ◆ Klasifikátor přiřadí objekty do tříd a následně se zhodnotí správnost klasifikace.
- ◆ Tím je určena testovací chyba klasifikace – schopnost klasifikátoru generalizovat.

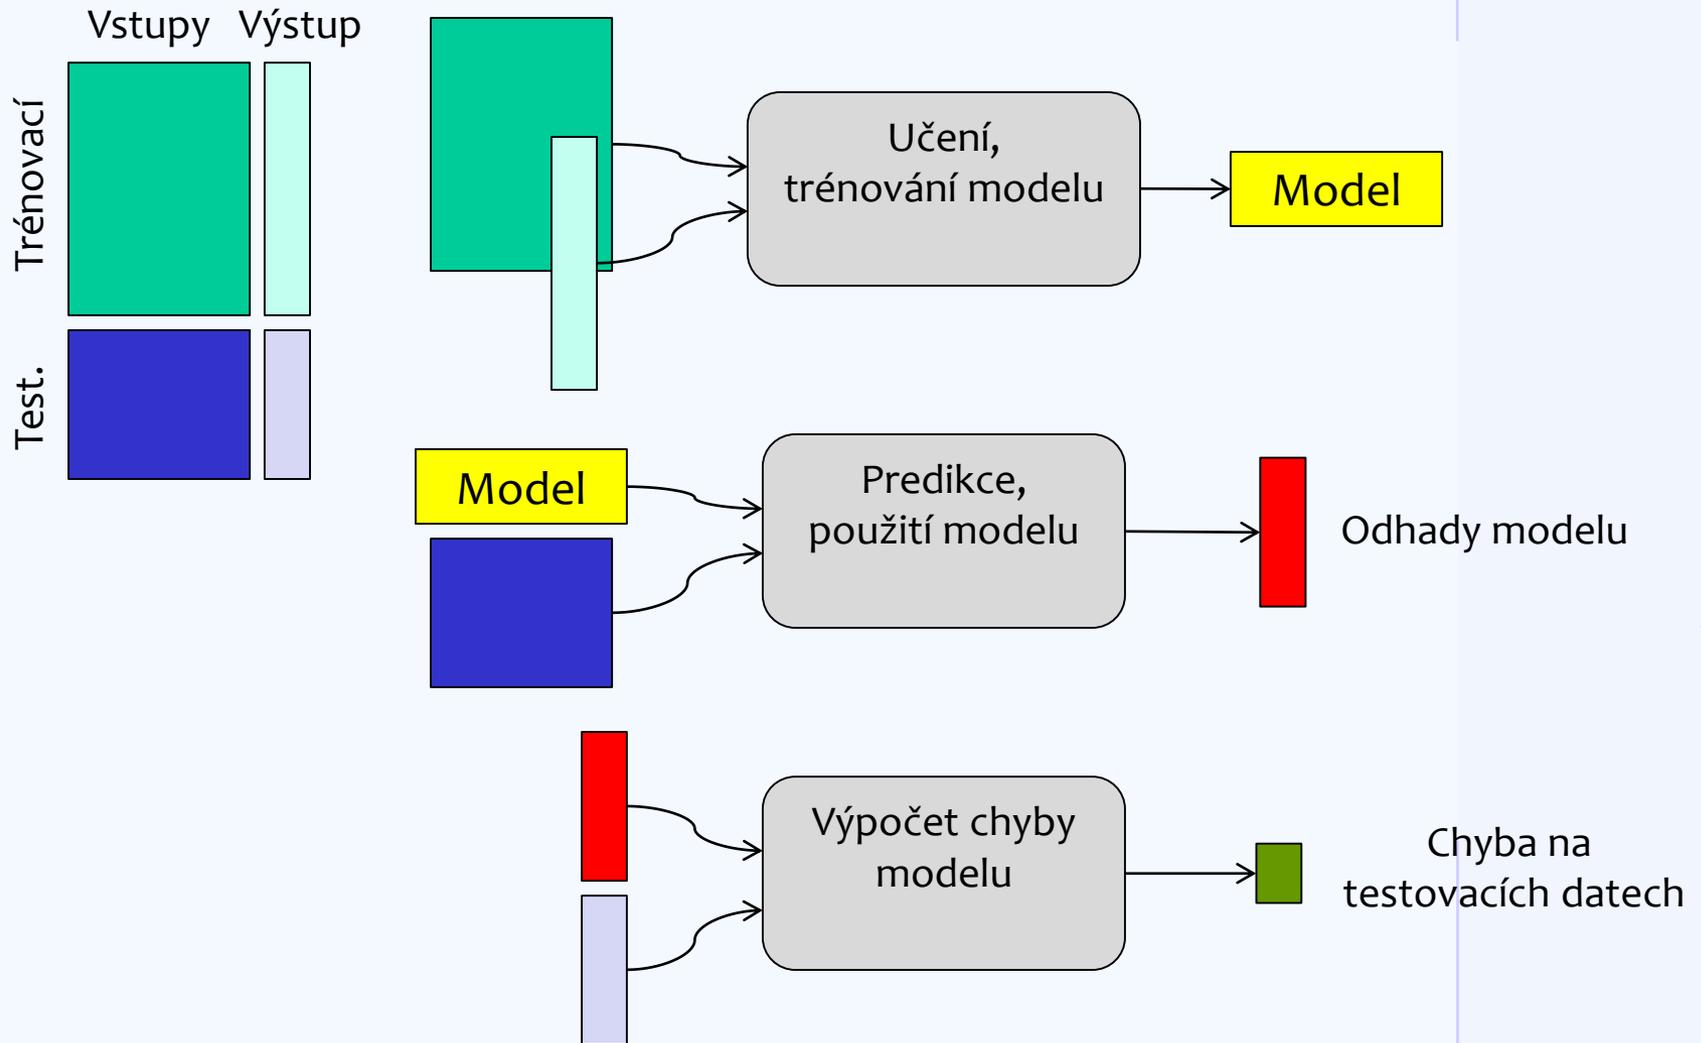
❖ Validací množina

- ◆ Při učení může dojít k jevu přeučení klasifikátoru.
- ◆ Znamená to, že klasifikátor se příliš přizpůsobil datům z trénovací množiny a ztratil schopnost zobecnění.
- ◆ Proto se používá validační množina, která má tomuto jevu (přeučení) zabránit.

Průběh učení



Učení a evaluace modelu



Křížová validace

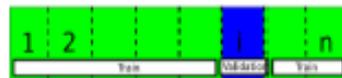
- Umožňuje odhadnout testovací chybu a potřebuje k tomu jen trénovací data
- Slouží k výběru (vhodné struktury a parametrů) modelu

Úplný postup pro výběr algoritmu křížovou validací, získání klasifikátoru a odhad jeho kvality

- 1 Rozdělíme data na Train / Test



- 2 Křížovou validací na Train vybereme algoritmus



- 3 Zvoleným algoritmem sestrojíme klasifikátor na Train



- 4 Jeho kvalitu odhadneme na Test



Senzitivita a specificita



	Skutečnost		
Výsledek testu	D+	D-	celkem
T+	a	b	a+b
T-	c	d	c+d
celkem	a+c	b+d	n

	Skutečnost	
Výsledek testu	H ₀	H ₁
H ₀	Ok	Chyba II. druhu: β
H ₁	Chyba I. druhu: α	Ok

α: hladina významnosti testu
 β: síla testu

Senzitivita

$$SE = \frac{a}{a+c}$$

Specificita

$$SP = \frac{d}{b+d}$$

Nesprávná pozitivita

$$FP = \frac{b}{b+d}$$

Nesprávná negativita

$$FN = \frac{c}{a+c}$$

Prediktivní honota pozitivního testu

$$PV^+ = \frac{a}{a+b}$$

Prediktivní honota negativního testu

$$PV^- = \frac{d}{c+d}$$

ROC křivka

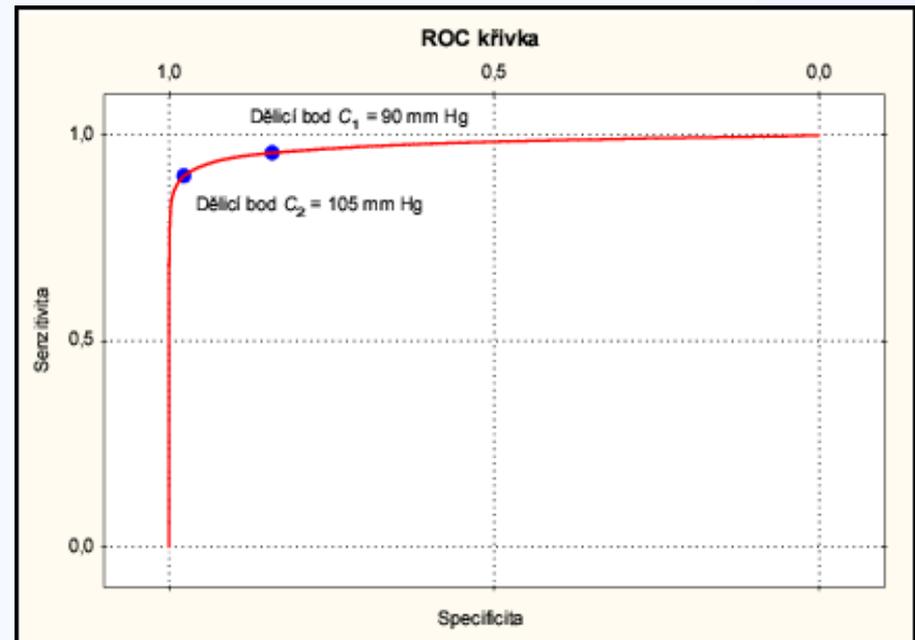
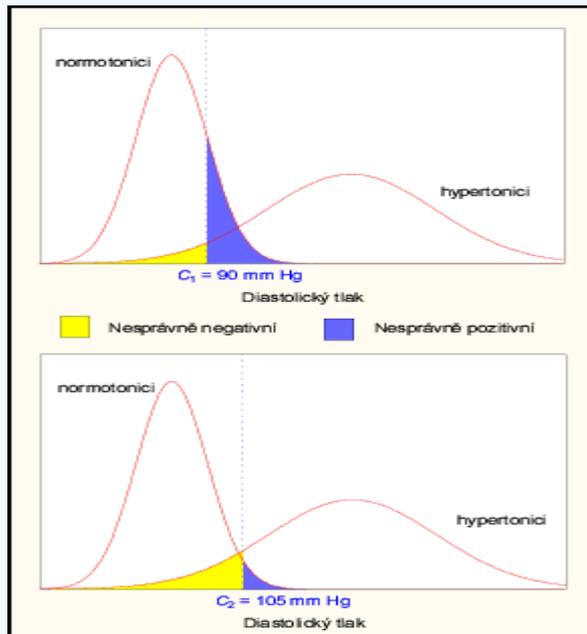


❖ Receiver Operating Characteristic

- ◆ původně z radiologie – hodnocení kvality radaru
 - ◆ v medicíně se používá nejčastěji pro zhodnocení přesnosti diagnostického testu, jehož výsledkem je spojitá veličina vs. pozitivní či negativní výsledek testu
 - ◆ vhodná také pro hodnocení modelů při dolování dat – pro pravděpodobnostní modely odhadující příslušnost ke klasifikační třídě, popř. pro modely, kdy je nutné optimalizovat současně senzitivitu i specificitu
- ## ❖ ROC křivka vyjadřuje vztah mezi specificitou a senzitivitou pro všechny možné hodnoty prahu q
- ◆ za prahovou lze volit libovolnou hodnotu mezi dvěma sousedními hodnotami testu

ROC křivka

- ❖ Rozdělení diastolické tlaku ve skupině normotoniků a hypertoniků
- ❖ Vyznačené plochy ukazují podíl nesprávně pozitivních závěrů (normotonika zařadíme mezi hypertoniky) a podíl nesprávně negativních závěrů (hypertonika zařadíme mezi normotoniky).





Klasifikátor



k-NN

1NN – nejbližší soused

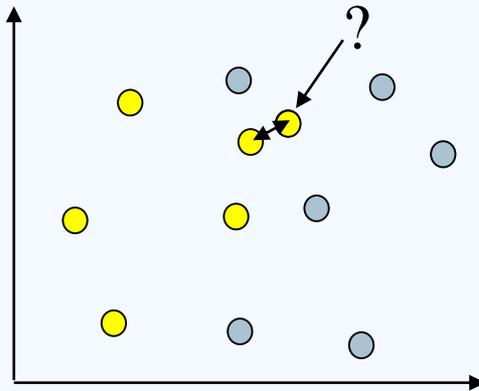


❖ Trénování – generování modelu

- ◆ Ulož trénovací data

❖ Klasifikace – použití modelu

- ◆ Najdi nejbližšího souseda a klasifikuj stejnou třídou



Metrika, Euklidovská vzdálenost



- ◆ Je třeba nějak určit podobnost vzorů – jejich vzdálenost
- ◆ Vzdálenost musí splňovat určité podmínky:
 1. $d(x,y) \geq 0$.
 2. $d(x,y) = 0$ iff $x = y$.
 3. $d(x,y) = d(y,x)$.
 4. $d(x,y) \leq d(x,z) + d(z,y)$ (*trojúhelníková nerovnost*).

Dva body v n -rozměrném prostoru: $P = (p_1, p_2, \dots, p_n)$ $Q = (q_1, q_2, \dots, q_n)$

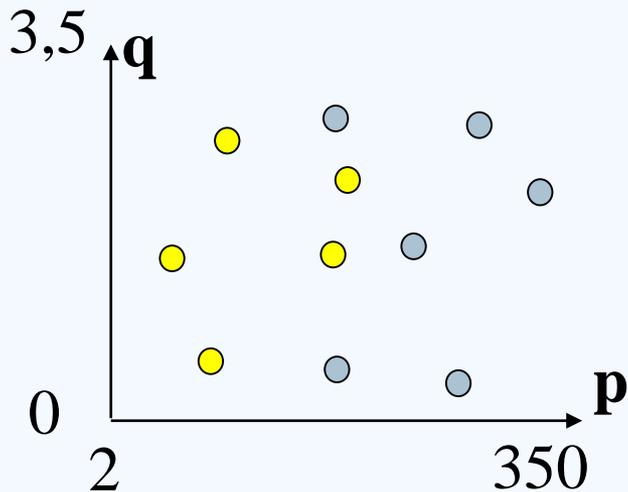
- ◆ Odmocňování není nezbytně nutné, když vzdálenosti porovnáváme

$$\text{Euklidovská vzdálenost } P \text{ a } Q = \sqrt{(p_1 - q_1)^2 + (p_2 - q_2)^2 + \dots + (p_n - q_n)^2} = \sqrt{\sum_{i=1}^n (p_i - q_i)^2}.$$

Váha atributů



- ❖ Problém – různé rozsahy vzdáleností
- ❖ Při určování euklidovské vzdálenosti mají atributy různou váhu – např. **p** je 100x důležitější než **q**

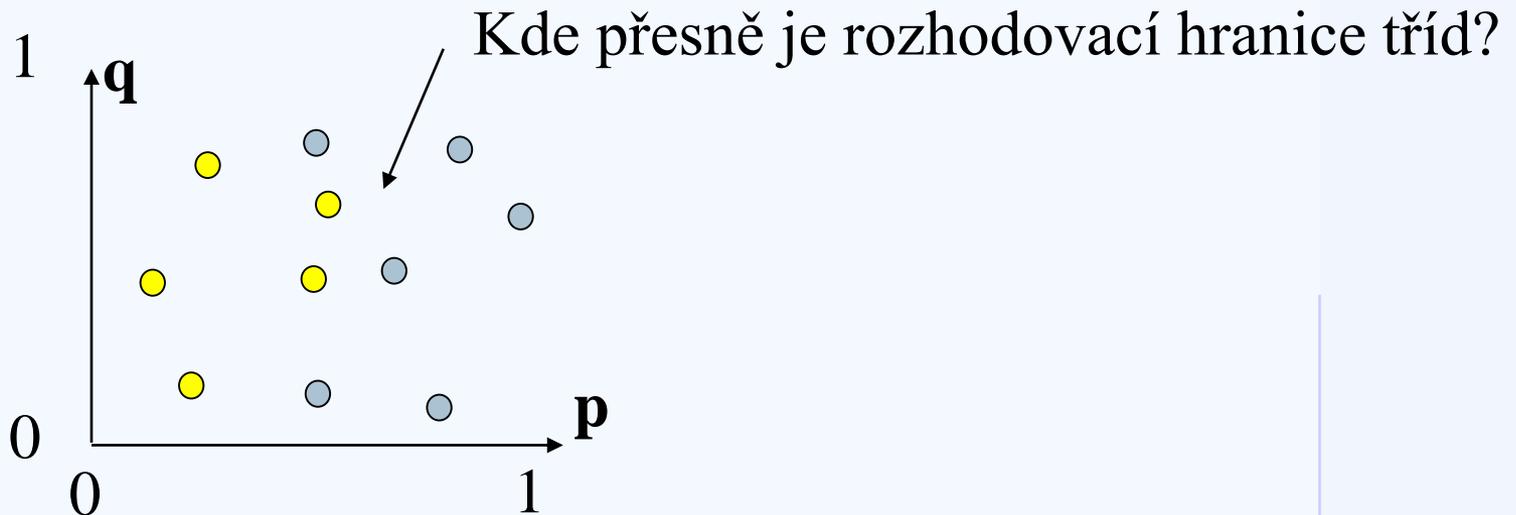


Normalizace atributů

- ❖ Problém vyřešíme přeškálováním (normalizací) atributů:

$$a_i = \frac{v_i - \min v_i}{\max v_i - \min v_i} \quad \text{nebo} \quad a_i = \frac{v_i - \text{Avg}(v_i)}{\text{StDev}(v_i)}$$

- ❖ Původní rozsahy se transformují do $\langle 0,1 \rangle$



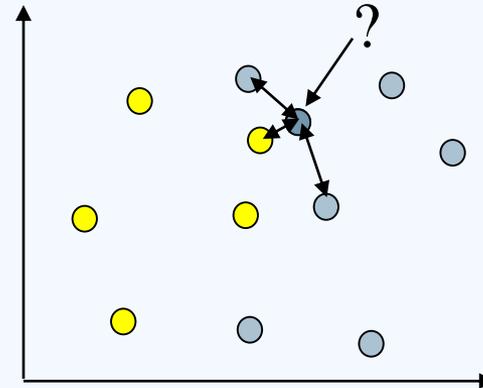
kNN – k nejbližších sousedů



❖ Klasifikace

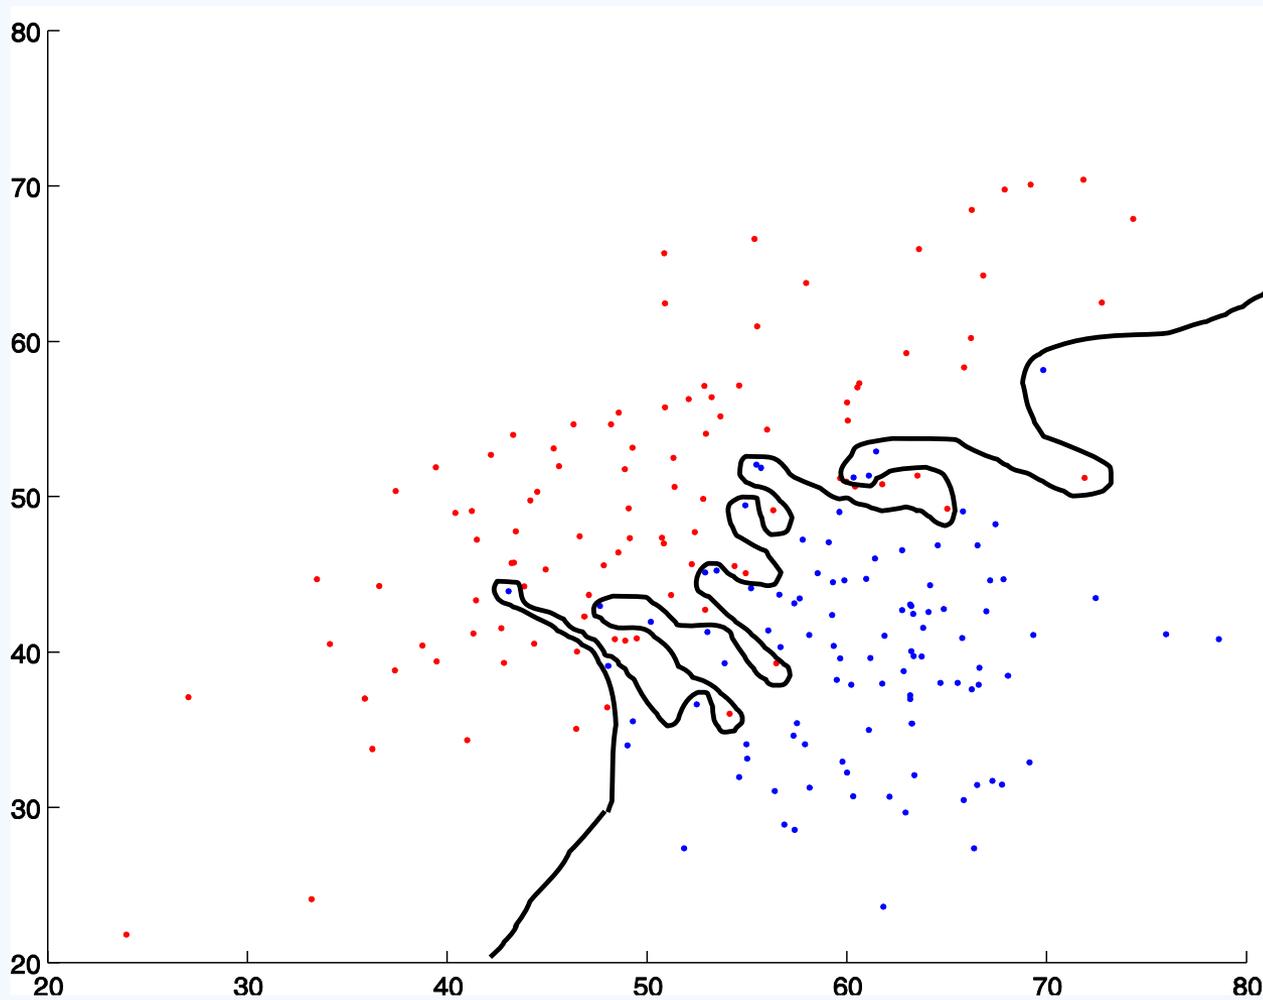
- ◆ Najdi **k** nejbližších sousedů a klasifikuj majoritní třídou

❖ Příklad 3NN klasifikace:

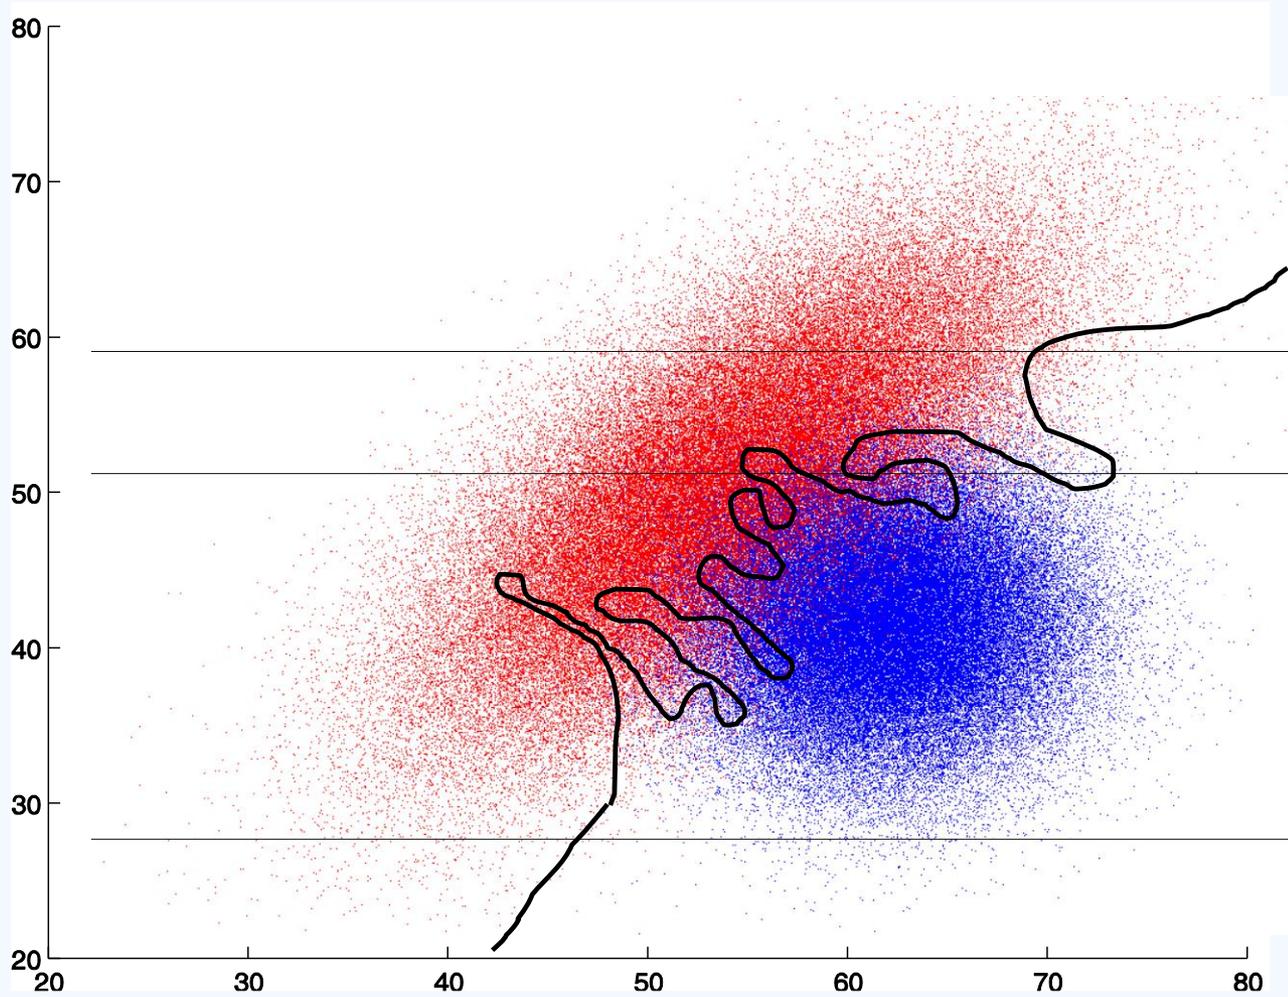


❖ Jak zvolit optimální **k**?

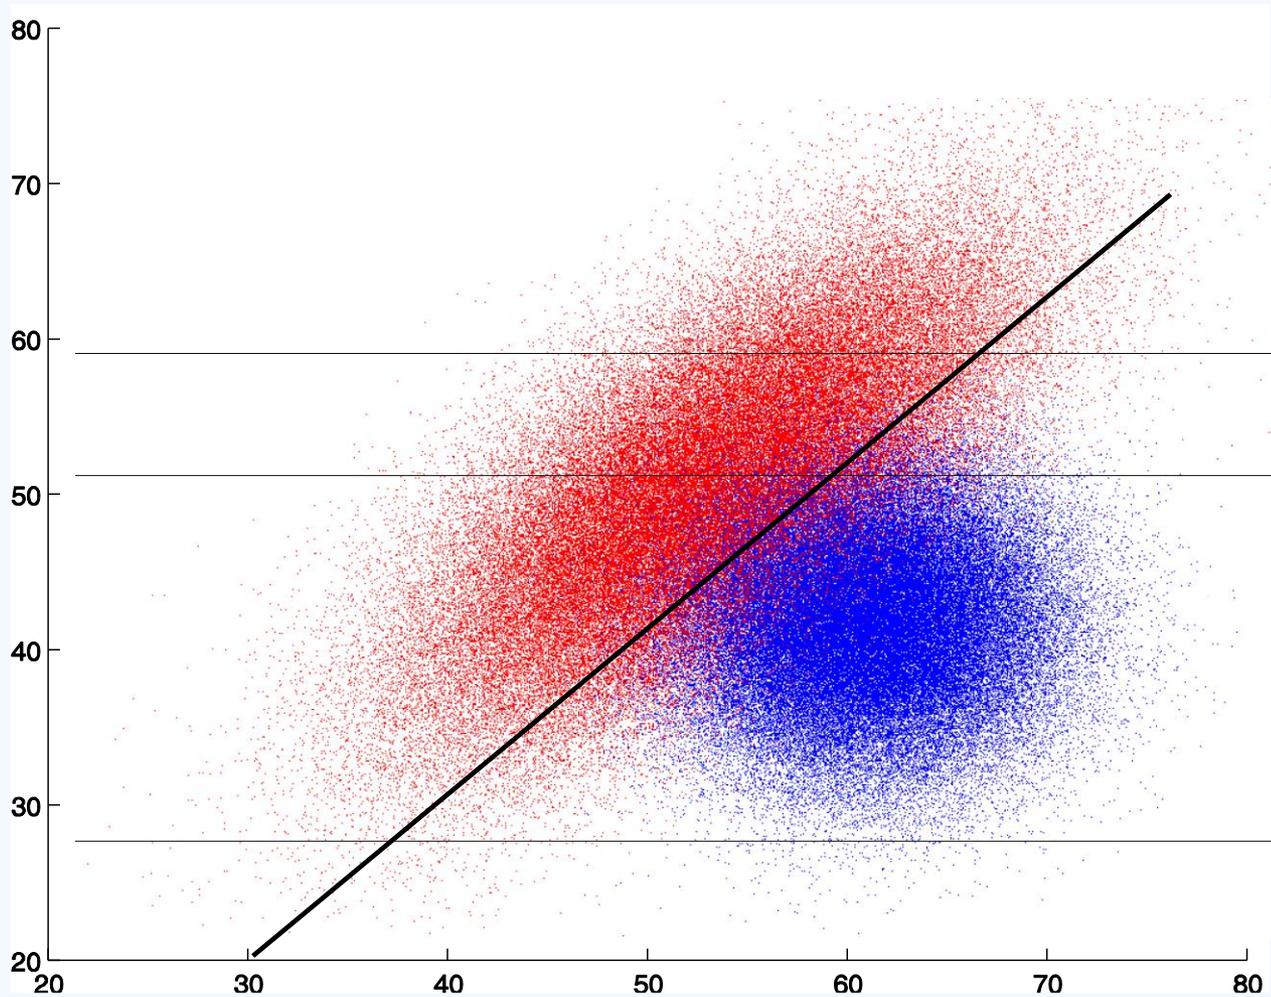
Klasifikace



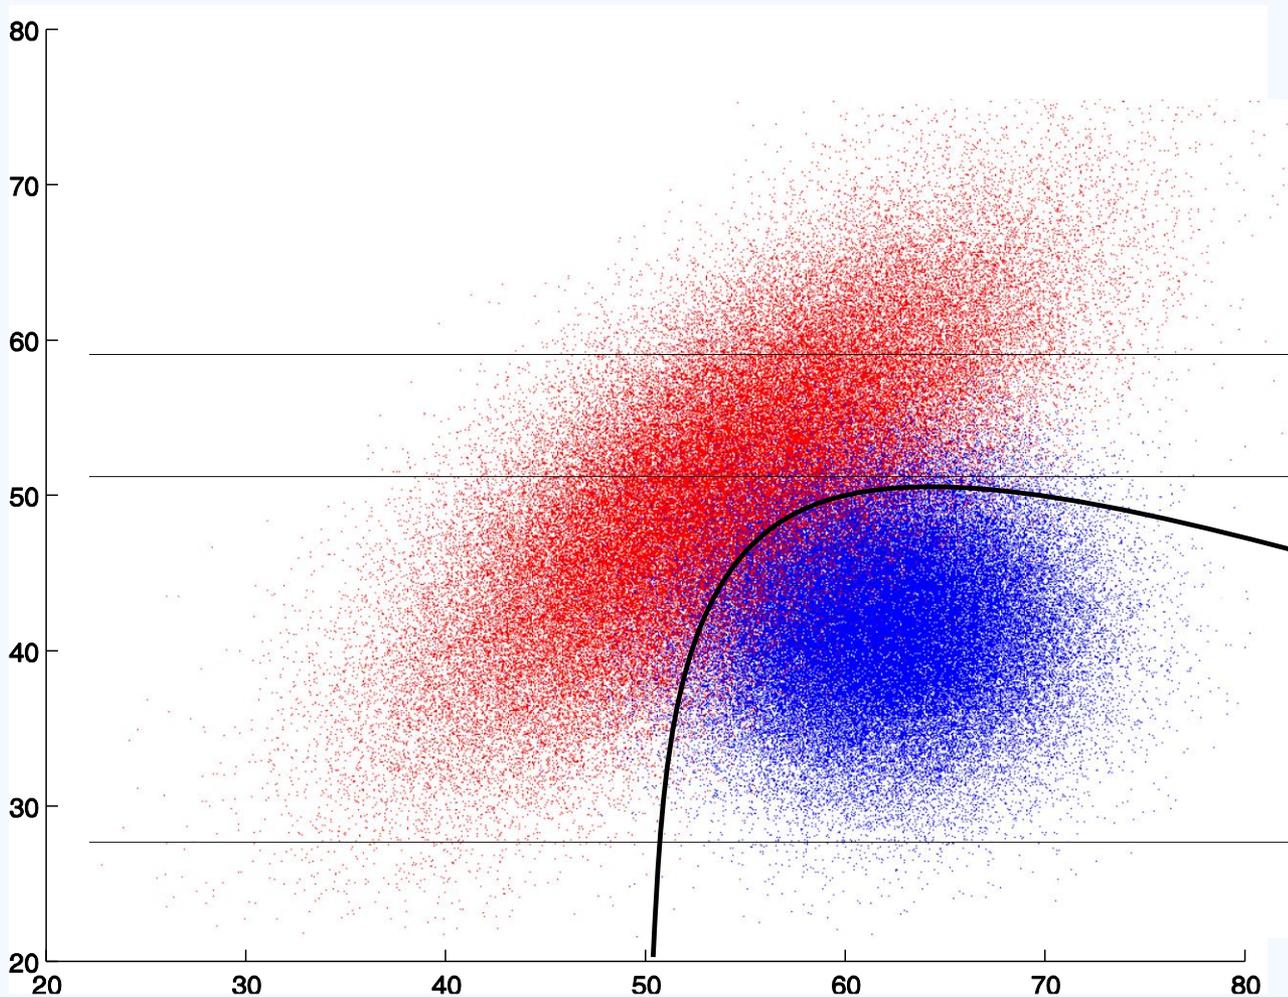
Generalizace



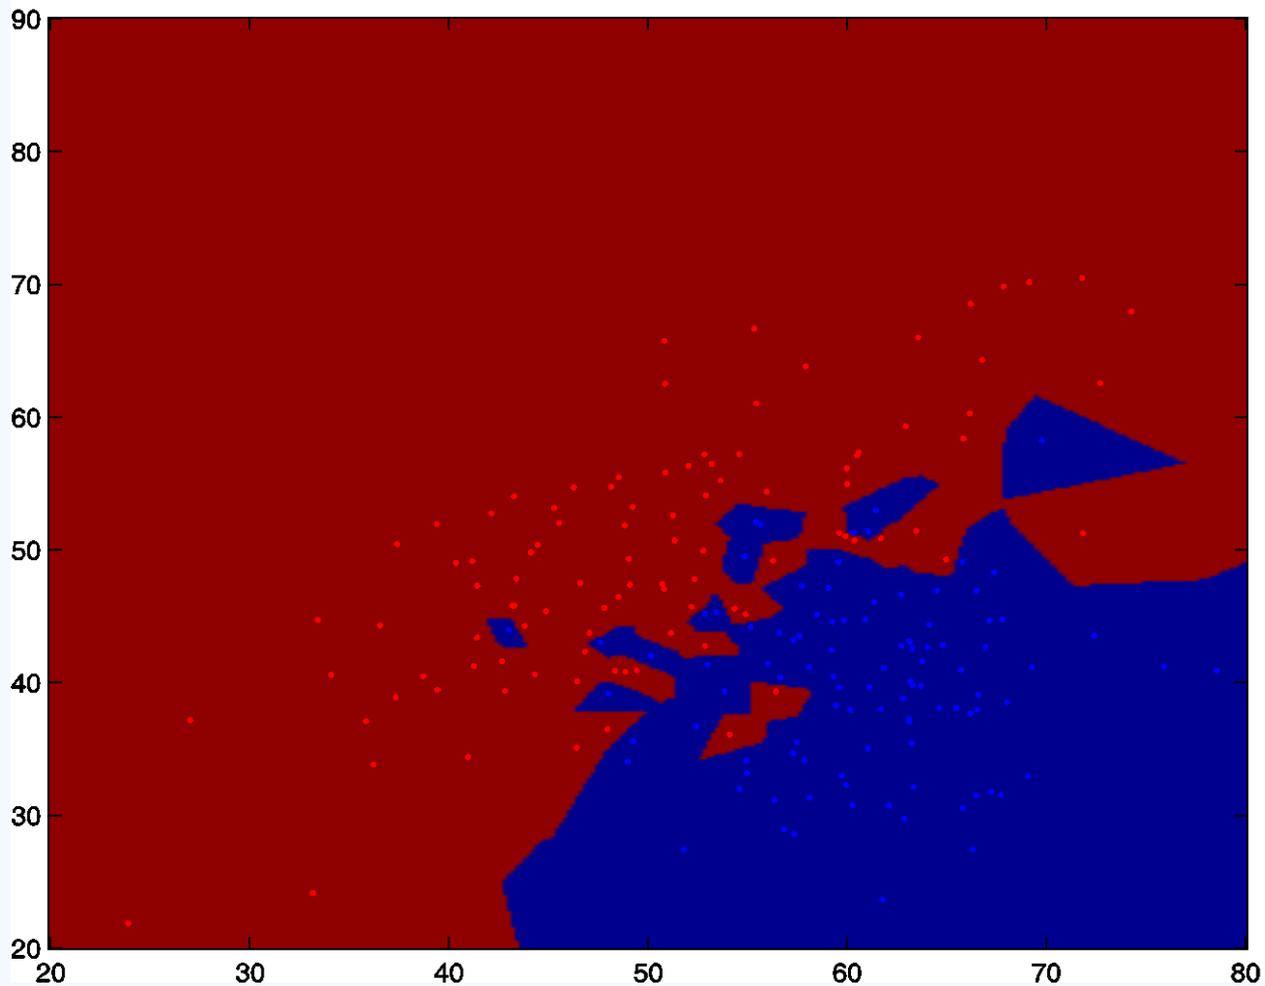
Lineární klasifikátor (separátor)



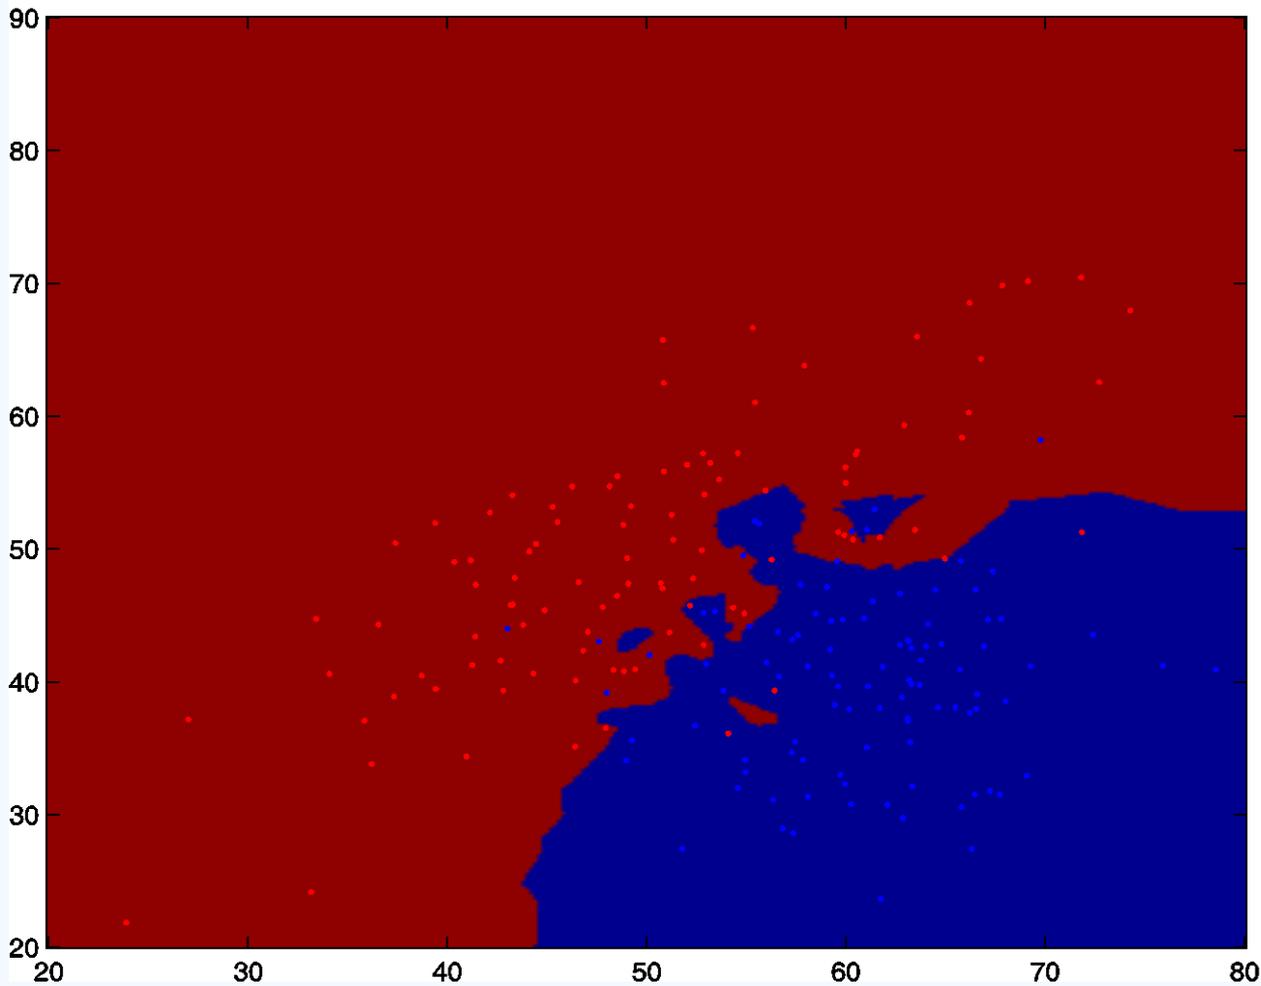
Nelineární klasifikátor



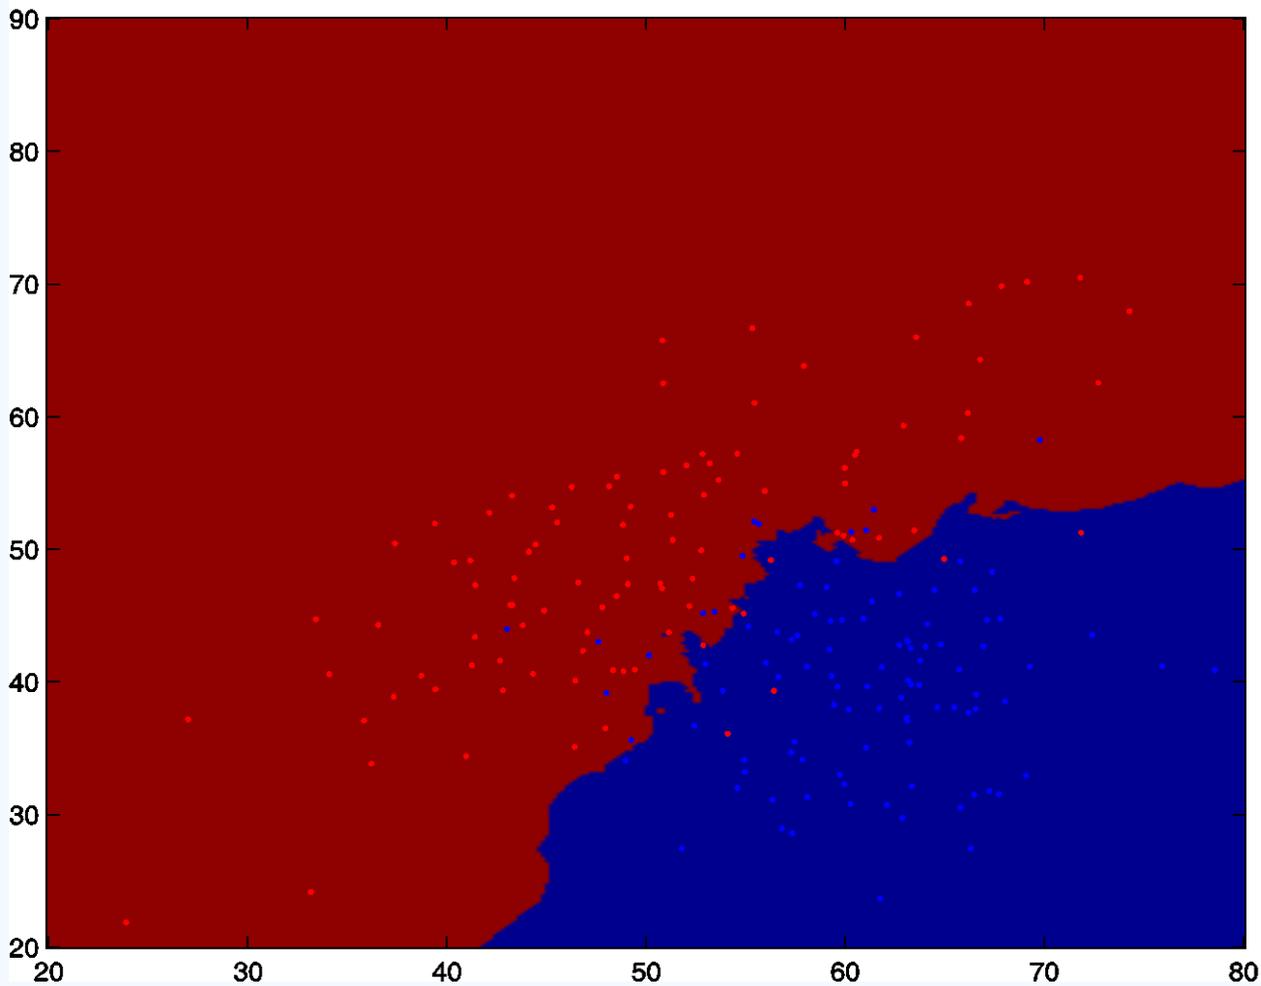
1NN



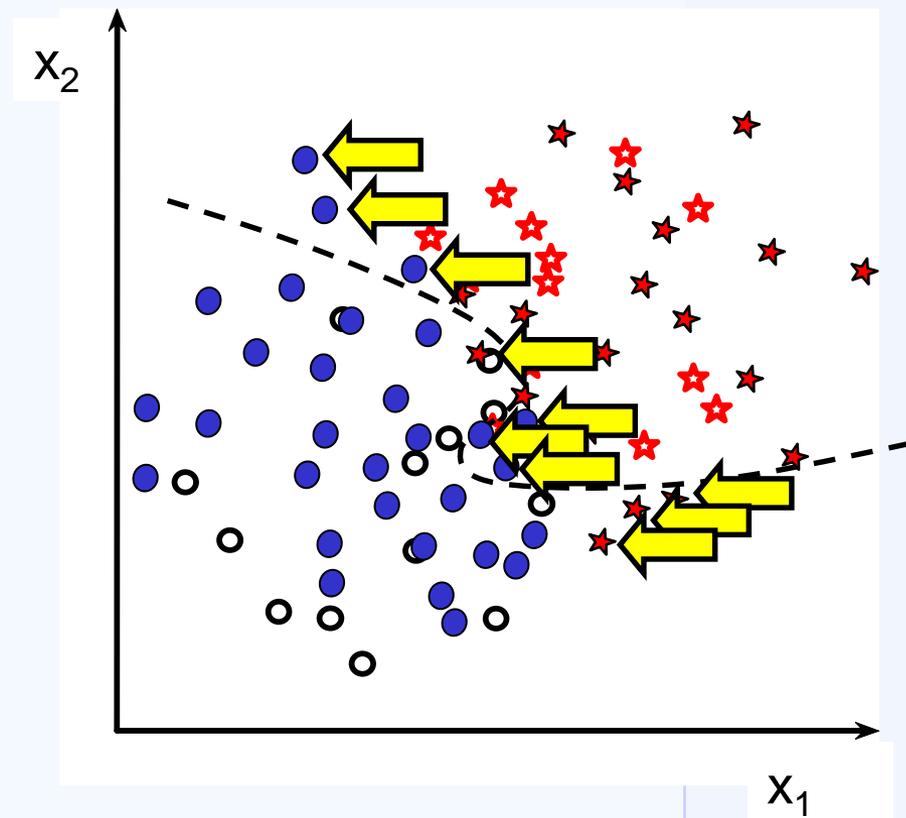
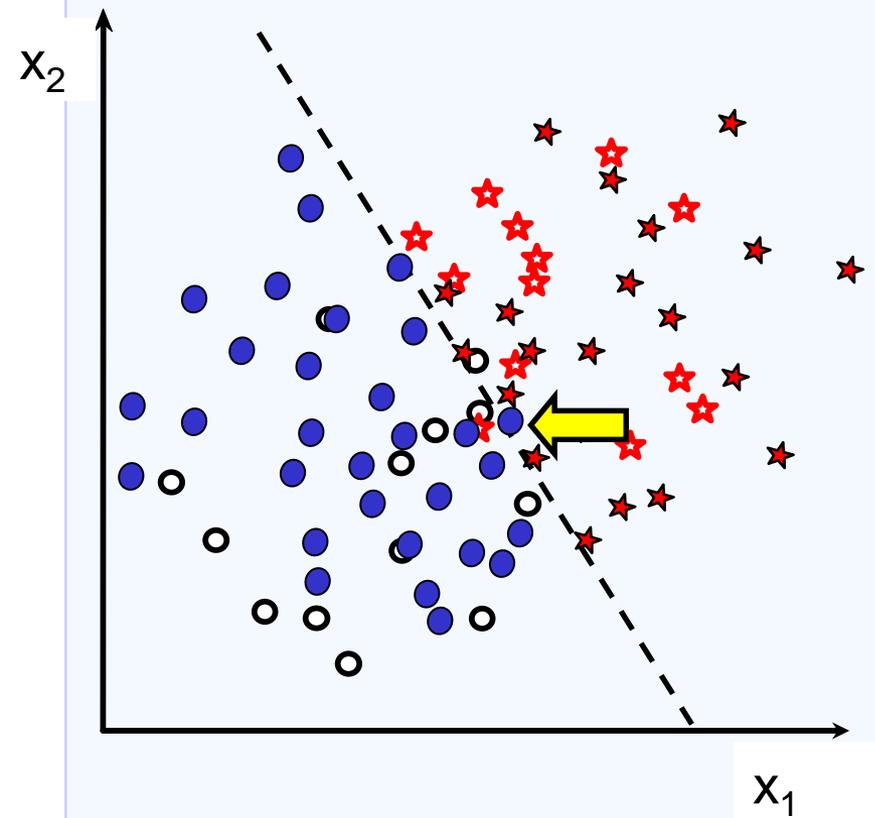
3NN



9NN



Přeučení



Jak zjistit přeučení?



- Rozdělit na trénovací a testovací data.
- Model vygenerovat na datech trénovacích.
- Chybu počítat na datech testovacích.

mpg	cyl	disp	hp	wgt	acc	year	Origin	name	
15	8	400	150	3761	9.5	70	US	chevrolet_monte	TRAIN
14	8	455	225	3086	10	70	US	buick_estate_wag	TEST
24	4	113	95	2372	15	70	JP	toyota_corona_mi	TRAIN
22	6	198	95	2833	15.5	70	US	plymouth_duster	TRAIN
18	6	199	97	2774	15.5	70	US	amc_hornet	TEST
21	6	200	85	2587	16	70	US	ford_maverick	TRAIN
27	4	97	88	2130	14.5	70	JP	datsun_pl510	TRAIN
26	4	97	46	1835	20.5	70	EU	volkswagen_1131	TRAIN
25	4	110	87	2672	17.5	70	EU	peugeot_504	TEST
24	4	107	90	2430	14.5	70	EU	audi_100_ls	TEST

Diskuze k NN



- ❖ Velmi populární metody a často i velmi úspěšné
- ❖ Ale pomalejší vybavování
 - ◆ Při klasifikaci musím projít celou trénovací množinu
- ❖ Pozor na váhy atributů
 - ◆ Řešením je normalizace dat
- ❖ Důležité najít vhodné k
 - ◆ Abychom minimalizovali chybu na testovacích datech
- ❖ Použitelné i pro regresní problémy



Naivní Bayesovský klasifikátor

Bayesovské učení



❖ Bayesovské uvažování

- ◆ je základem pro algoritmy učení, které přímo manipulují s pravděpodobnostmi
- ◆ je nástrojem pro analýzu a pochopení ostatních algoritmů strojového učení

❖ Výhodou metod bayesovského učení je schopnost klasifikovat příklady do tříd s určitou pravděpodobností.

❖ Metody Bayesovského učení:

- ◆ Bayesovský optimální klasifikátor
- ◆ Gibbsův algoritmus
- ◆ Naivní bayesovský klasifikátor
- ◆ Učení bayesovských sítí

Naivní bayesovský klasifikátor



- ❖ Naivní bayesovský klasifikátor vychází z předpokladu, že jednotlivé evidence E_1, \dots, E_K jsou podmíněně nezávislé při platnosti hypotézy H . Pak platí

$$P(H | E_1, \dots, E_K) = \frac{P(H)}{P(E_1, \dots, E_K)} \prod_{i=1}^K P(E_i | H)$$

- ❖ Naivní bayesovský klasifikátor:

$$H_{NB} = \arg \max_{H_j} P(H_j) \prod_{i=1}^K P(E_i | H_j)$$

Příklad – naivní Bayes



Pro ilustraci tohoto postupu vezměme opět úlohu poskytování úvěru, tentokrát ale pouze na základě výše příjmu. Předpokládejme, že banka vyhoví u $2/3$ žádosti o úvěr; tedy apriorní pravděpodobnosti budou $P(\text{půjčit})=0.667$ a $P(\text{nepůjčit})=0.333$. Dále předpokládejme, že vysoký příjem mělo 91% klientů, kterým banka půjčila a nízký příjem mělo 88% klientů, kterým banka nepůjčila. Tedy

$$P(\text{vysoký_příjem} | \text{půjčit}) = 0.91 \quad P(\text{nízký_příjem} | \text{půjčit}) = 0.09$$

$$P(\text{vysoký_příjem} | \text{nepůjčit}) = 0.12 \quad P(\text{nízký_příjem} | \text{nepůjčit}) = 0.88.$$

Předpokádejme, že posuzujeme klienta s vysokým příjmem. Bude větší pravděpodobnost, že banka půjčí nebo že nepůjčí? Podle Bayesovy věty spočítáme

$$P(\text{vysoký_příjem} | \text{půjčit}) \times P(\text{půjčit}) = 0.607$$

$$P(\text{vysoký_příjem} | \text{nepůjčit}) \times P(\text{nepůjčit}) = 0.040$$

Tedy $H_{\text{MAP}} = \text{půjčit}$. Víme tedy, která hypotéza je pravděpodobnější, přestože jsme přímo nespočítali aposteriorní pravděpodobnosti obou hypotéz. Tyto pravděpodobnosti získáme, pokud budeme uvedené hodnoty normovat tak, aby jejich součet byl roven 1.

Výhodou bayesovských metod je právě tato schopnost klasifikovat příklady do tříd s určitou pravděpodobností. Tuto pravděpodobnost můžeme interpretovat jako spolehlivost rozhodnutí.



Pravidla, stromy

Pravidla

- ❖ procedurální sémantika

JESTLIŽE situace PAK akce

- ❖ deklarativní sémantika

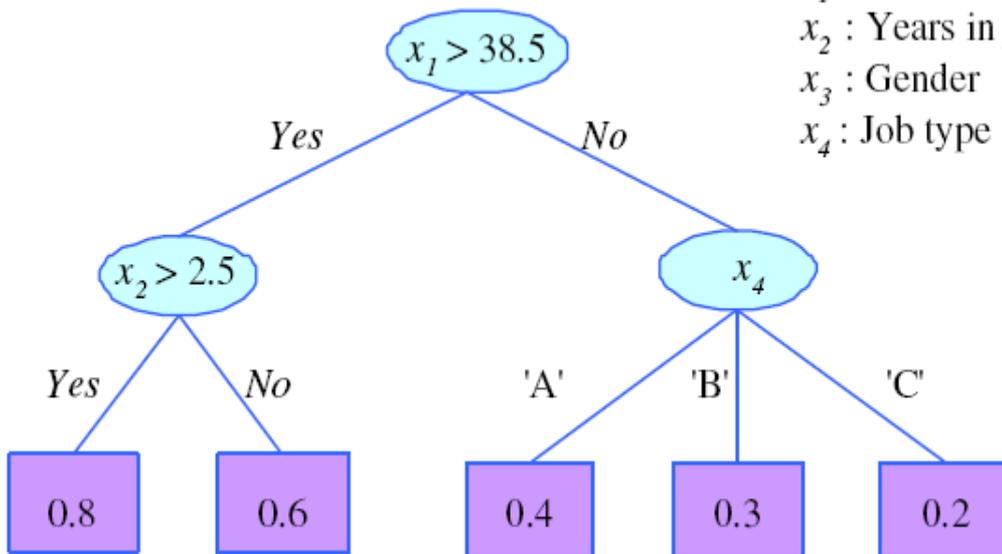
JESTLIŽE předpoklad PAK závěr

- ❖ situace, předpoklad a závěr jsou kombinace tvrzení o stavu světa

Pravidla a stromy

- R1: IF (age > 38.5) AND (years-in-job > 2.5) THEN $y = 0.8$
- R2: IF (age > 38.5) AND (years-in-job ≤ 2.5) THEN $y = 0.6$
- R3: IF (age ≤ 38.5) AND (job-type = 'A') THEN $y = 0.4$
- R4: IF (age ≤ 38.5) AND (job-type = 'B') THEN $y = 0.3$
- R5: IF (age ≤ 38.5) AND (job-type = 'C') THEN $y = 0.2$

x_1 : Age
 x_2 : Years in job
 x_3 : Gender
 x_4 : Job type



Decision tree:

```

Ta <= 547.6988:
...TmaxToff > 37:
...:pozice_maxima_z_mapy03x <= 37: 1 (3)
...: pozice_maxima_z_mapy03x > 37: 2 (3)
...: TmaxToff <= 37:
...:pozice_maxima_z_mapy08x <= 59:
...:T_max_poz82 <= 0.78626: 2 (32.6/11.5)
...: T_max_poz82 > 0.78626: 3 (15.4/2.9)
...: pozice_maxima_z_mapy08x > 59:
...:T_max_hod01 <= 378.8304: 1 (2)
...: T_max_hod01 > 378.8304: 2 (8)
Ta > 547.6988:
...Tw > 14.5955: 3 (2)
Tw <= 14.5955:
...T_max_hod46 > 148.9341: 2 (8)
T_max_hod46 <= 148.9341:
...T_max_poz75 <= 0.7622: 2 (2.1)
...T_max_poz75 > 0.7622: 1 (14.9/1.9)
    
```

Size of decision tree : 10.

Accuracy: 79,5%

(a) (b) (c) <-classified as

```

-----
18          (a): class 1
  2 42      (b): class 2
 16 10      (c): class 3
    
```

Rules:

Rule 1: (14/1, lift 4.3)
 Ta > 547.6988
 Tw <= 14.5955
 T_max_hod46 <= 148.9341
 T_max_poz75 > 0.7622

Rozhodovací stromy – ID3



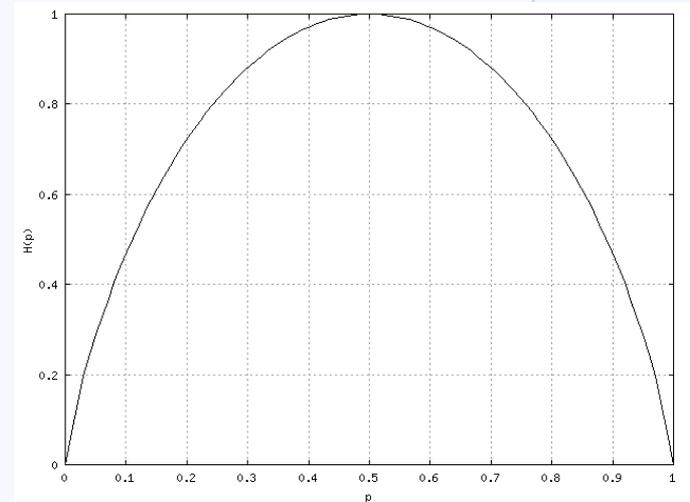
- ❖ Diferenciální diagnostika

- ❖ Algoritmus TDIDT (ID3 - Quinlan, 1986)
 1. zvol jeden atribut jako kořen dílčího stromu,
 2. rozděl data v tomto uzlu na podmnožiny podle hodnot zvoleného atributu a přidej uzel pro každou podmnožinu,
 3. existuje-li uzel, pro který nepatří všechna data do téže třídy, pro tento uzel opakuj postup od bodu 1, jinak skonči.

Rozhodovací stromy – volba atributu



- ❖ Pro kořenový uzel se vybírá takový atribut, který objekty od sebe maximálně odliší.
- ❖ Využívá se proto např. entropie (míra informační hodnoty atributu)

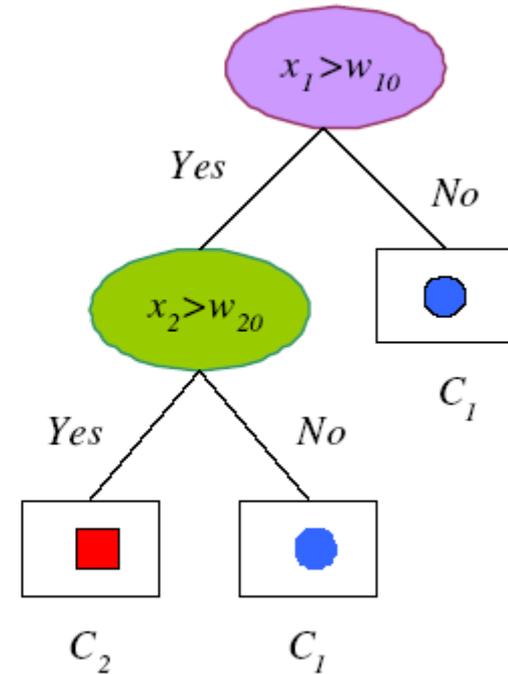
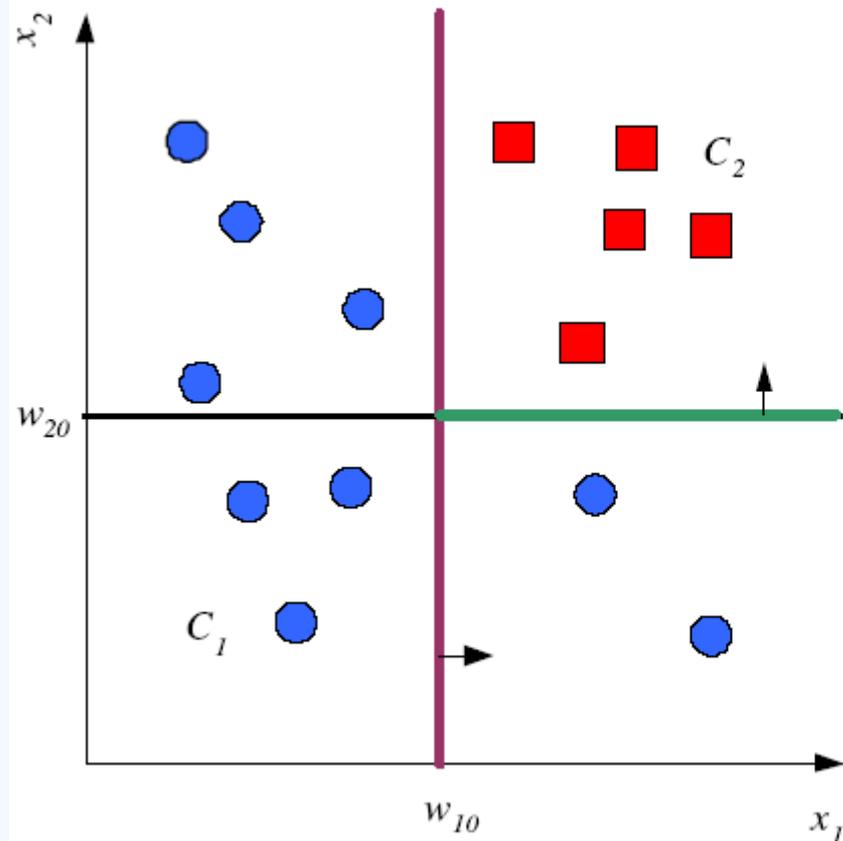


- ❖ Entropie

$$H = \frac{I}{n} = -K \sum_{i=1}^s P_i \ln P_i$$

- ❖ Vypočteme H pro všechny příznaky a zvolíme příznak s minimální entropií H.

Rozhodovací stromy



Indukce stromu z trénovacích dat

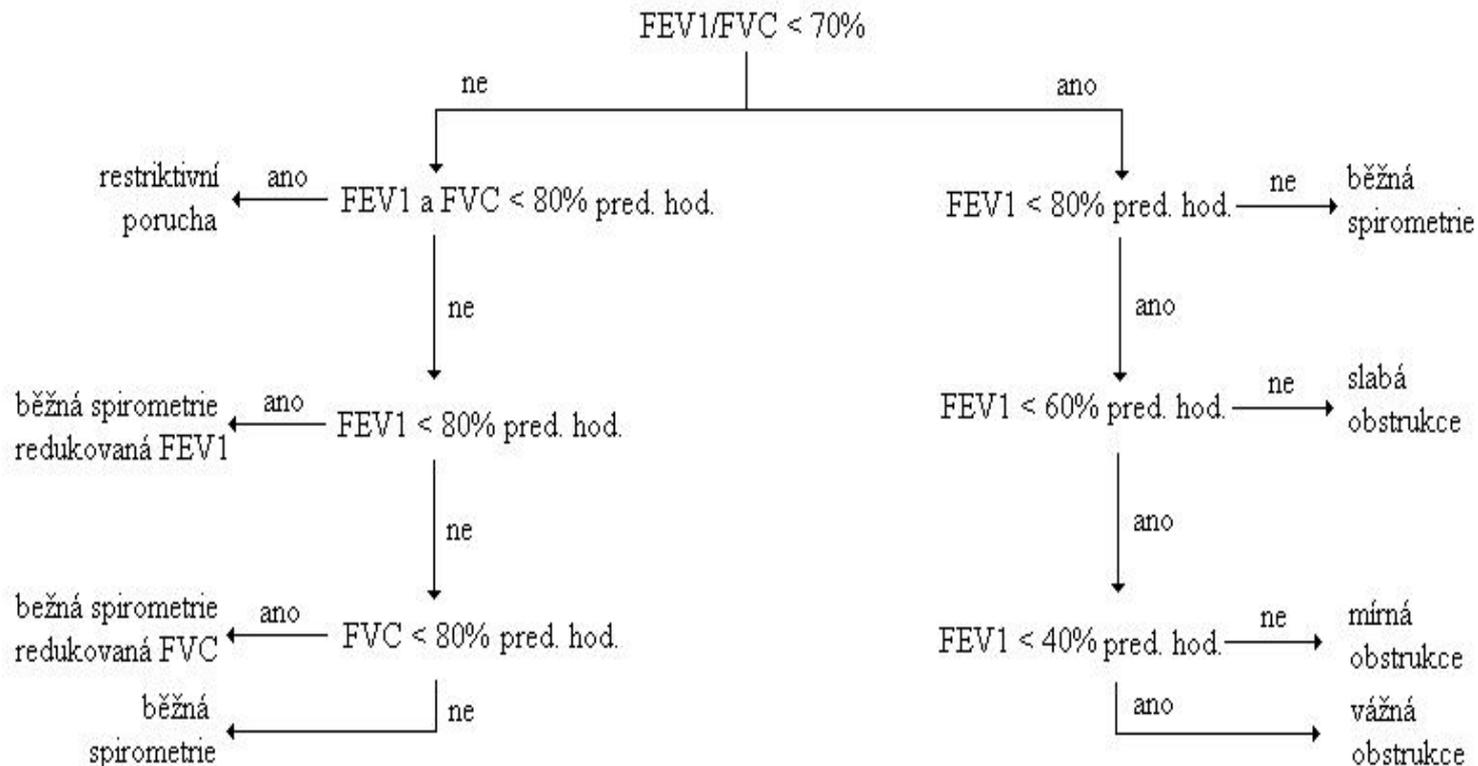
- ❖ dáno: **S** ... trénovací množina (množina klasifikovaných příkladů)
- 1.** Nalezni "nejlepší" atribut **at₀** (t.j. atribut, jehož hodnoty nejlépe diskriminují mezi pozitivní a neg. příklady) a tím ohodnot' kořen vytvářeného stromu.
- 2.** Rozděl množinu **S** na podmnožiny **S₁, S₂, ..., S_n** podle hodnot atributu **at₀** a pro každou množinu příkladů **S_i** vytvoř nový uzel jako následníka právě zpracovávaného uzlu (kořenu)
- 3.** Pro každý nově vzniklý uzel s přiřazenou podmnožinou **S_i** proved':
 - ◆ Jestliže v **S_i** nejsou žádné případy, pak je uzel listem a pro rozhodnutí použij rodiče. Konec.
 - ◆ Jestliže všechny příklady v **S_i** patří do stejné třídy, pak je uzel listem a jeho rozhodnutí bude třída, do níž příklady patří. Konec.
 - ◆ Jestliže nezbyl atribut, podle něhož se můžeme rozhodovat, a **S_i** přesto obsahuje příklady více tříd (chyby v datech, šum), pak je uzel listem a jako rozhodnutí použij majoritní třídu z **S_i**.
 - ◆ jinak pokračuj ve větvení: jdi na bod **1** s tím, že $S := S_i$.

Přímá klasifikace

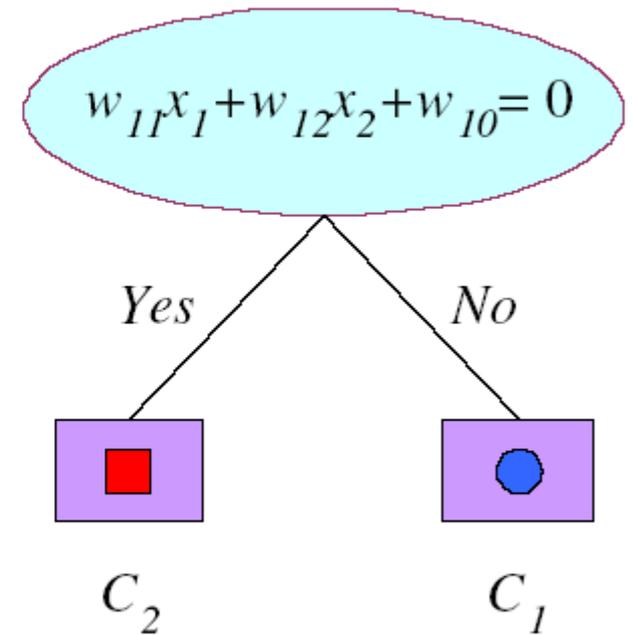
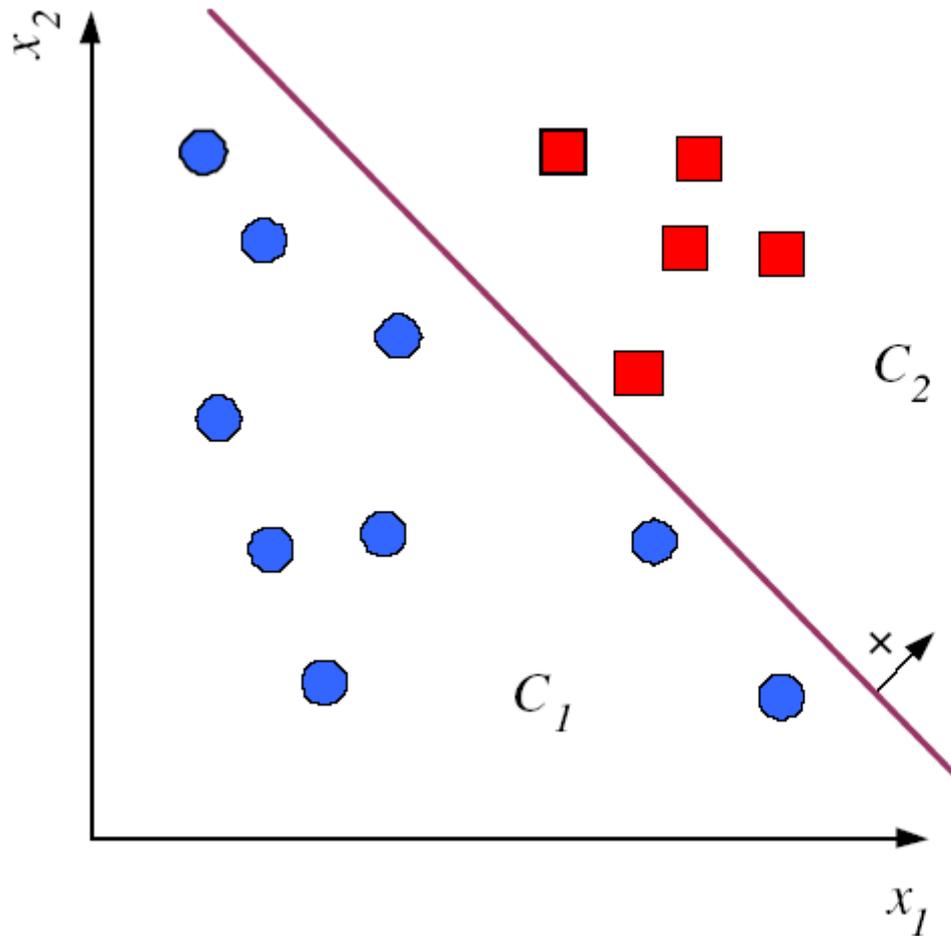


❖ Ukázka diagnostiky spirometrie – rozhodovací strom

❖ Dřízňaky: FVC – usilovná vitální kapacita FEV1 –



Stromy se složitějšími uzly

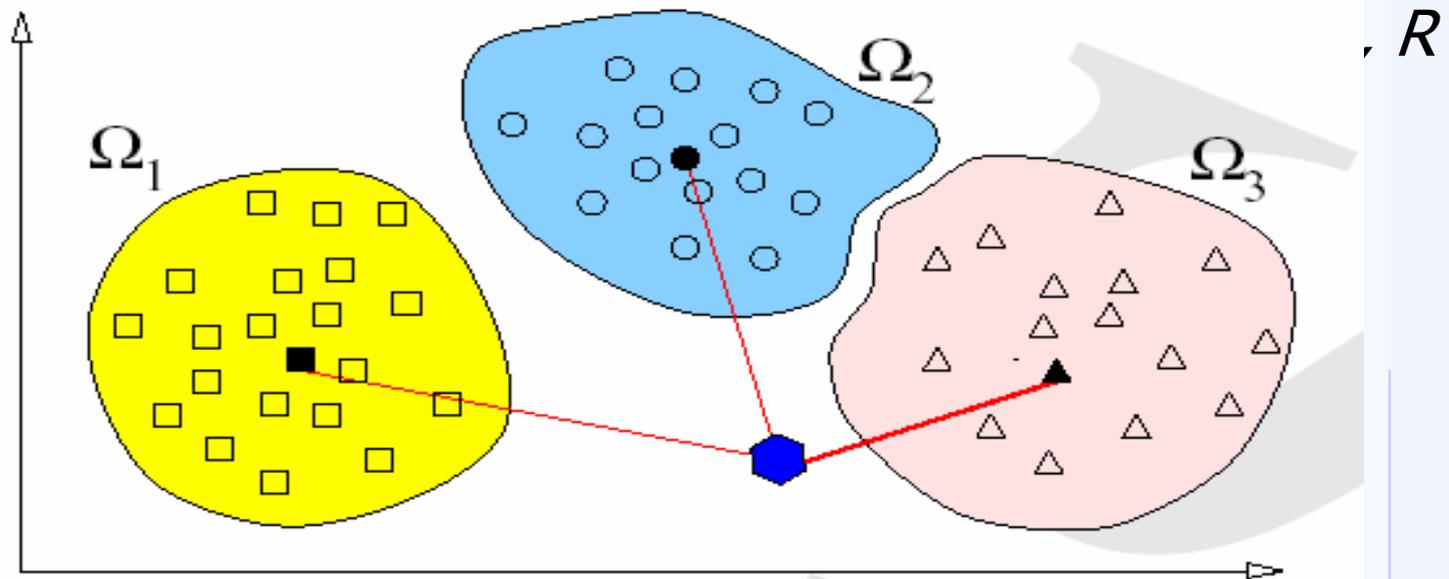




Další klasifikátory

Kritérium minimální vzdálenosti

- ❖ Porovnávání klasifikovaných obrazů se vzorovými obrazy – tzv. etalony
- ❖ Lze použít v úlohách s oddělitelnými množinami obrazů
- ❖ Neznámé obrazy pak klasifikujeme pravidlem



Klasifikátor s diskriminační funkcí



- ❖ Pro každou třídu definujeme takovou diskriminační funkci, aby pro všechny obrazy patřící do r -té klasifikační třídy platilo

$$g_i(\mathbf{x}) > g_j(\mathbf{x}) \mid r \in \langle 1, R \rangle, j = 1, \dots, R, i \neq j.$$

- ❖ Rozhodovací pravidlo pak nabývá tvaru

$$\omega_r = \max(g_j(\mathbf{x})), j = 1, \dots, R$$

- ❖ Rovnice rozdělujících nadploch určíme řešením soustavy rovnic

$$g(\mathbf{x}) = g_i(\mathbf{x}) - g_j(\mathbf{x}) \mid i, j = 1, \dots, R, i \neq j.$$

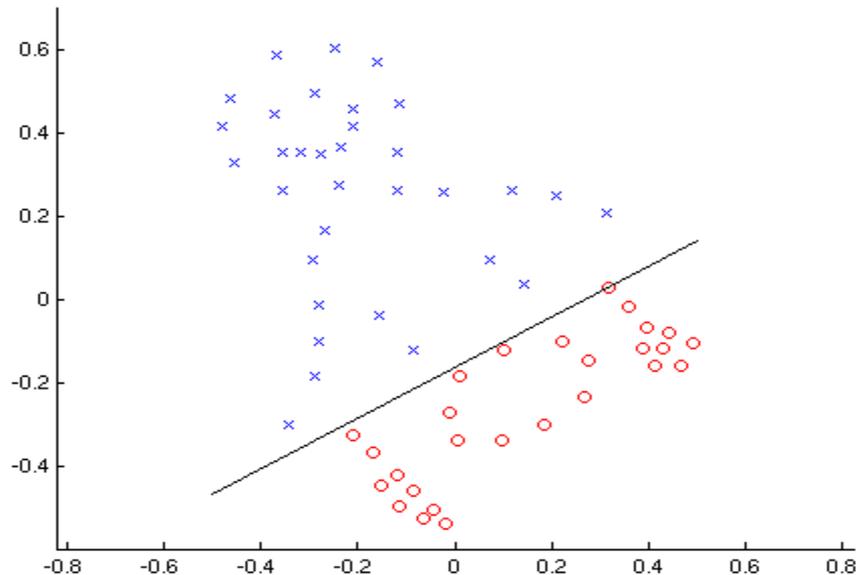
Lineární diskriminační funkce

- ❖ Diskriminační funkce ve tvaru

$$g_i(x) = \sum_{j=1}^n q_{ij} x_j + q_{i0}, \quad i = 1, 2, \dots, R$$

- ❖ A funkce $g(x)$ má tvar

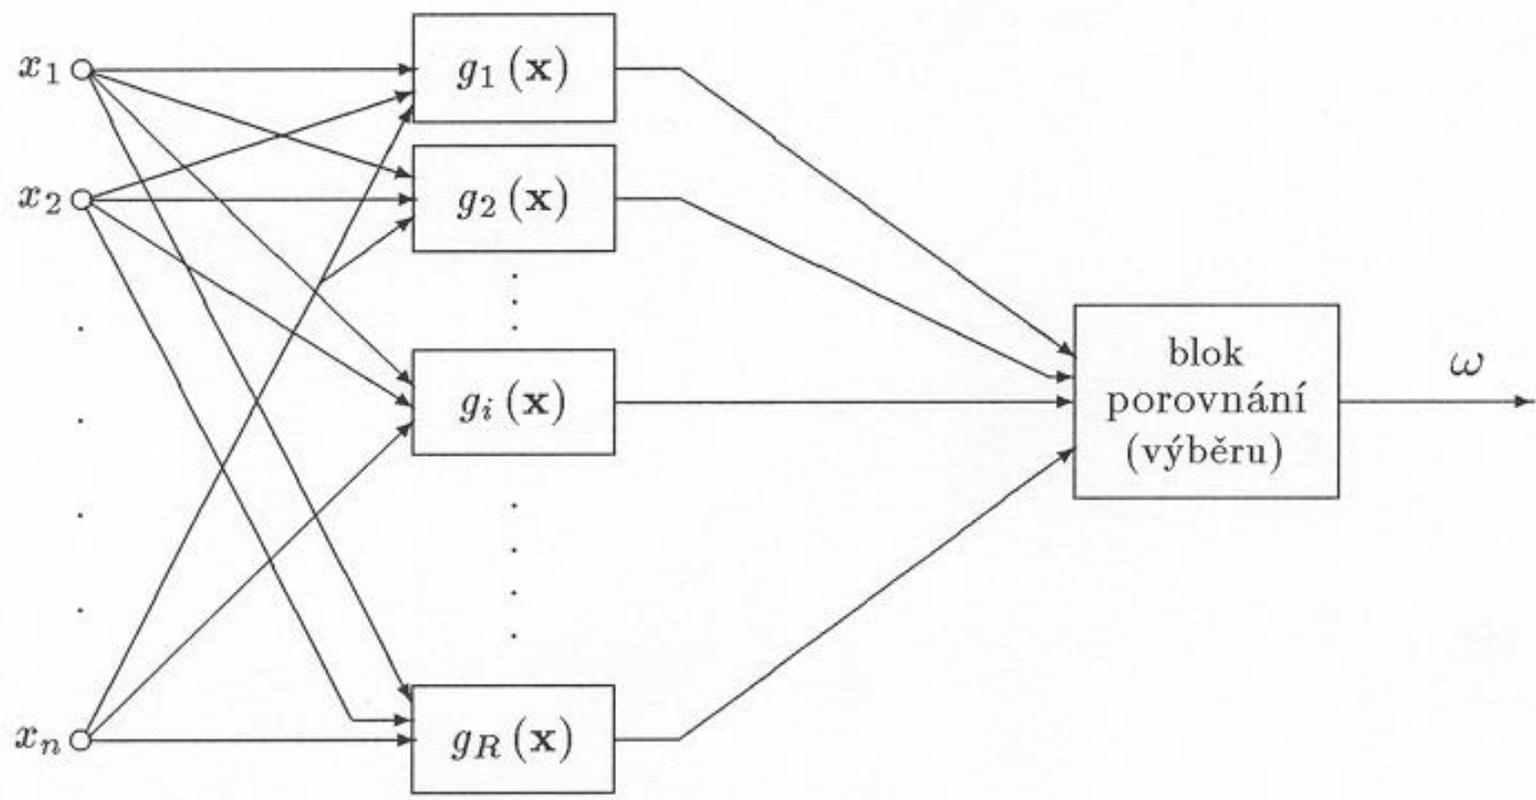
$$g(x) = g_1(x) - g_2(x) = (\mathbf{q}_1 - \mathbf{q}_2)^T \cdot x - (q_{10} - q_{20}) = \mathbf{q}^T \cdot x + q_0$$



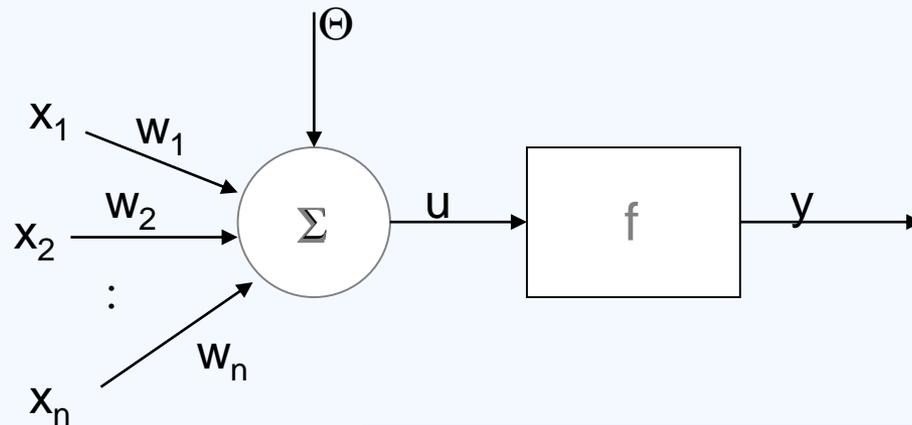
Klasifikátor s diskriminační funkcí



❖ Struktura klasifikátoru



Lineární klasifikátor - perceptron



x_i – vstupy neuronu

w_i – váhy neuronu

Θ - práh neuronu

u – vnitřní potenciál neuronu

y – výstup neuronu

$$y = f \left(\sum_{i=1}^N w_i x_i - \Theta \right)$$

Funkce f :

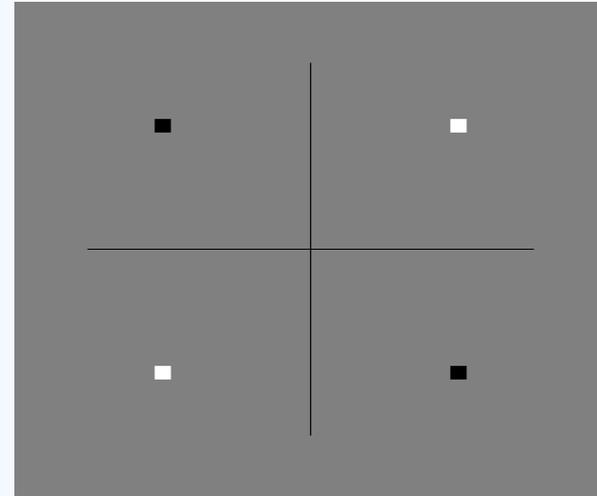
Sigmoida: $f_s(u) = \frac{1}{1 + e^{-u}}$

Heavisideova funkce: $f_h = \begin{cases} 1 & \text{pro } u > 0 \\ 0 & \text{pro } u \leq 0 \end{cases}$

Perceptron a XOR



- ❖ Rozhodnutí nelze aproximovat lineární funkcí.
- ❖ Marvin Minsky & Seymour Papert tyto autority zastavily vývoj v NN na 12 až 15 let.
- ❖ Rumelhart & McClelland sestavili neurony do vrstev.
- ❖ Výsledky výpočtu byly předány další vrstvě.
- ❖ Tato myšlenka se opírá o dva průlomové nápady ...
- ❖ Skokovou aktivační funkci perceptronu nahradila spojitá funkce (např. sigmoida)
- ❖ Byl navržen nový algoritmus učení – metoda zpětného navracení (backpropagation)



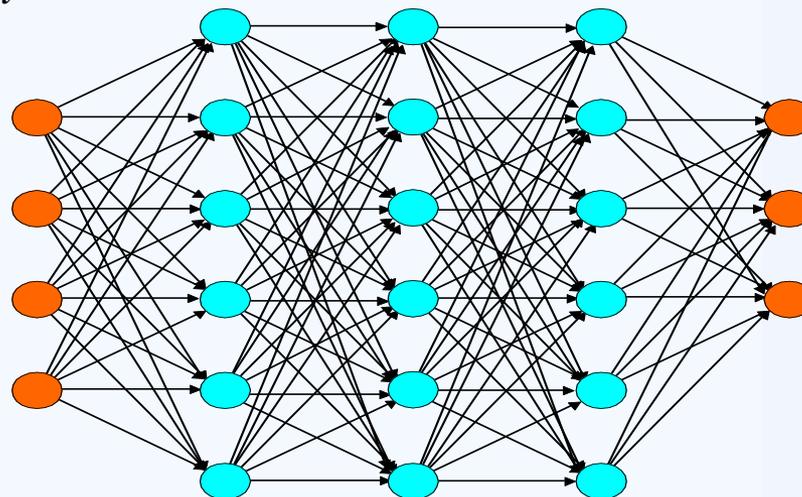


Vícevrstvé neuronové sítě

- ❖ Vrstvená síť typu $m - k_1 - k_2 - \dots - k_r - n$
 - ◆ se vstupní vrstvou dimenze m
 - ◆ s výstupní vrstvou dimenze n
 - ◆ s r skrytými vrstvami

Příklad:
síť 4-6-6-6-3

$m=4$



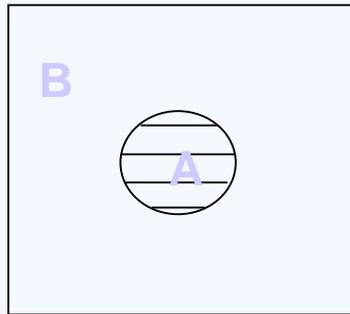
$n=3$

- ❖ Umějí realizovat libovolné spojitě zobrazení z m rozměrného vstupního vektorového do n rozměrného výstupního prostoru s libovolnou přesností.
- ❖ Lze najít příslušné skryté vrstvy sítě a hodnoty vah

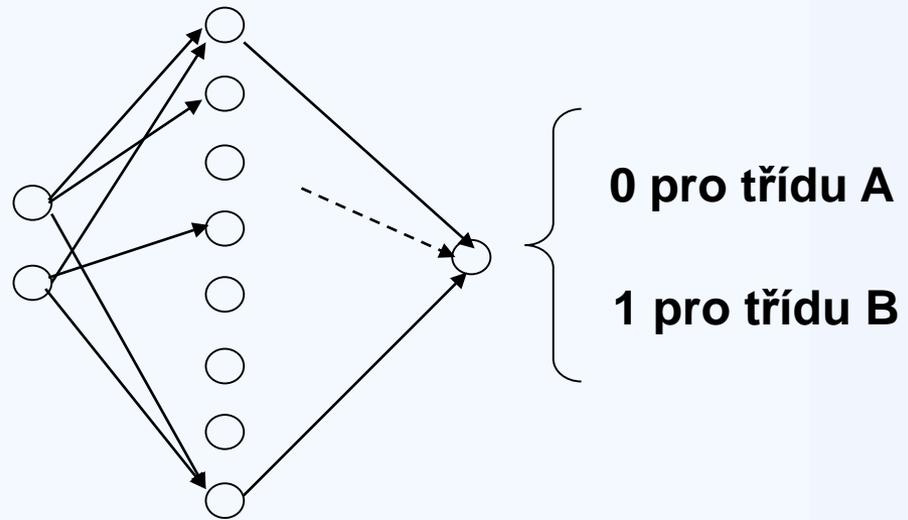
Příklad klasifikace



Správné třídy

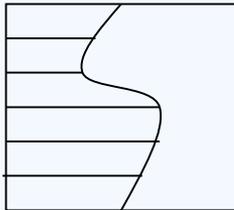


Architektura sítě

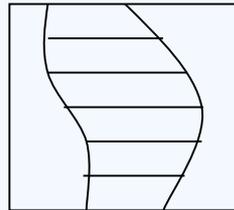


Kroky učení

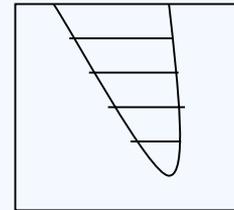
t=50



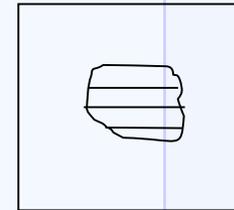
t=100



t=150



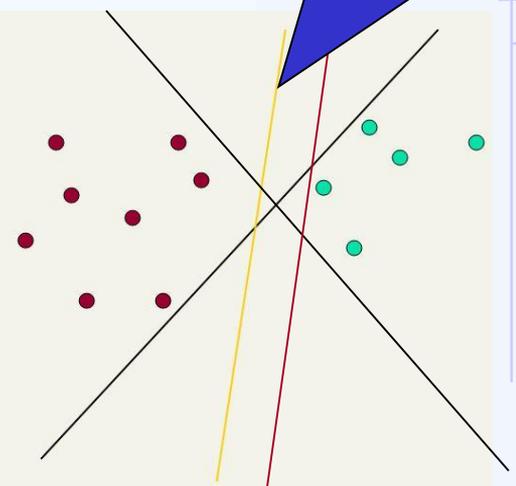
t=200



Linear classifiers: Which Hyperplane?

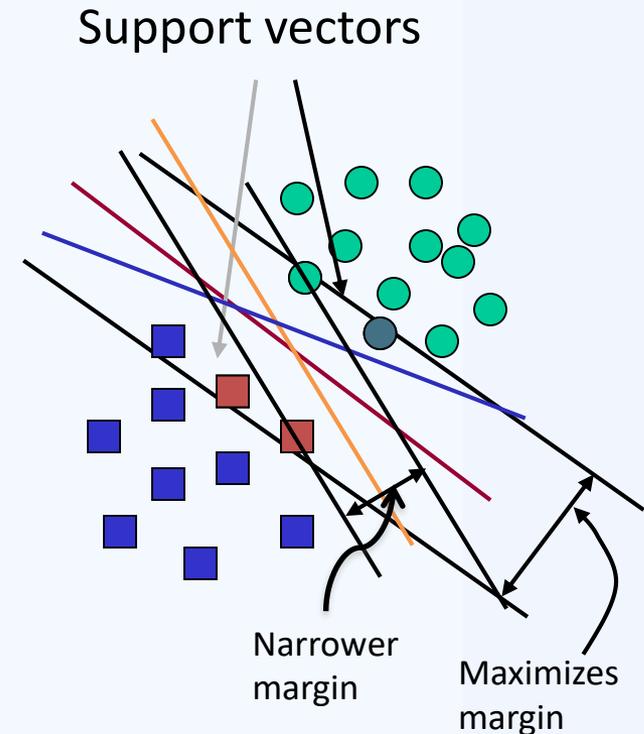
- ❖ Lots of possible solutions for a, b, c .
- ❖ Some methods find a separating hyperplane, but not the optimal one [according to some criterion of expected goodness]
 - ◆ E.g., perceptron
- ❖ Support Vector Machine (SVM) finds an optimal* solution.
 - ◆ Maximizes the distance between the hyperplane and the "difficult points" close to decision boundary
 - ◆ One intuition: if there are no points near the decision surface, then there are no very uncertain classification decisions

This line represents the decision boundary:
 $ax + by - c = 0$



Support Vector Machine (SVM)

- ❖ SVMs maximize the *margin* around the separating hyperplane.
- ❖ A.k.a. large margin classifiers
- ❖ The decision function is fully specified by a subset of training samples, *the support vectors*.
- ❖ Solving SVMs is a *quadratic programming* problem
- ❖ Seen by many as the most successful current classification method*

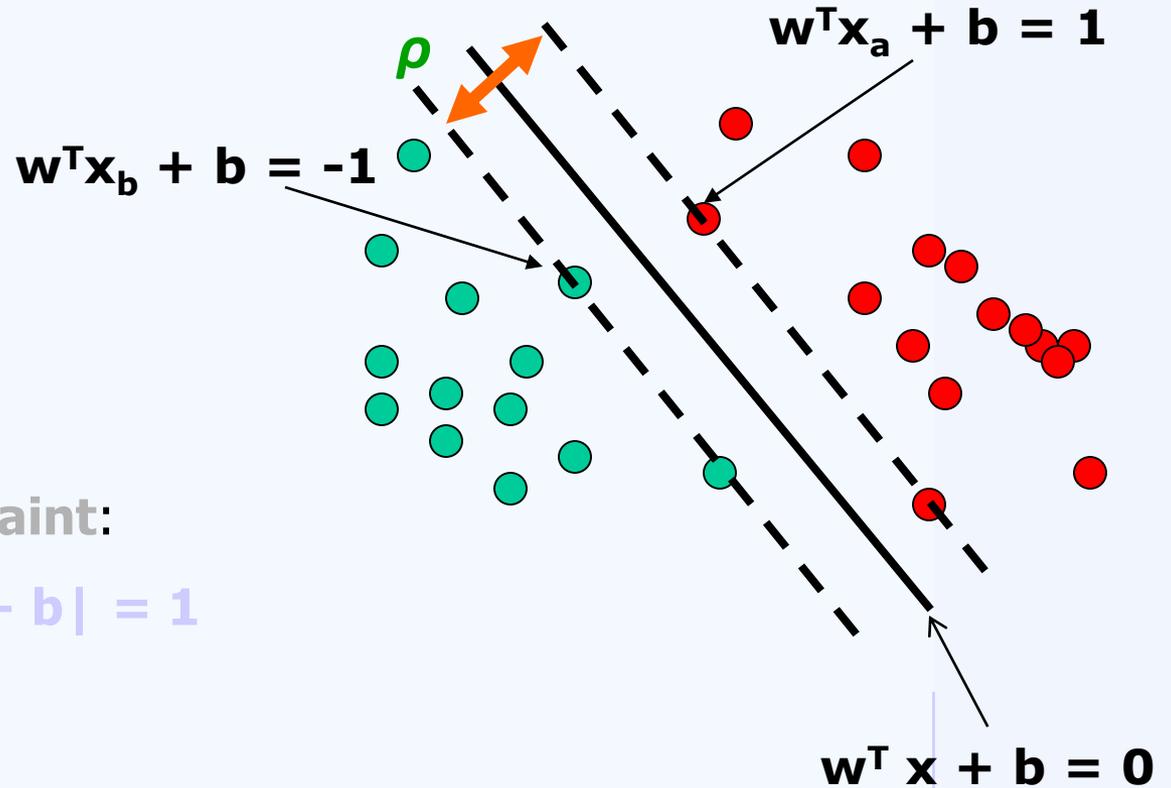


*but other discriminative methods often perform very similarly

Maximum Margin: Formalization

- ❖ \mathbf{w} : decision hyperplane normal vector
- ❖ \mathbf{x}_i : data point i
- ❖ y_i : class of data point i (+1 or -1) NB: Not 1/0
- ❖ Classifier is: $f(\mathbf{x}_i) = \text{sign}(\mathbf{w}^T \mathbf{x}_i + b)$
- ❖ Functional margin of \mathbf{x}_i is: $y_i (\mathbf{w}^T \mathbf{x}_i + b)$
 - ◆ But note that we can increase this margin simply by scaling \mathbf{w} , \mathbf{b}
- ❖ Functional margin of dataset is twice the minimum functional margin for any point
 - ◆ The factor of 2 comes from measuring the whole width of the margin

Linear Support Vector Machine



❖ Hyperplane

$$w^T x + b = 0$$

❖ Extra scale constraint:

$$\min_{i=1, \dots, n} |w^T x_i + b| = 1$$

❖ This implies:

$$w^T(x_a - x_b) = 2$$

$$\rho = \|x_a - x_b\|_2 = 2 / \|w\|_2$$

Classification with SVMs

❖ Given a new point \mathbf{x} , we can score its projection onto the hyperplane normal:

◆ I.e., compute score: $\mathbf{w}^T \mathbf{x} + b = \sum a_i y_i \mathbf{x}_i^T \mathbf{x} + b$

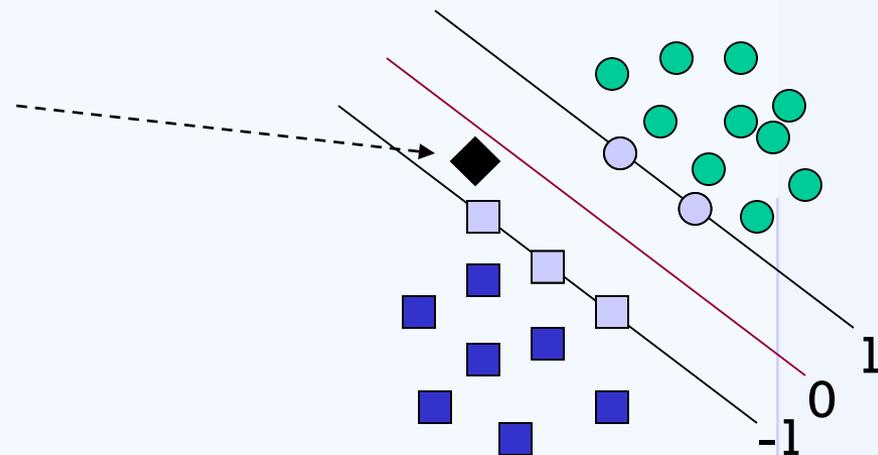
❖ Decide class based on whether $<$ or $>$ 0

◆ Can set confidence threshold t .

Score $> t$: yes

Score $< -t$: no

Else: don't know



Linear SVMs: Summary

- ❖ The classifier is a *separating hyperplane*.
- ❖ The most “important” training points are the support vectors; they define the hyperplane.
- ❖ Quadratic optimization algorithms can identify which training points \mathbf{x}_i are support vectors with non-zero Lagrangian multipliers α_i .
- ❖ Both in the dual formulation of the problem and in the solution, training points appear only inside inner products:

Find $\alpha_1 \dots \alpha_N$ such that

$\mathbf{Q}(\boldsymbol{\alpha}) = \sum \alpha_i - \frac{1}{2} \sum \sum \alpha_i \alpha_j y_i y_j \mathbf{x}_i^T \mathbf{x}_j$ is maximized and

(1) $\sum \alpha_i y_i = 0$

(2) $0 \leq \alpha_i \leq C$ for all α_i

$$f(\mathbf{x}) = \sum \alpha_i y_i \mathbf{x}_i^T \mathbf{x} + b$$

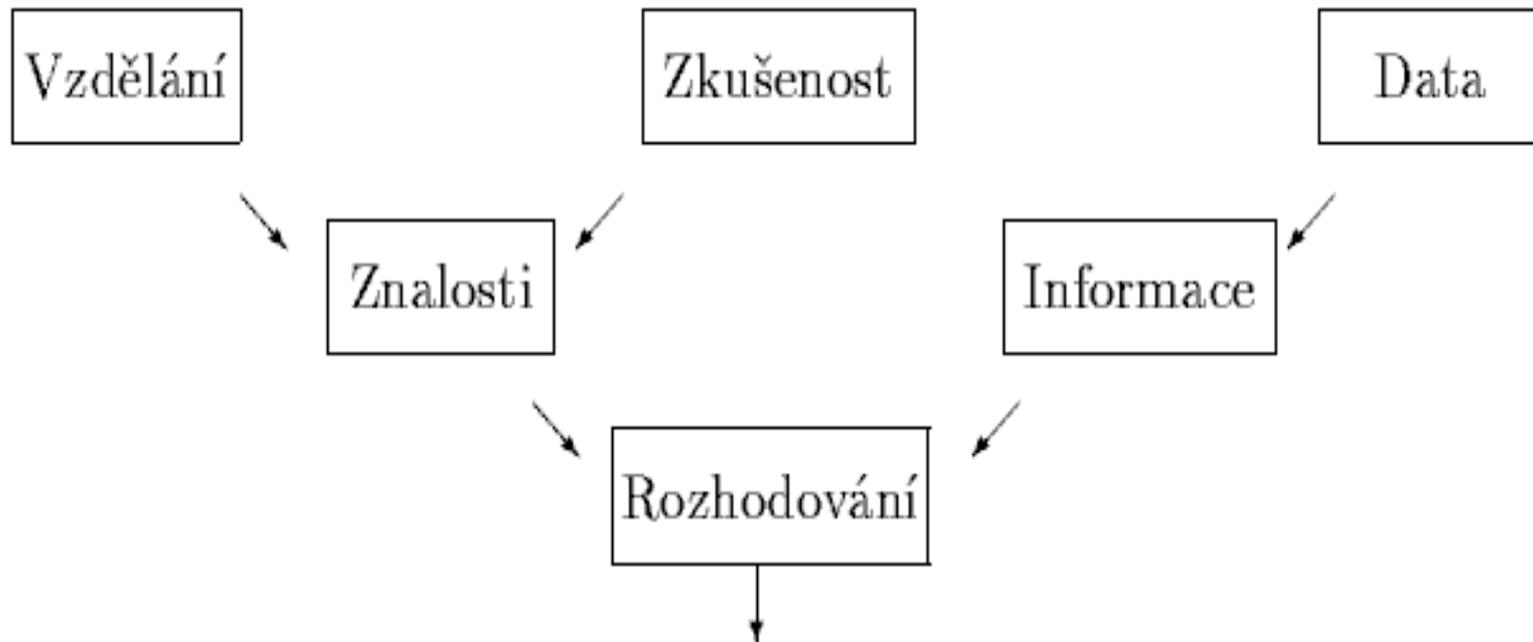


Expertní, DSS a CBR systémy

Způsoby reprezentace znalostí

- ❖ predikátová logika
- ❖ sémantické sítě
- ❖ rámce
- ❖ **pravidla**
 - ◆ procedurální sémantika
JESTLIŽE situace PAK akce
 - ◆ deklarativní sémantika
JESTLIŽE předpoklad PAK závěr

Data a znalosti v procesu rozhodování



Expertní systémy



Počítačové programy simulující rozhodovací činnost lidského experta při řešení složitých úloh a využívající vhodně zakódovaných speciálních znalostí převzatých od experta s cílem dosáhnout ve zvolené problémové oblasti kvality rozhodování na úrovni experta.

Expertní systémy



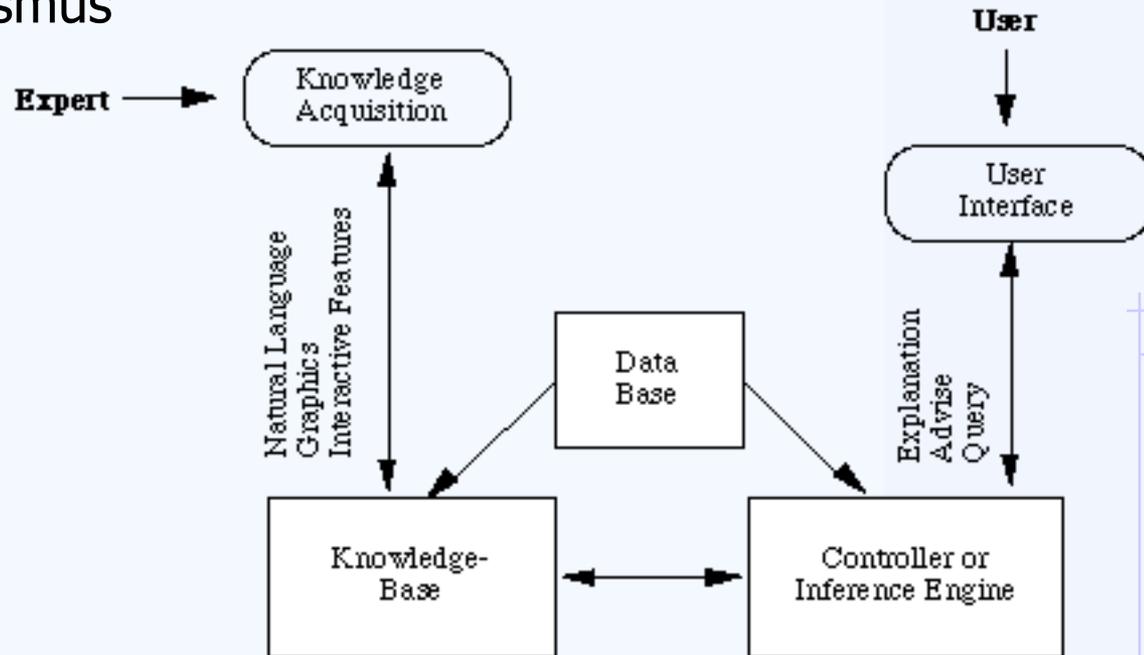
❖ Tři části

- ◆ Báze dat
- ◆ Báze znalostí
- ◆ Inferenční mechanismus

❖ Zajímavý problém získání znalostí od experta

❖ Práce s neurčitostí

❖ Možnost automatického rozšiřování báze znalostí pomocí učení



Role expertního systému

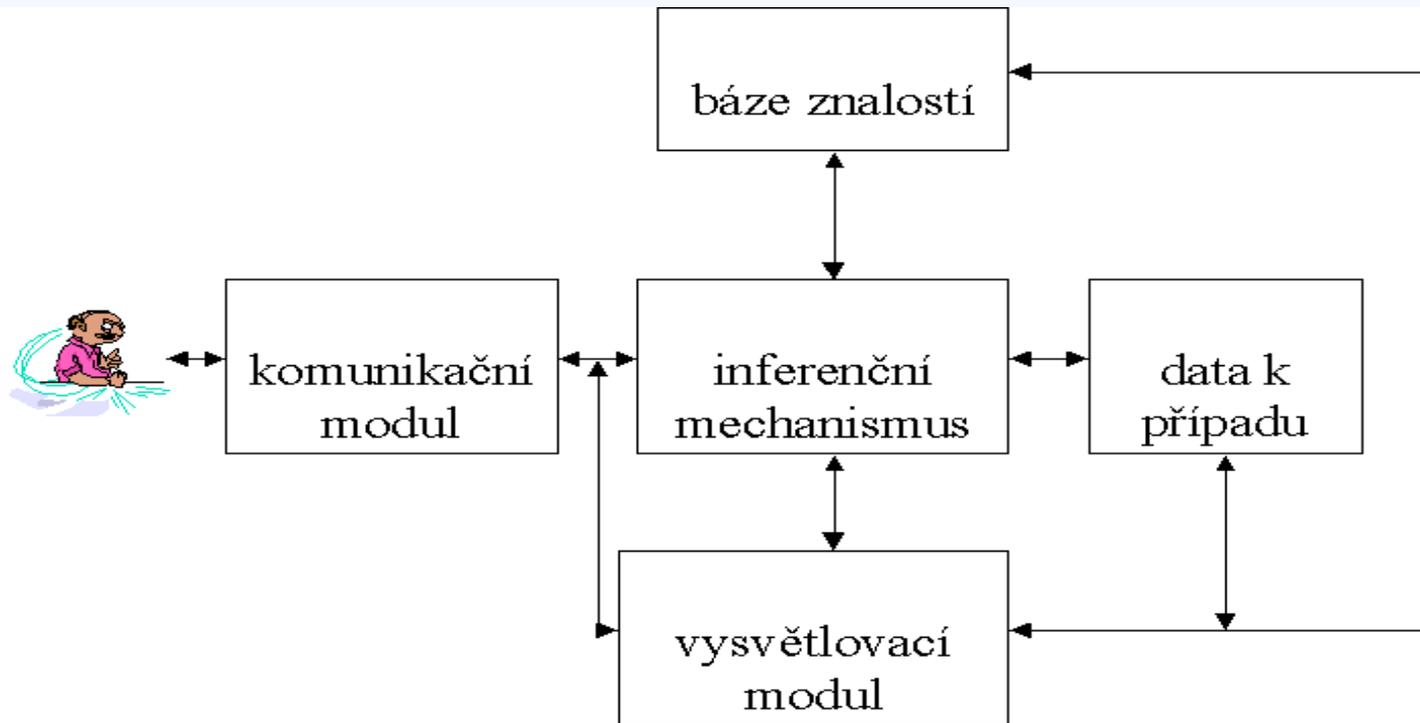
- ❖ expert
- ❖ kolega
- ❖ asistent

Charakteristické rysy expertního systému



- ❖ oddělení znalostí a mechanismu pro jejich využívání
- ❖ neurčitost v bázi znalostí
- ❖ neurčitost v datech
- ❖ dialogový režim
- ❖ vysvětlovací činnost
- ❖ modularita a transparentnost báze znalostí

Schéma expertního systému



Typy expertních systémů



❖ Diagnostické

- ◆ diagnóza (MYCIN, INTERNIST)
- ◆ interpretace (DENDRAL, PROSPECTOR)
- ◆ monitorování (VM)

❖ Generativní

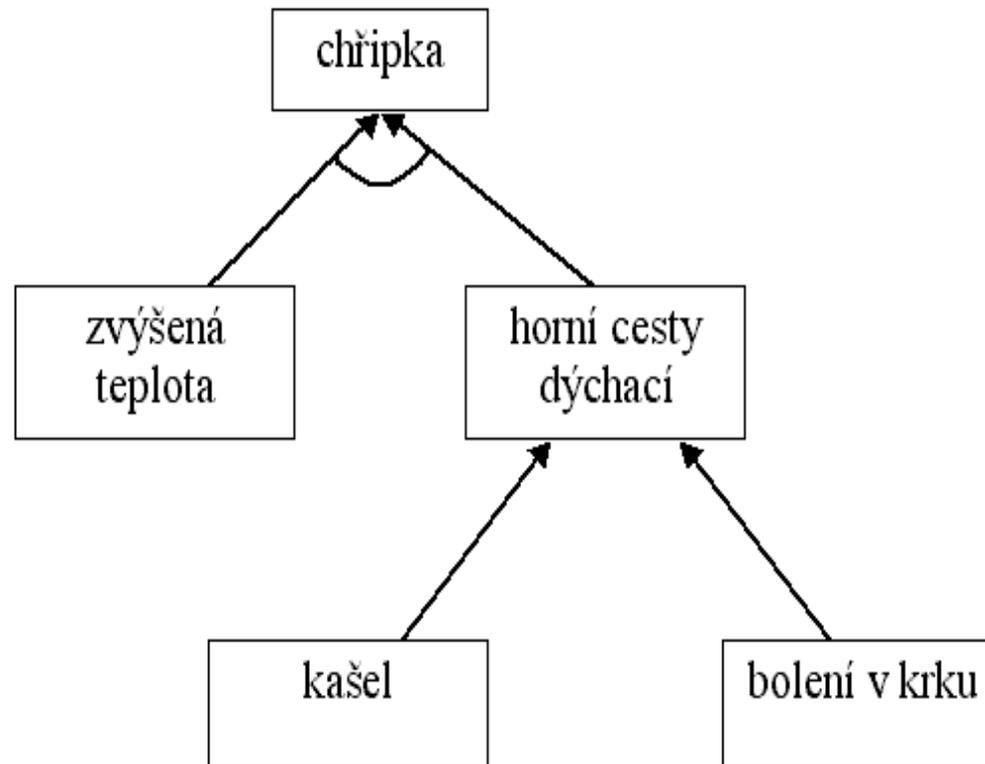
- ◆ návrh (R1/XCON)
- ◆ plánování (MOLGEN)
- ◆ predikce (GLAUKOMA)

Atributy a výroky

- ❖ výrok (auto má červenou barvu)
- ❖ atribut, hodnota (barva_auta = červená)
- ❖ objekt, atribut, hodnota (auto_25: barva = červená)

- ❖ typy atributů:
 - ◆ kategoriální (binární, nominální, ordinální)
 - ◆ numerické

Inferenční síť



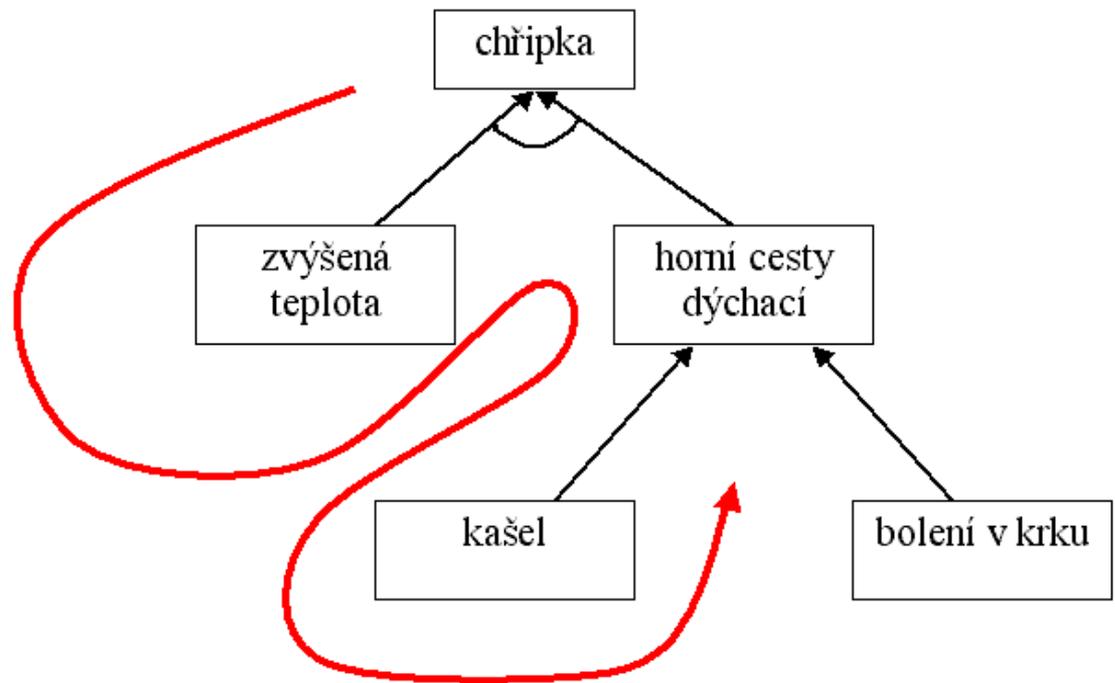
- ❖ uzly = tvrzení (dotazy, cíle, mezilehlé uzly)
- ❖ hrany = pravidla

Metody inference

- ❖ logické metody (dedukce, abdukce, indukce)
- ❖ zpětné nebo přímé řetězení
- ❖ generování a testování
- ❖ využití analogií

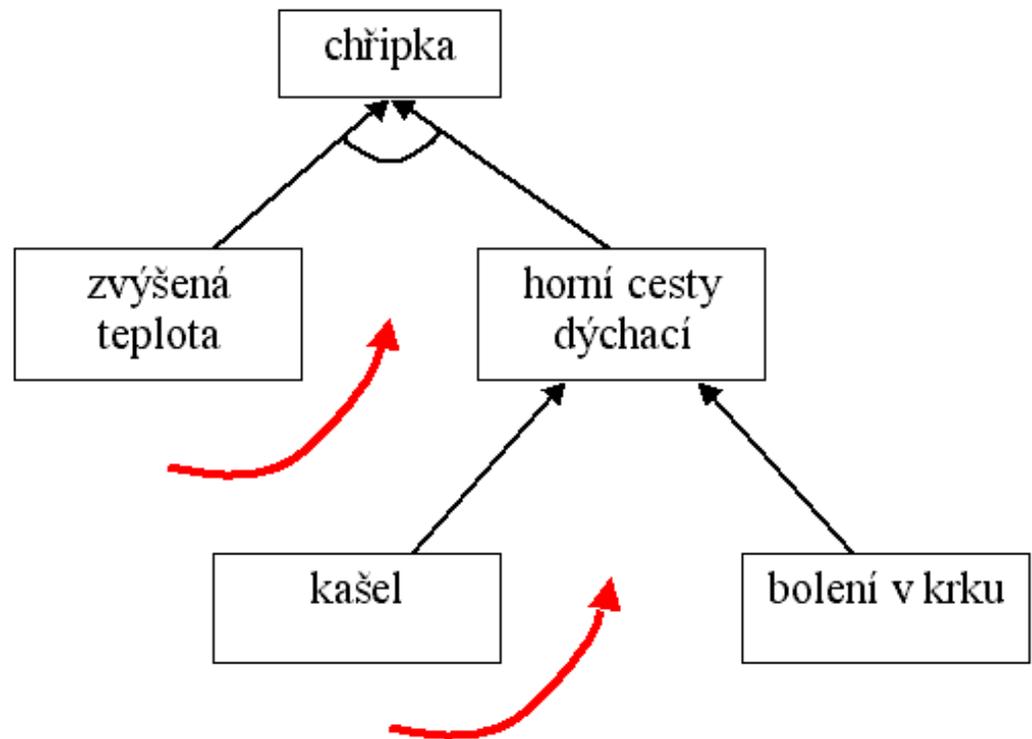
Zpětné řetězení

❖ Vycházíme z cílů, které chceme odvodit a pokoušíme se nalézt pravidla umožňující tyto cíle potvrdit i vyvrátit



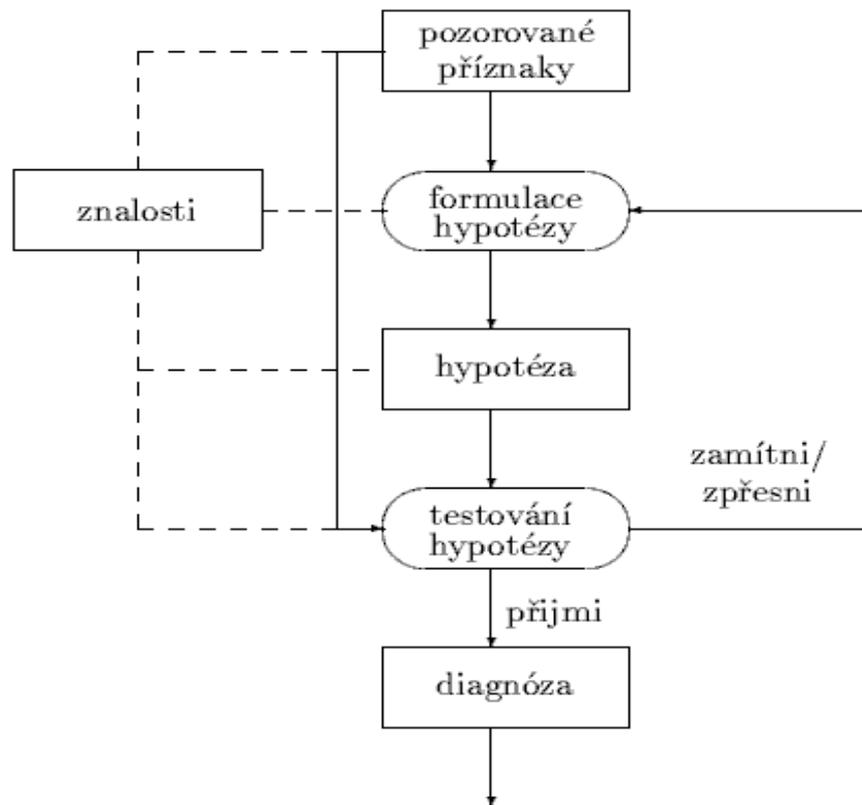
Přímé řetězení

❖ Vycházíme z faktů, které jsou splněna a pokoušíme se nalézt aplikovatelná pravidla



Inference v diagnostických systémech

- ❖ prohledávání báze (zpětné nebo přímé řetězení)
- ❖ aplikace pravidla (dedukce)



Neurčitost



❖ Ve znalostech

- ◆ Žadatel s vysokým příjmem splatí úvěr bez problémů
- ◆ Žadatel s vysokým příjmem nejspíš splatí úvěr

❖ V datech

- ◆ Žadatel o úvěr má měsíční příjem 20 500 korun
- ◆ Žadatel o úvěr má vysoký měsíční příjem
- ◆ Žadatel o úvěr má měsíční příjem asi 20 000 korun
- ◆ Žadatel o úvěr má asi vysoký měsíční příjem

Vyjádření neurčitosti

- ❖ trojhodnotová logika
- ❖ pseudopravděpodobnost (Bayesův vztah)
- ❖ míry důvěry a nedůvěry
- ❖ váhy (algebraická teorie)

Trojhodnotová logika



- ❖ Ke dvěma „standardním“ hodnotám 1 (true) a 0 (false) se přidává třetí hodnota X (unknown).
- ❖ Tato hodnota umožní vyjádřit, že pravdivostní hodnota nějakého tvrzení není známa:

A	$\neg A$		$A \wedge B$	0	X	1
0	1		0	0	0	0
X	X		X	0	X	X
1	0		1	0	X	1

negace

konjunkce

A	$\vee B$	0	X	1		$A \Rightarrow B$	0	X	1
0	0	X	1		0	1	1	1	
X	X	X	1		X	X	X	1	
1	1	1	1		1	0	X	1	

disjunkce

implikace

ké

ké

Pseudopravděpodobnostní přístup

❖ Míra postačitelnosti

$$L = \frac{P(E, H)}{P(E, \bar{H})}$$

❖ Míra nezbytnosti

$$\bar{L} = \frac{P(\bar{E}, H)}{P(\bar{E}, \bar{H})}$$

Míry důvěry a nedůvěry

- ❖ Míra důvěry (measure of belief)

$$MB(H, E) = \frac{P(H, E) - P(H)}{1 - P(H)}$$

- ❖ Míra nedůvěry (measure of disbelief)

$$MD(H, E) = \frac{P(H) - P(H, E)}{P(H)}$$

- ❖ Faktor jistoty $CF(H, E) = MB(H, E) - MD(H, E)$

Algebraická teorie

pro znalosti v podobě pravidel

předpoklad \Rightarrow závěr (váha)

- ❖ výpočet váhy předpokladu (NEG, CONJ, DISJ)
- ❖ výpočet příspěvku váhy předpokladu k váze závěru (CTR)
- ❖ Kombinování vah pravidel se stejným závěrem (GLOB)

Vysvětlování



- ❖ důvody pro vysvětlování
 - ◆ uživatel získá větší důvěru v závěry systému
 - ◆ tvůrce aplikace může lépe ladit bázi znalostí

- ❖ typické možnosti vysvětlování
 - ◆ why (proč systém klade tento dotaz)
 - ◆ how (jak systém odvodil své doporučení)

Faktory úspěchu

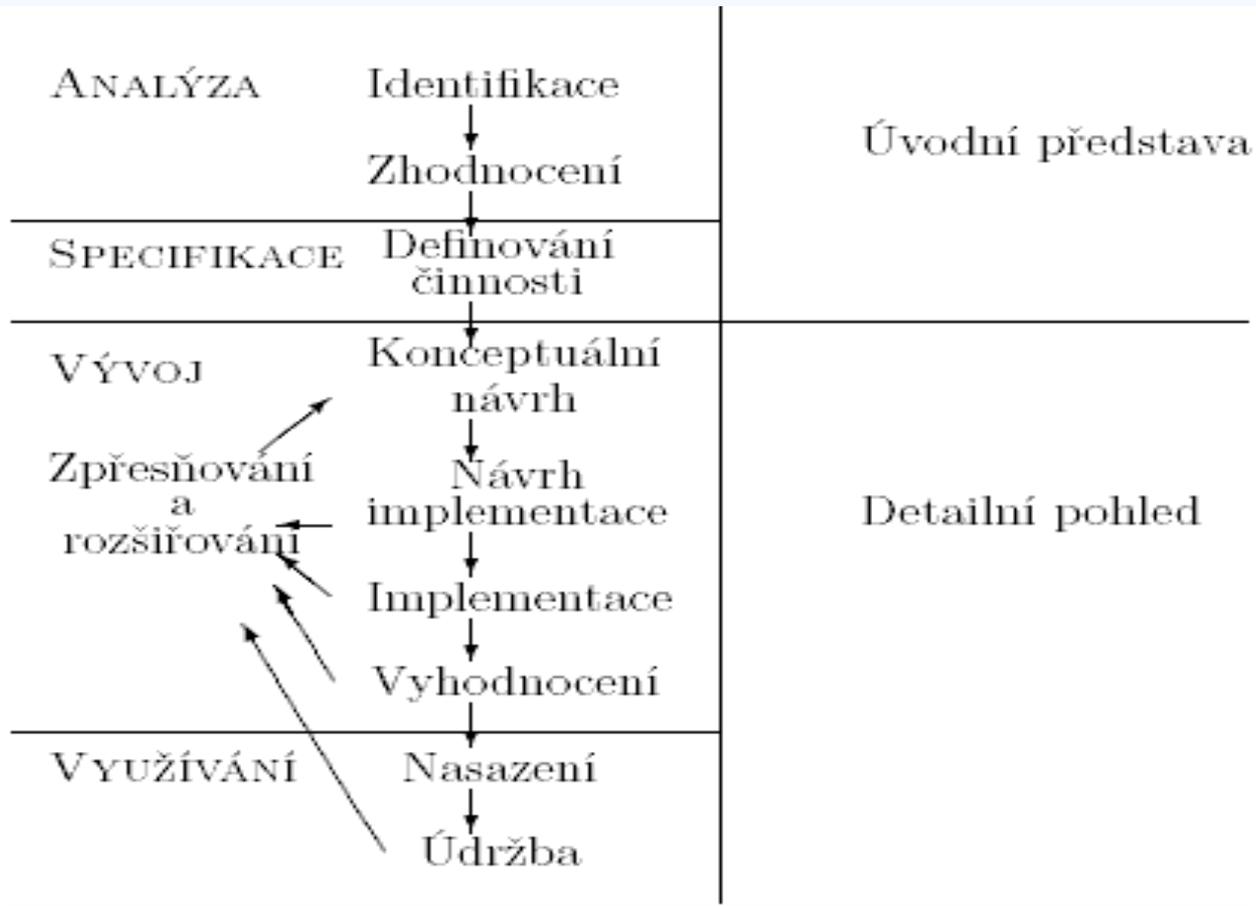


- ❖ Důvody pro aplikaci
 - ◆ expert není přímo k dispozici
 - ◆ expert odchází a je třeba zaškolit zástupce
 - ◆ snaha zajistit standardizaci způsobu rozhodování

- ❖ Zkušenosti z úspěšných projektů
 - ◆ získejte experta pro spolupráci
 - ◆ zaměřte se na koncového uživatele
 - ◆ použijte inkrementální způsob vývoje

Vývoj znalostního systému

softwarový projekt, klíčovou roli hrají **znalosti**



Výhody použití expertních systémů

- ❖ zvýšená dostupnost expertízy
- ❖ snížené náklady na provedení expertízy
- ❖ trvalost expertízy
- ❖ opakovatelnost expertízy
- ❖ rychlá odezva

Limitující faktory



- ❖ chybějí efektivnější techniky získávání znalostí
- ❖ chybějí přesné testovací procedury
- ❖ nedostatečné integrování do používaných technologií
- ❖ znalostní inženýři kladou malý důraz na aplikační oblast



CBR – případové usuzování

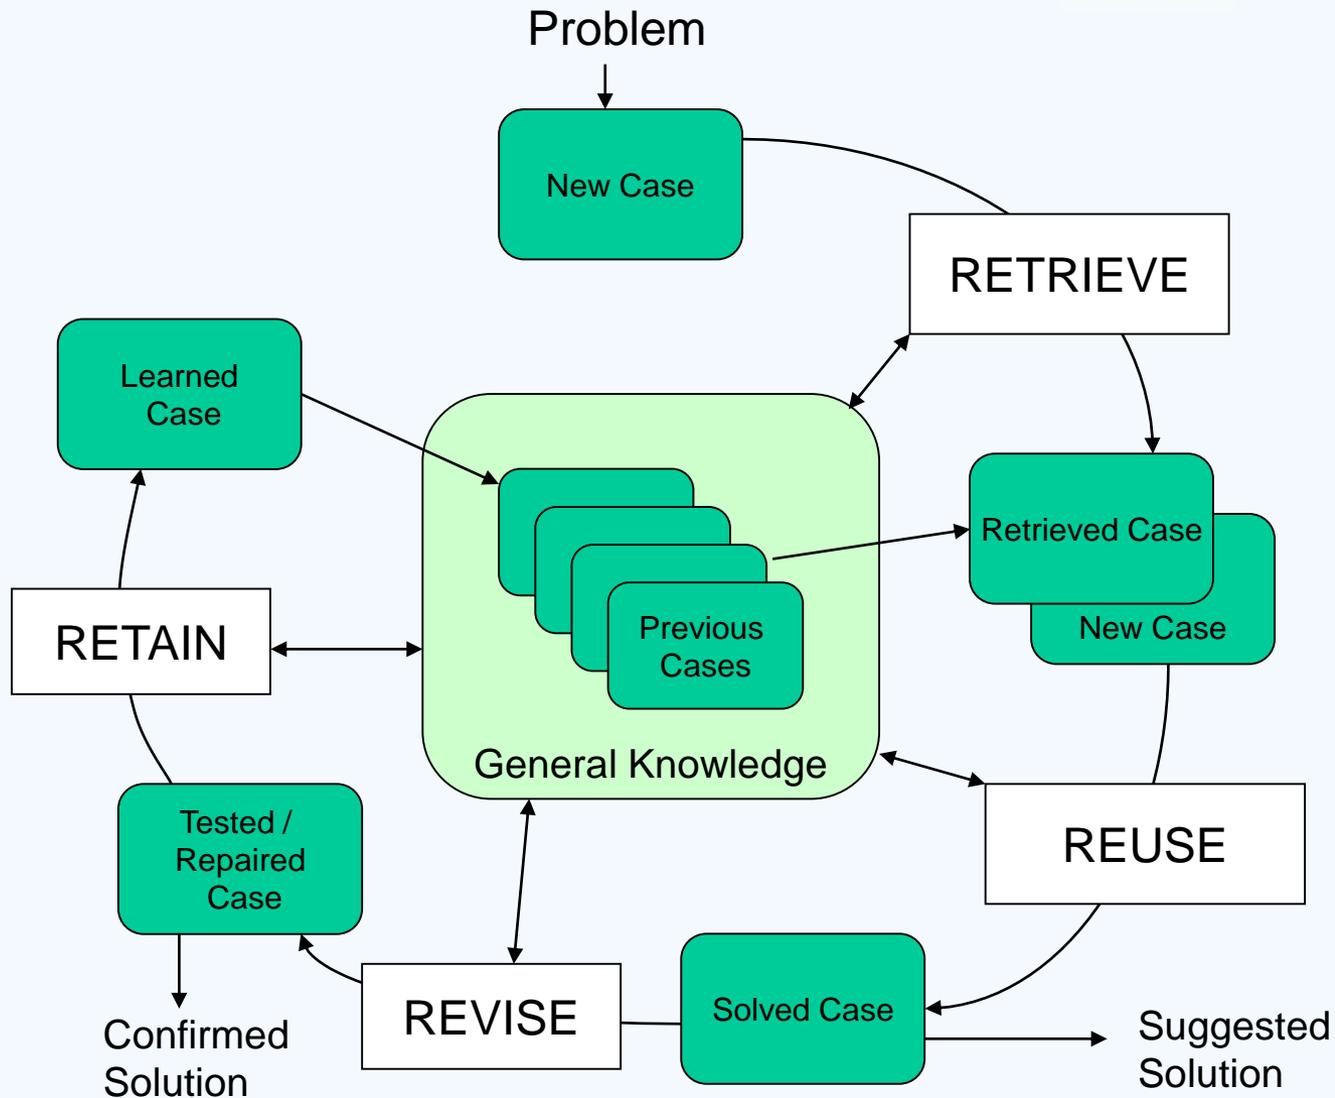
Case based reasoning



❖ Case-Based reasoning (CBR), broadly construed, is the process of solving new problems based on the solutions of similar past problems.

❖ Reasoning by remembering

Case based reasoning



CBR cycle - Retrieve



- ❖ One or several cases from the case base are selected, based on the modeled similarity.
- ❖ The retrieval task is defined as finding a small number of cases from the case-base with the highest similarity to the query.
- ❖ This is a k-nearest-neighbor retrieval task considering a specific similarity function.
- ❖ When the case base grows, the efficiency of retrieval decreases => methods that improve retrieval efficiency, e.g. specific index structures such as kd-trees, case-retrieval nets, or discrimination networks.

CBR cycle - Reuse



- ❖ Reusing a retrieved solution can be quite simple if the solution is returned unchanged as the proposed solution for the new problem.
- ❖ Adaptation (if required, e.g. for synthetic tasks).
- ❖ Most practical CBR applications today try to avoid extensive adaptation for pragmatic reasons.

CBR cycle - Revise

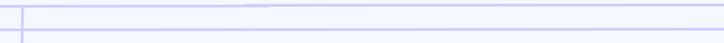


- ❖ In this phase, feedback related to the solution constructed so far is obtained.
- ❖ This feedback can be given in the form of a correctness rating of the result or in the form of a manually corrected revised case.
- ❖ The revised case or any other form of feedback enters the CBR system for its use in the subsequent retain phase.

CBR cycle - Retain



- ❖ The retain phase is the learning phase of a CBR system (adding a revised case to the case base).
- ❖ Explicit competence models have been developed that enable the selective retention of cases (because of the continuous increase of the case-base).
- ❖ The revised case or any other form of feedback enters the CBR system for its use in the subsequent retain phase.



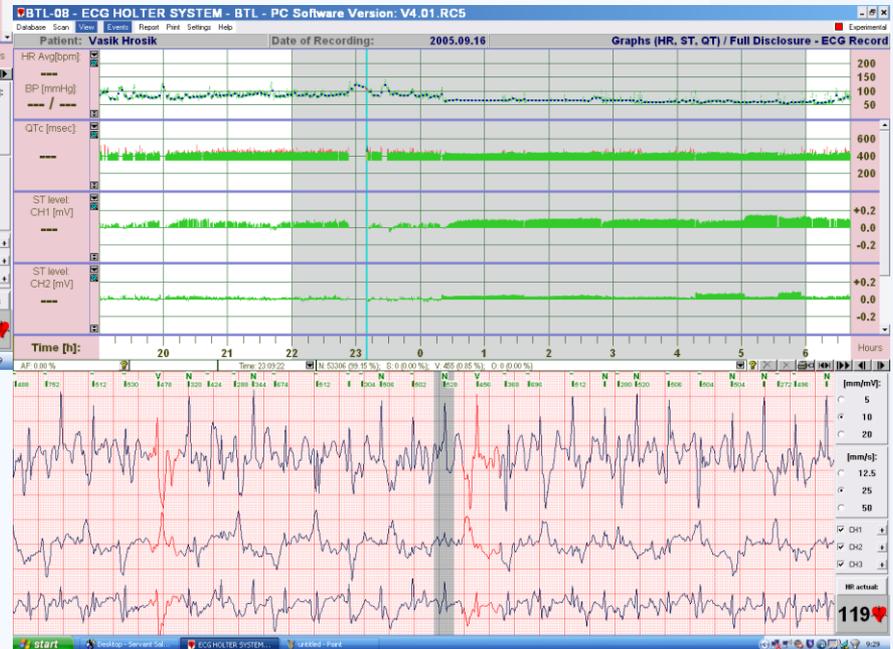


Příklady využití klasifikace

Holter



❖ Demonstrace variability signálu při holterovském měření

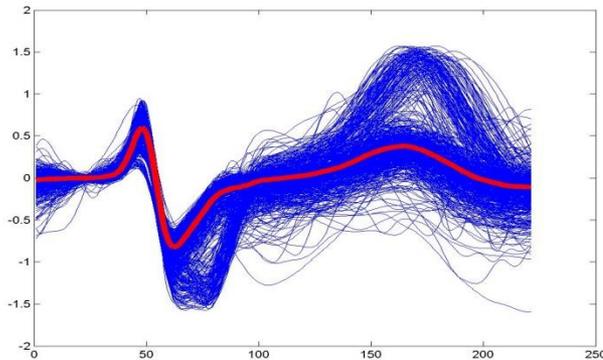


❖ Je třeba velké robustnosti jak u analýzy signálu tak při diagnostice

Chudáček, V. - Georgoulas, G. - Lhotská, L. - Stylios, C. - Petřík, M. - et al.

Examining Cross-Database Global Training to Evaluate Five Different Methods for Ventricular Beat Classification, In:

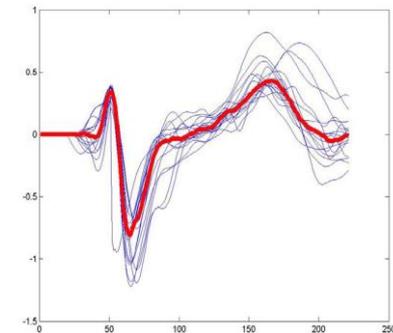
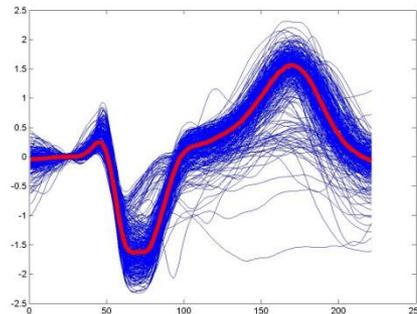
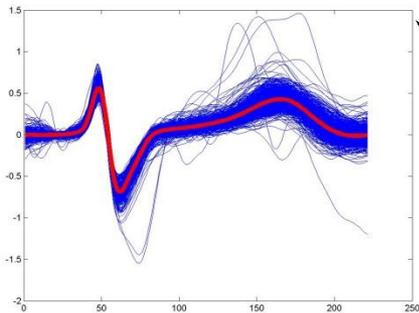
Holter příklad



❖ Roztřídění (clustering) beatů z holterovského EKG záznamu

❖ Na základě změřených parametrů vypočítán medián

❖ Cíl: Koherentní skupina pro další diagnostiku

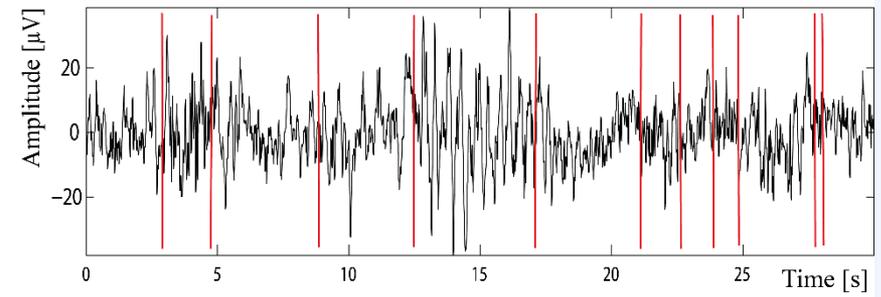
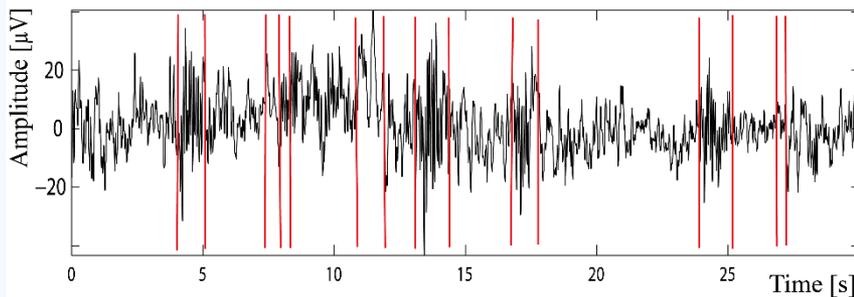
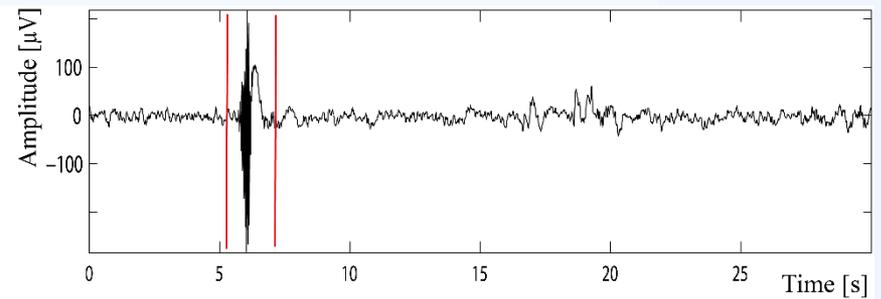
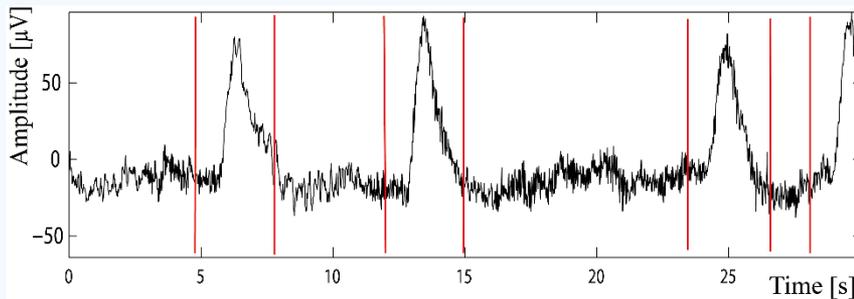


Signal segmentation



We used constant or adaptive segmentation in our experiments (according to the specific tasks)

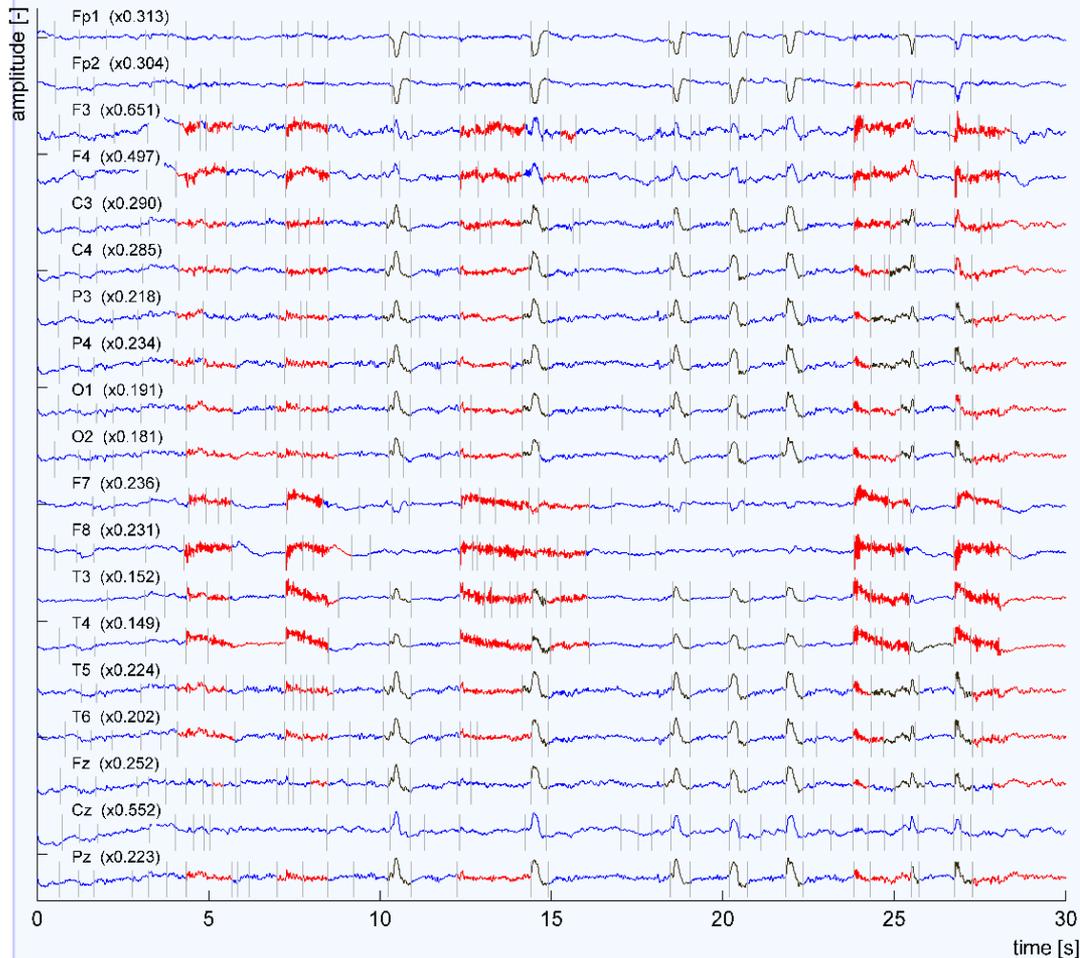
Example of adaptive segmentation of one EEG signal:



Phase 3



Automatic classification of recording



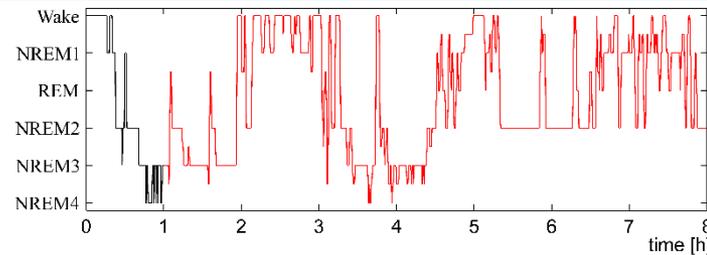
- **statistical features** (mean, standard deviation, kurtosis, skewness, median, 2nd and 3rd Hjorth parameters)
- **frequency features computed for typical EEG bands** (delta to gamma)
- **features obtained by interval or period analysis** (distributions between maxima and minima or between zero and other levels crossing)
- **entropy-based features**
We can also use
- **features extracted after application of the Wavelet Transform**

Sleep EEG data classification

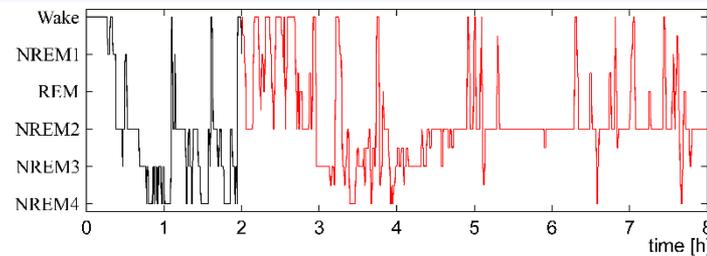


Example of incremental learning process on long-term sleep EEG data

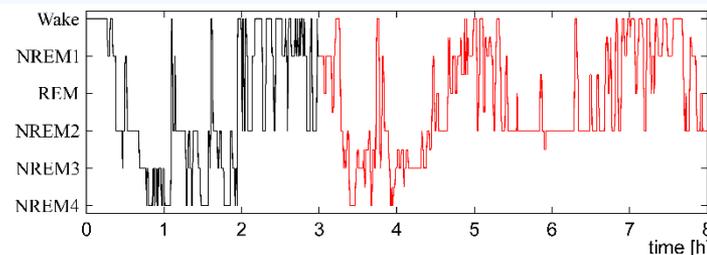
1



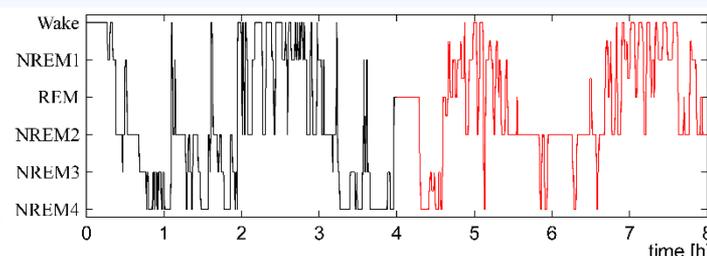
2



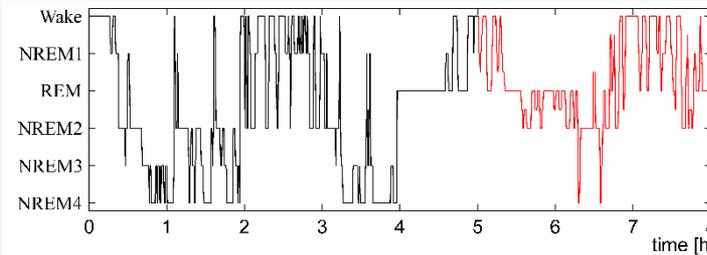
3



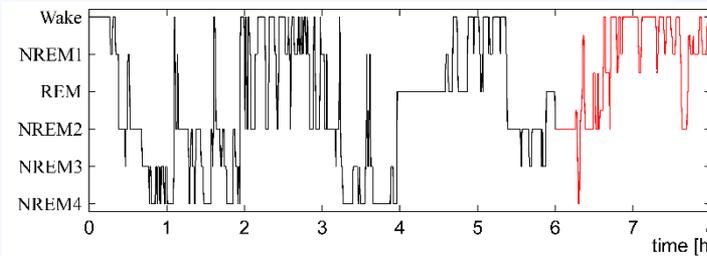
4



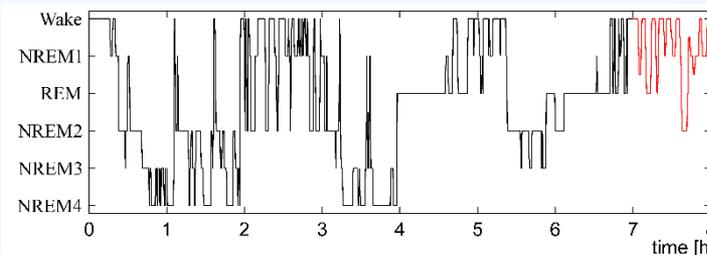
5



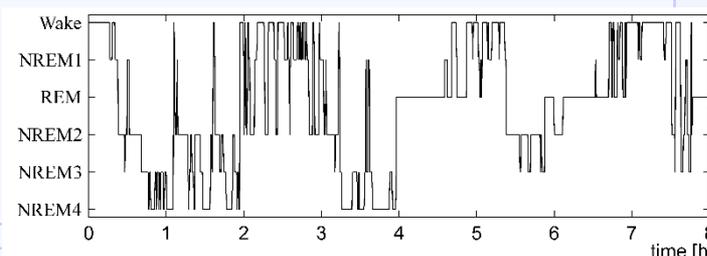
6



7



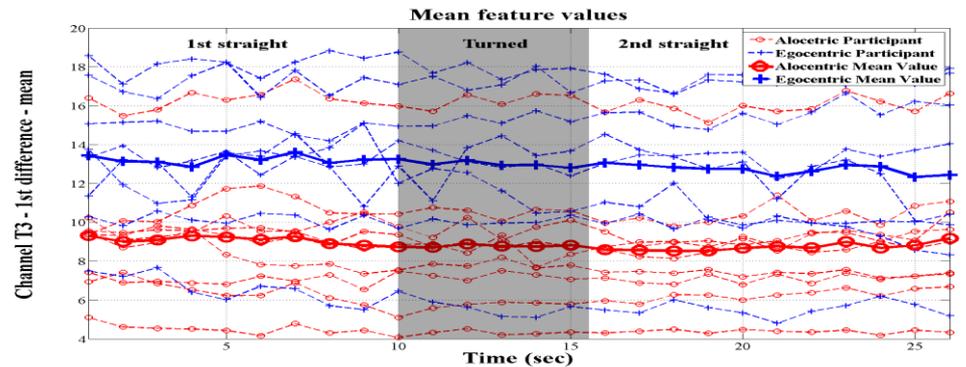
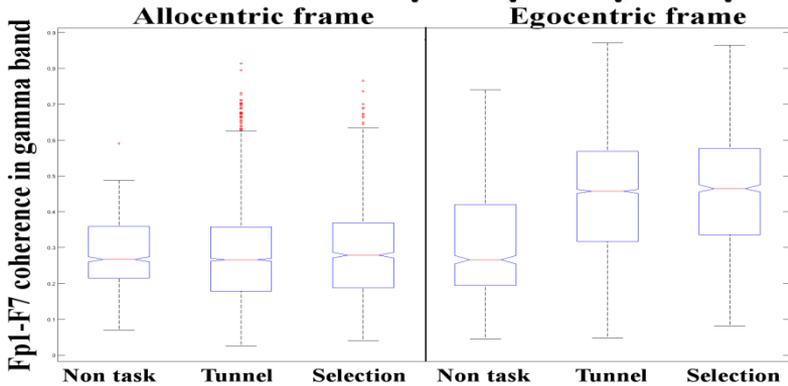
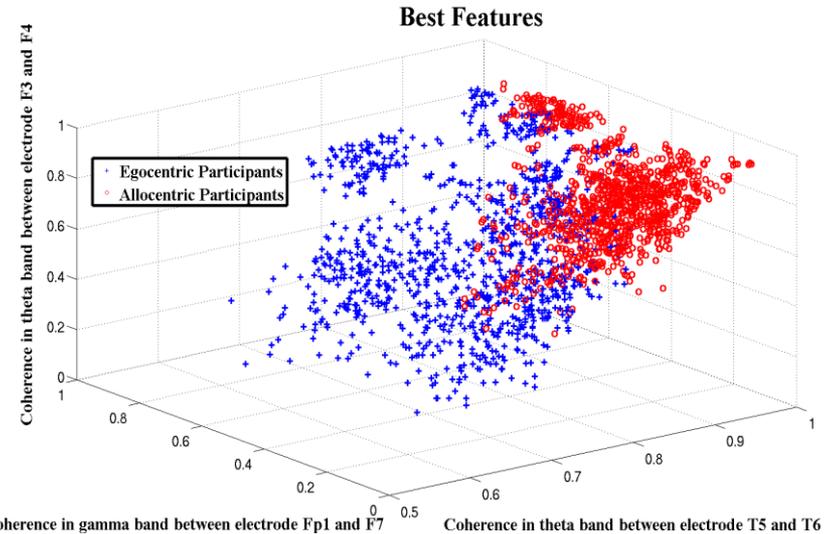
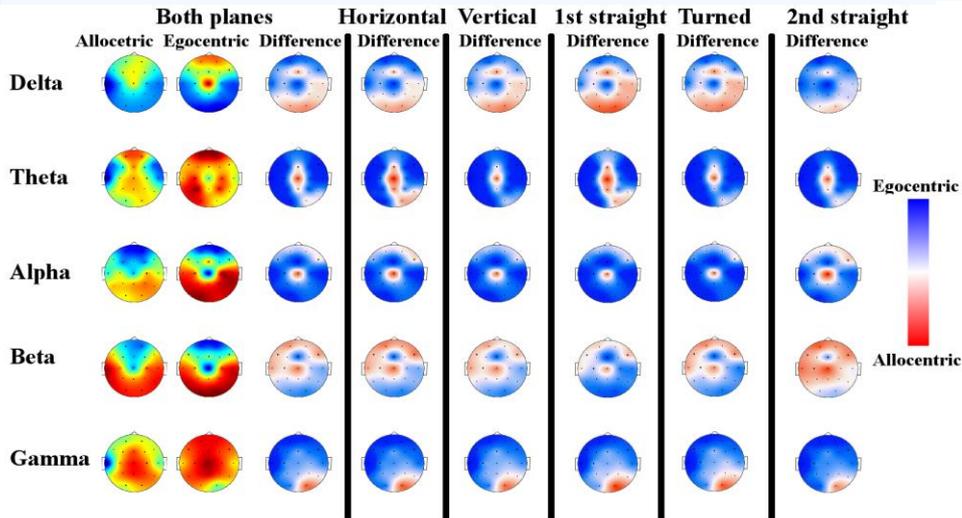
8



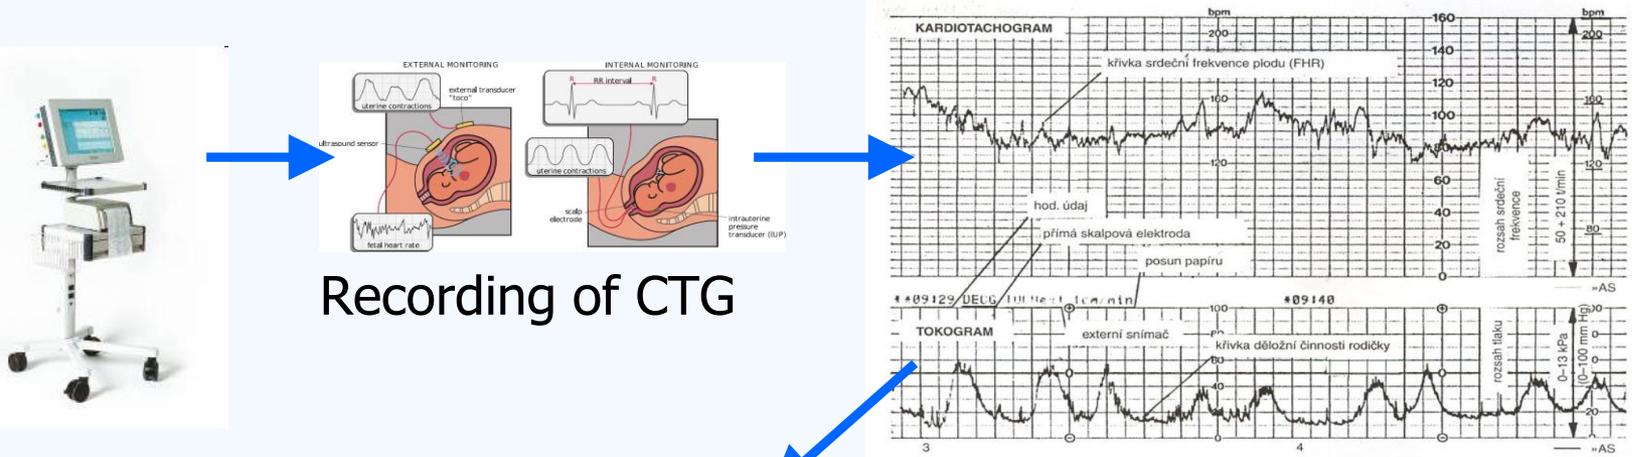
Spatial navigation



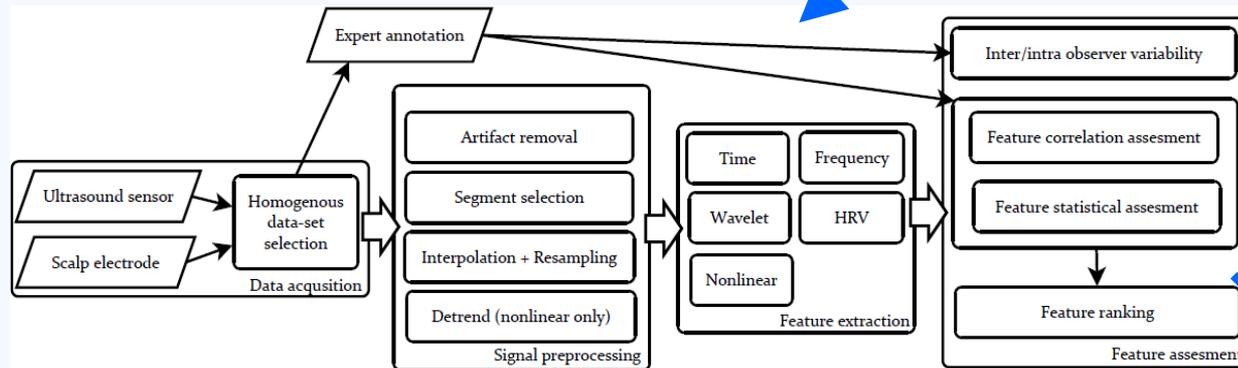
Intrahemispheric and interhemispheric coherences resulted in 10% lower error rates comparing to features in previous studies. There were new navigation strategies identified.



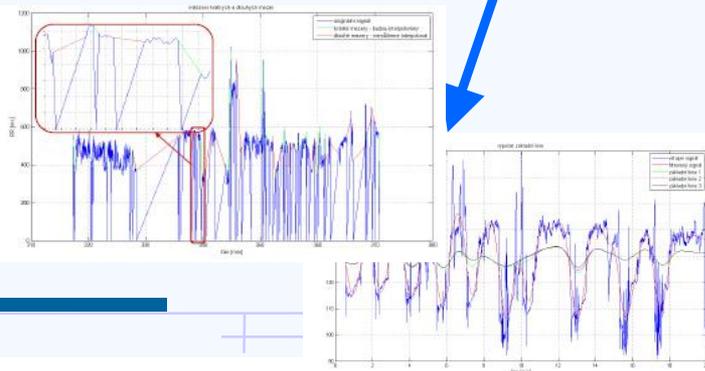
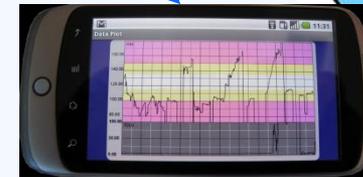
CTG analysis – general view



Recording of CTG



- ❖ Pre-processing
- ❖ Feature extraction
- ❖ Feature Selection
- ❖ Diagnosis/Classification
- ❖ Visualization





- ❖ Description of database

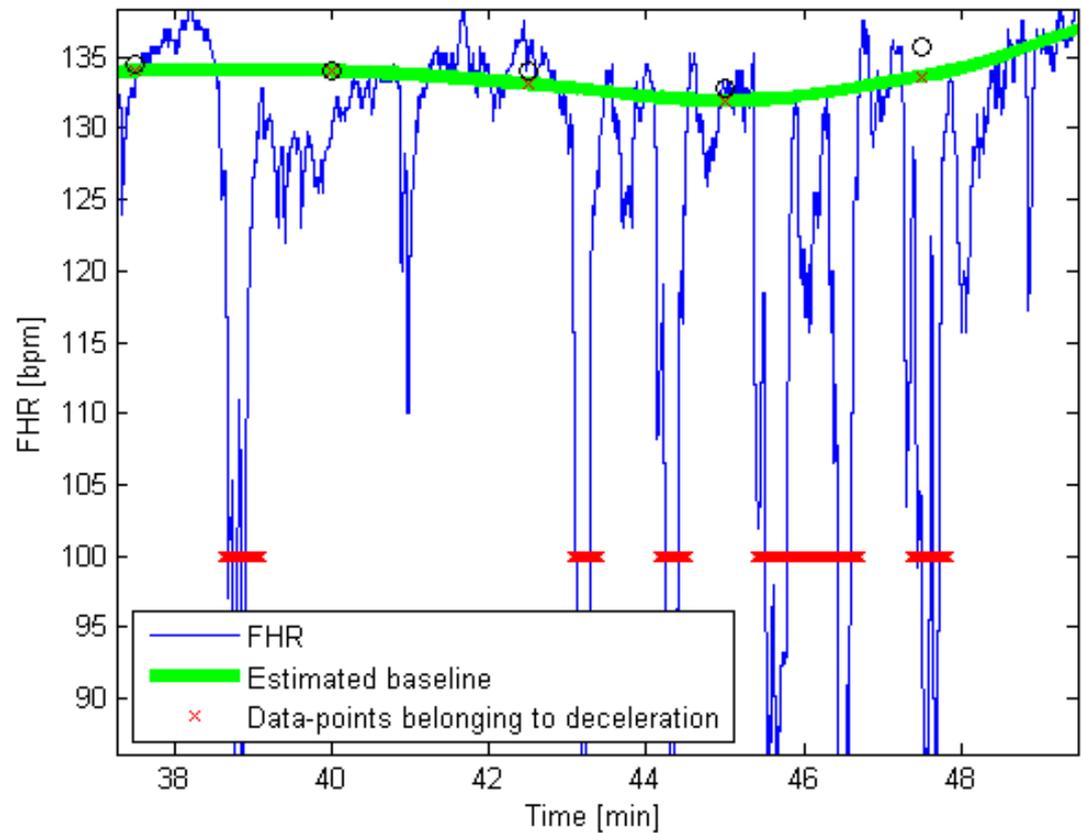
- ❖ Signal pre-processing

- ◆ Artefact detection
- ◆ feature-significant noise estimation
- ◆ Baseline estimation

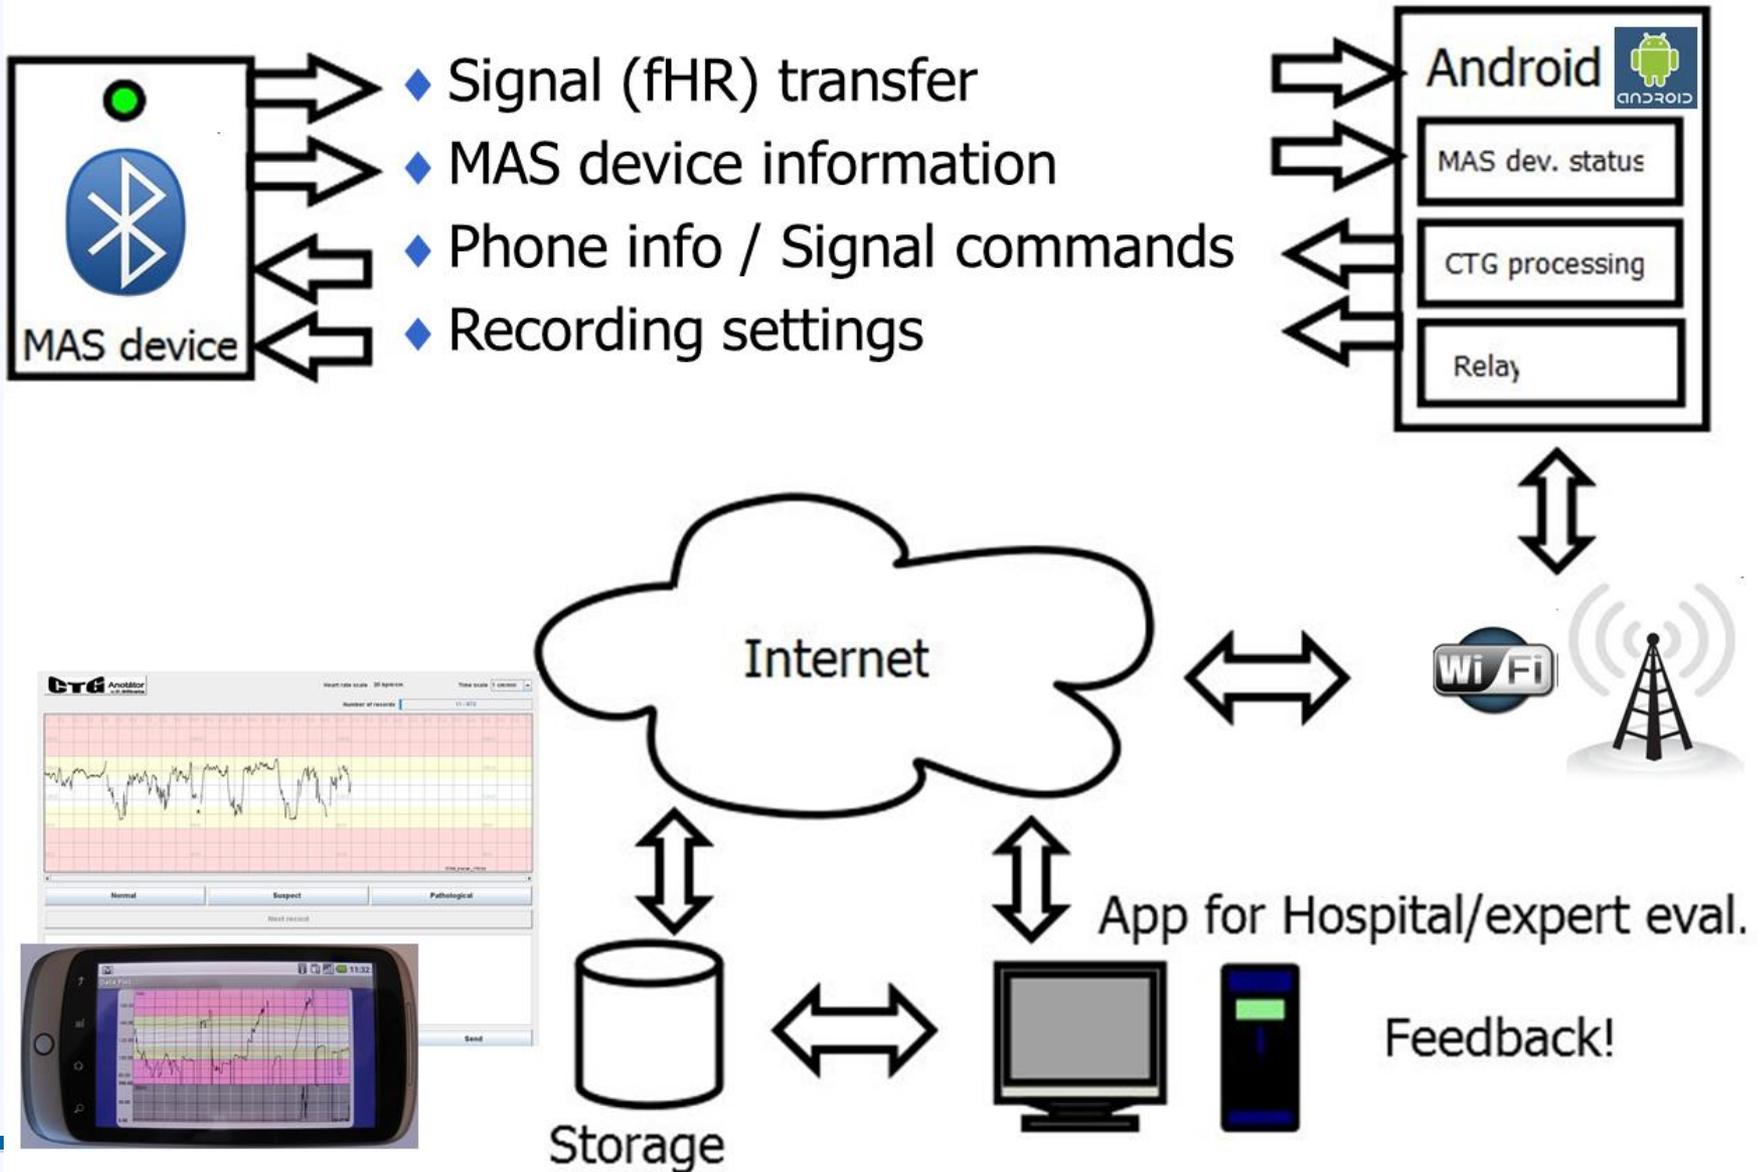
- ❖ Feature extraction

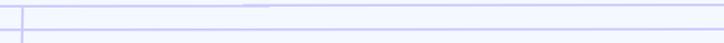
- ◆ Parametrizace izolinie
- ◆ Parametrizace decelerací
- ◆ FIGO guidelines

Example of FHR-baseline estimation on recording from CTU-UHB db



SW proposal for the MAS project







Selected Practical Aspects of Automated FHR Analysis

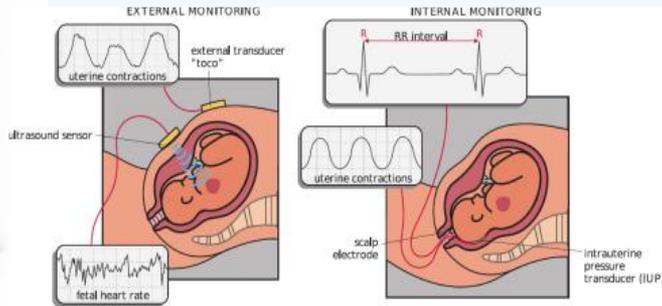
Václav Chudáček

**CTG analysis group
Czech Institute of Informatics, Robotics and Cybernetics
CTU in Prague**



Context of the work

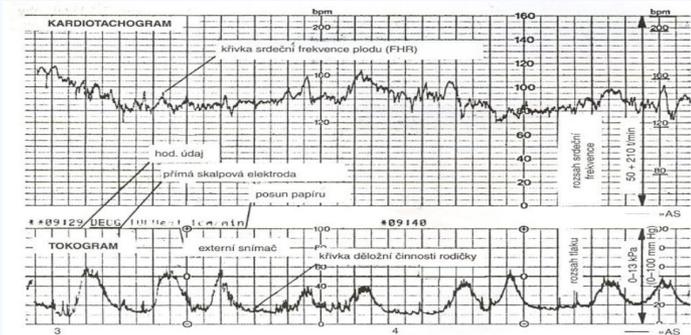
Intro: Current state of evaluation



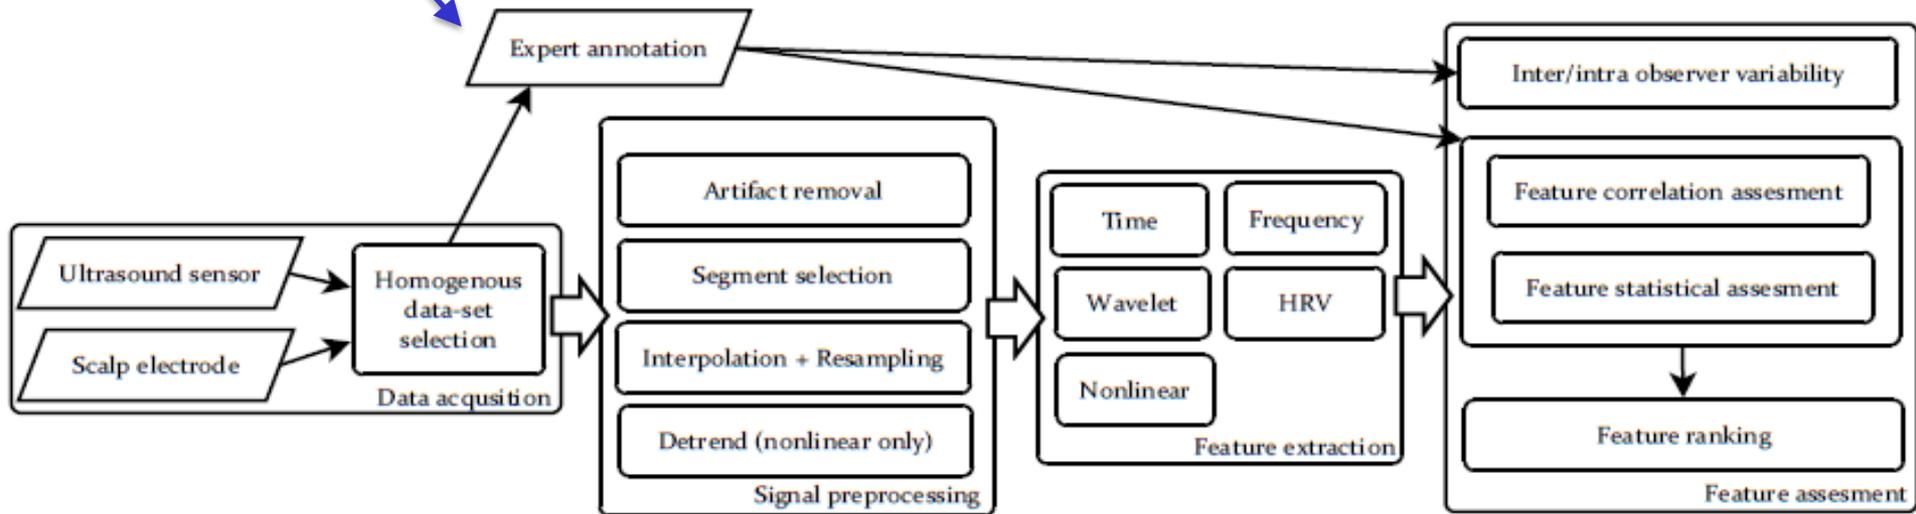
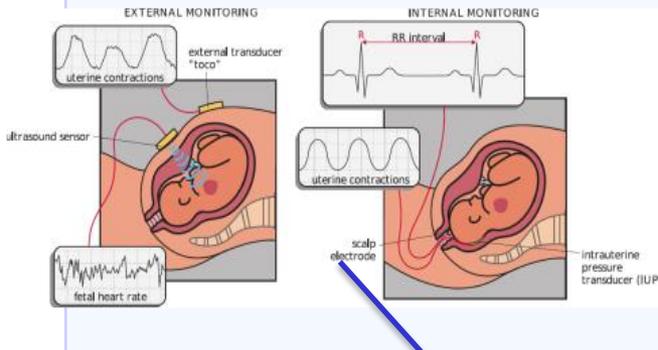
- ❖ FHR is measured by US or fECG
- ❖ Signs of hypoxia are sought for
- ❖ Decision are made based on FHR and clinical data

❖ Outcomes:

- ❖ Healthy babies
- ❖ Caesarean sections (20-50% in CZ)
- ❖ Pathological pH (1-3%) → severe cases may result in neurological damage such as cerebral palsy etc.



Intro: Automated analysis?



❖ Machine representation of FHR is used



Sources of motivation and frustration

"Wisdom comes from experience. Experience is often a result of lack of wisdom."
- *Terry Pratchett*

General



❖ Automated analysis?

❖ Ill defined inputs

- ❖ Databases in general – small, and very difficult to compare
- ❖ CTG segment used for evaluation – how long, how far, which stage
- ❖ Other inputs – e.g. clinical, technical, etc.

❖ Ill defined outputs

- ❖ What type of outcome do we use as an indicator of CTG/FHR class
 - ◆ pH+BDecf (reason: Cerebral palsy – objective/statistical sound outcome measure): **not very useful (very few cases)**
 - ◆ Apgar5 (reason: ? – current CPR techniques are able to get over 7 in 5th minute in most cases): **unreliable (subjective, not necessary related to hypoxia)**
 - ◆ pH alone (reason: it is easy): **best (it does not relate to the long-term outcome, about 20% of measurements are wrong, no clear threshold)**
 - ◆ Expert evaluation (reason: that is how it is done in the hospital): - **(large variability, increased defensiveness in evaluation)**

Clinical



- ❖ Hard to assess real-life CTG evaluation
 - ❖ Interventions due to multiple factors
 - ❖ CS with normal objective outcome (how often was it necessary?)
 - ❖ Low-risk pregnancies not monitored
 - ❖ Bad outcomes often related to very low quality or missing recordings

- ❖ Guidelines in intrapartum CTG not very good regarding:
 - ◆ Clear explanation of reasoning
 - ◆ Consistency, Repeatability
 - ◆ Reasons for use (cf. history of the CTG introduction)

- ❖ Increase of CS without impact on # of hypoxic babies

- ❖ Existence of many related confounding factors

- ❖ Variability among fetuses (e.g. male vs. female)

Technical



- ❖ Majority of works done on static evaluation only
 - ❖ One window (usually length < 40min, sleep episodes not considered)
 - ❖ Often no prediction (evaluation of full data)

- ❖ Limits of technical methods not advertised
 - ❖ Ultrasound or STAN recordings – huge difference in terms of quality
 - ❖ Some methods need certain length of recording without noise
 - ❖ Tocographic data – hardly usable

- ❖ Lack of pathological cases

- ❖ Preprocessing of the data is feature-dependant

- ❖ Almost none of the other information available in the hospital is not considered



Pieces of our work

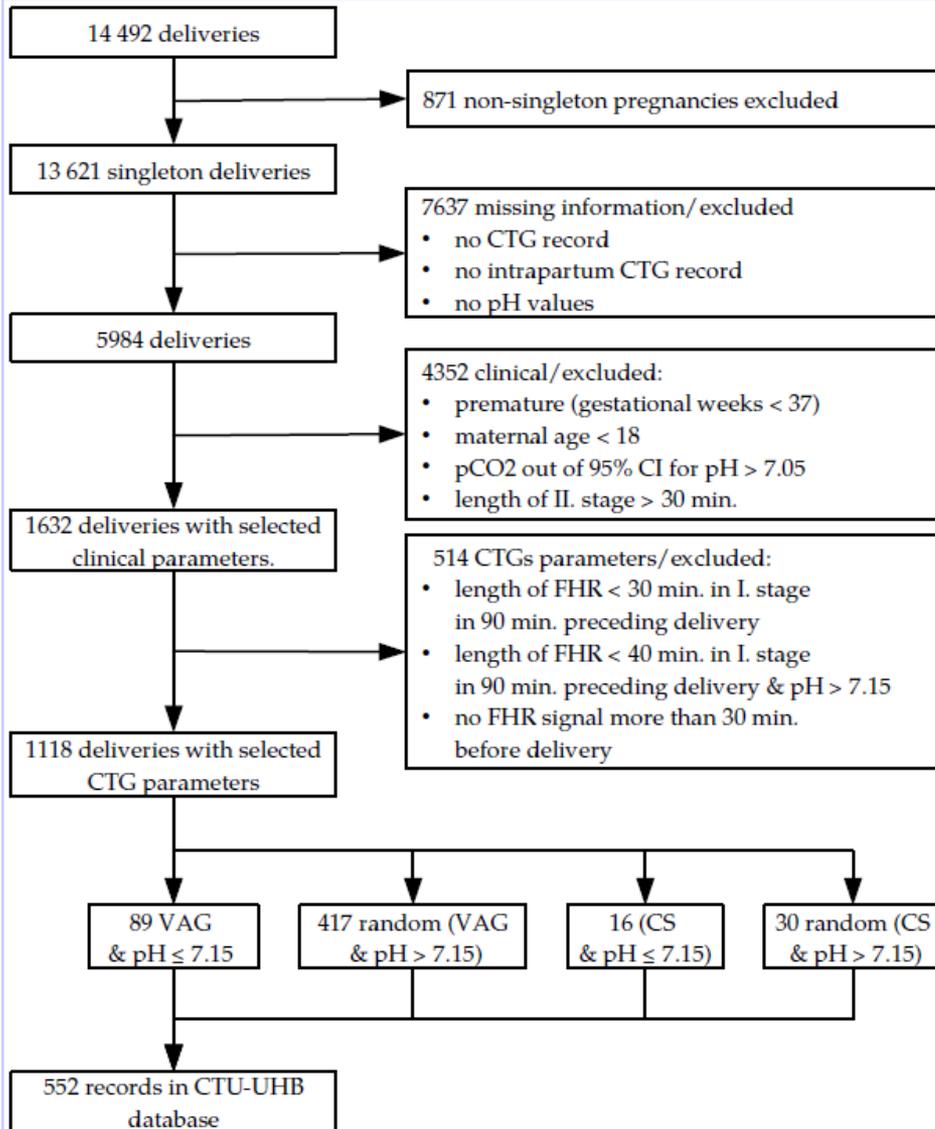
(addressing in part the general problems above)



Database

CTU-UHB cardiocotocograpic database

CTU-UHB database



- ❖ Collaboration with Ob&Gyn clinic in Brno
- ❖ USG and STAN data
- ❖ Only mature fetuses
- ❖ First open-access CTG database
- ❖ Common ground for algorithm comparison
- ❖ Available at Physionet

Outcome measures for CTU-UHB



❖ Subjective – expert evaluation

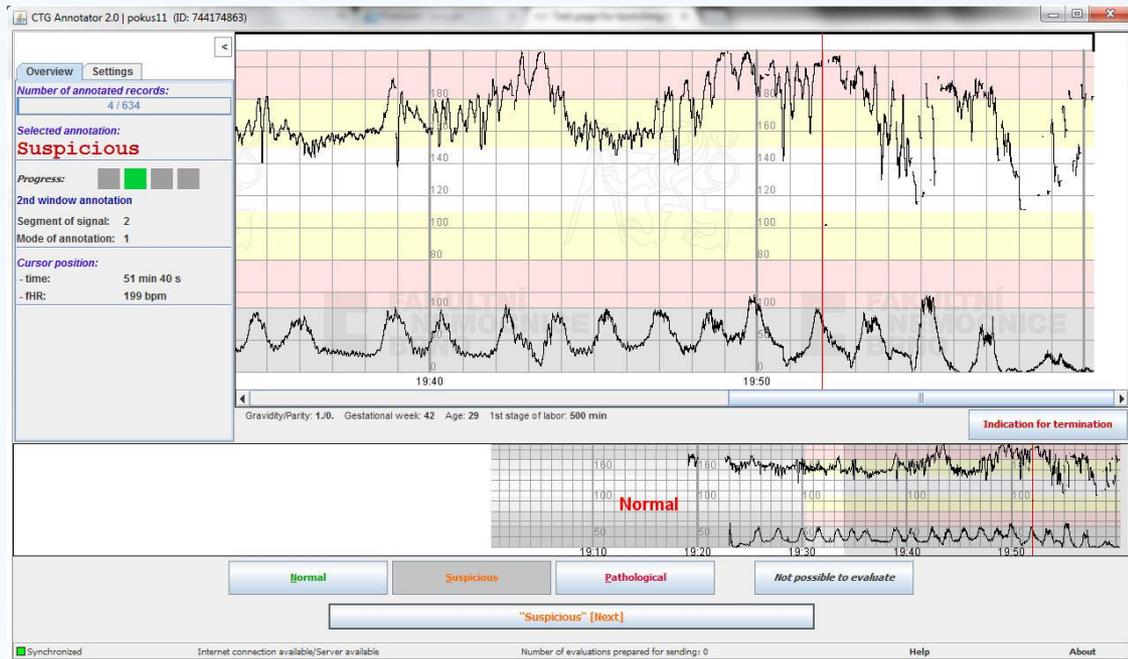
- ❖ Annotations acquired via CTG Annotator
- ❖ Majority voting, Latent class model based on 9 experts
- ❖ Apgar score

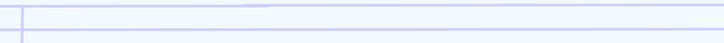
❖ Objective

- ❖ pH, pCO₂, BDecf, BE

❖ Mixture

- ❖ Majority, LCMs





Educational SW using the db



Průběh porodu

9/6/2014_04:00 Spont. odtok
plodové vody_21:45 C5=8; 5ml
penicilínu ve 100ml FR i.v.
_10/6/2014_02:00 2,5ml PNC ve
100ml FR i.v._04:00 Epidural_05:00
Epidural_06:00 2,5ml PNC ve 100 ml
FR i.v.

06:00 - 06:30
Progres = 3cm

06:50 - 07:20
Progres = 4cm

_08:30 500ml FR+5j Oxytocin_08:45
Epidural

08:50 - 09:20
Progres = 5cm

_09:30 Epidural

10:10 - 10:40
Progres = 8cm

10:40 - 11:10
Progres = LEM

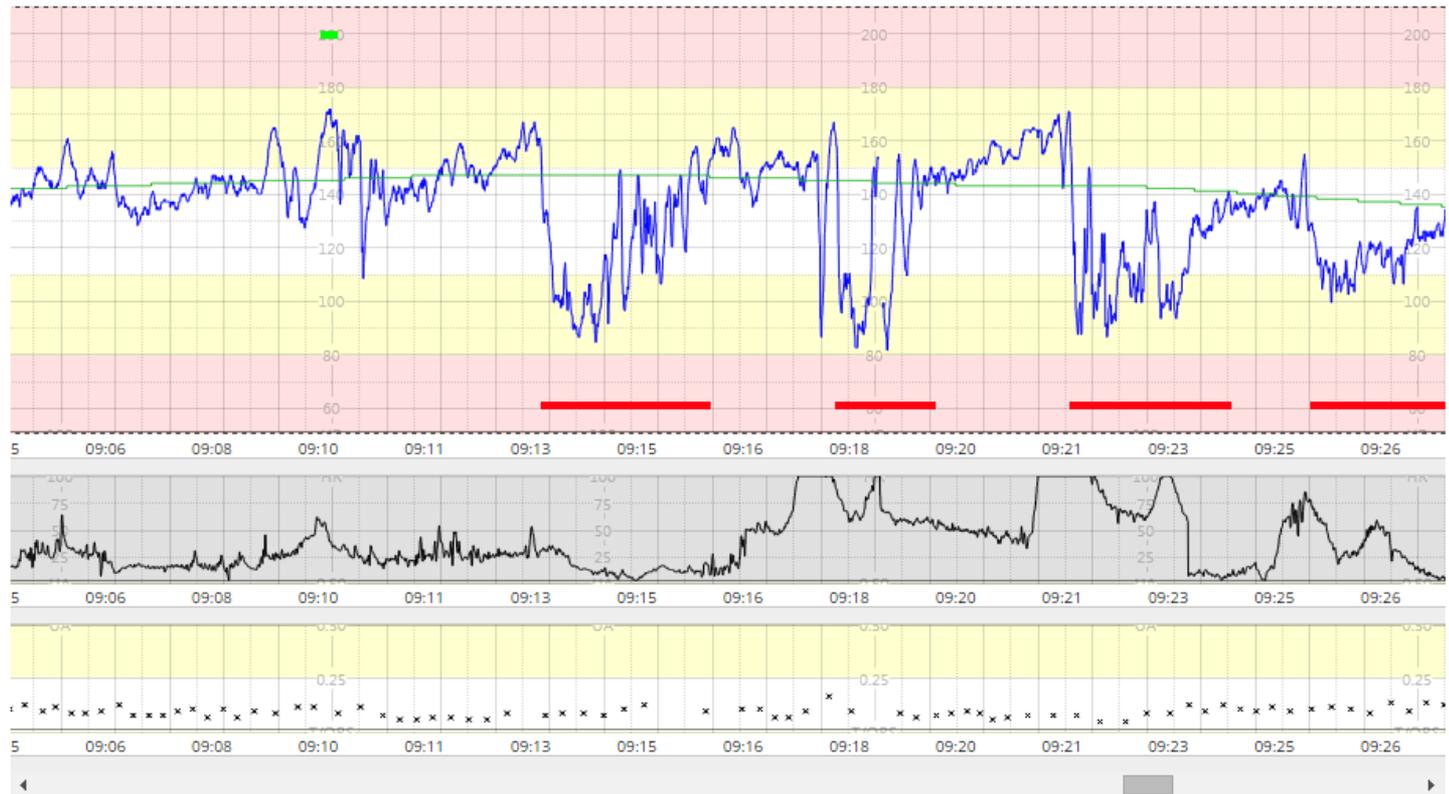
Matka: věk 25, GRAV I, PARA I, týden 40 + 5, indukovaný porod ne

Novorozenec: žena, 3230 g, pH 7.17

Příznaky z automatické figoanalýzy

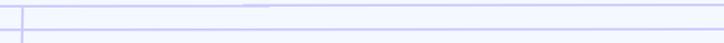
Baseline: 145 Bradycardia: 0
Stress Ratio: ? LTV: 19
STV: 7

Naměřené hodnoty



FIGO guidelines

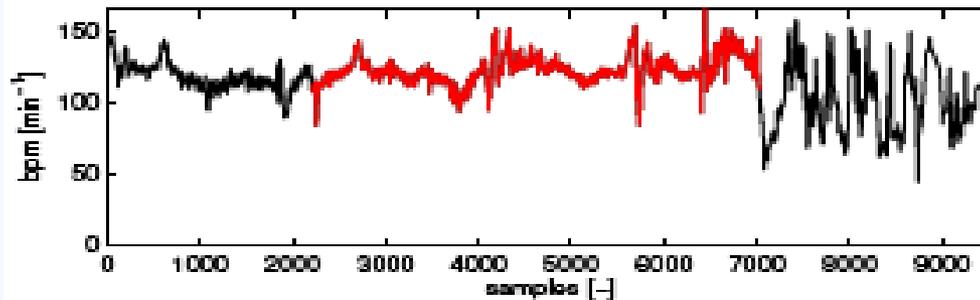
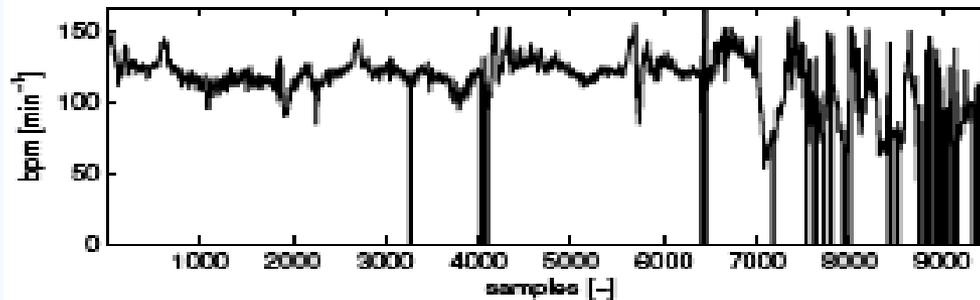
TQRS guidelines



Signal pre-processing

❖ Gap & Artefact detection

- ❖ Gap removal (< 15s)
- ❖ Artefact rejection
- ❖ Bernardes inspired thresholds
- ❖ Adapted to 4Hz from beat to beat



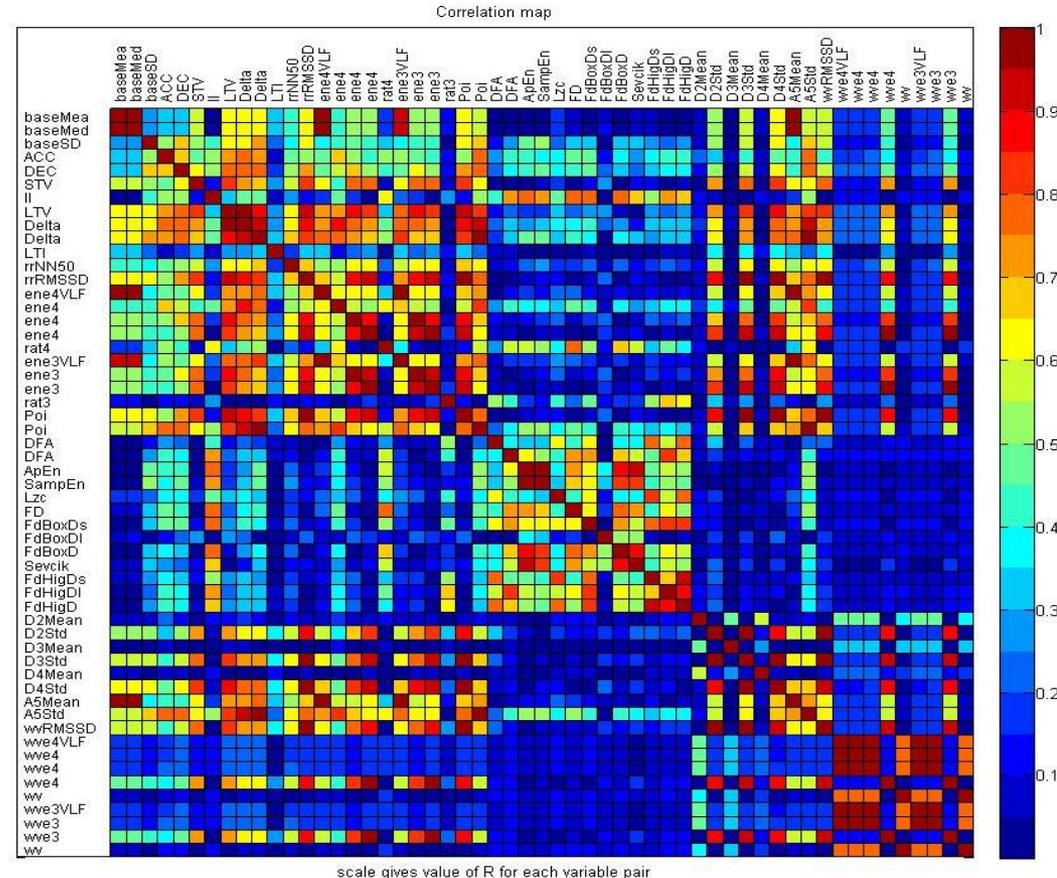
FIGO features

- ❖ Official obstetrics guidelines for CTG evaluation
- ❖ Circular definition of Acceleration/Deceleration
- ❖ Baseline detection based on histogram assessment

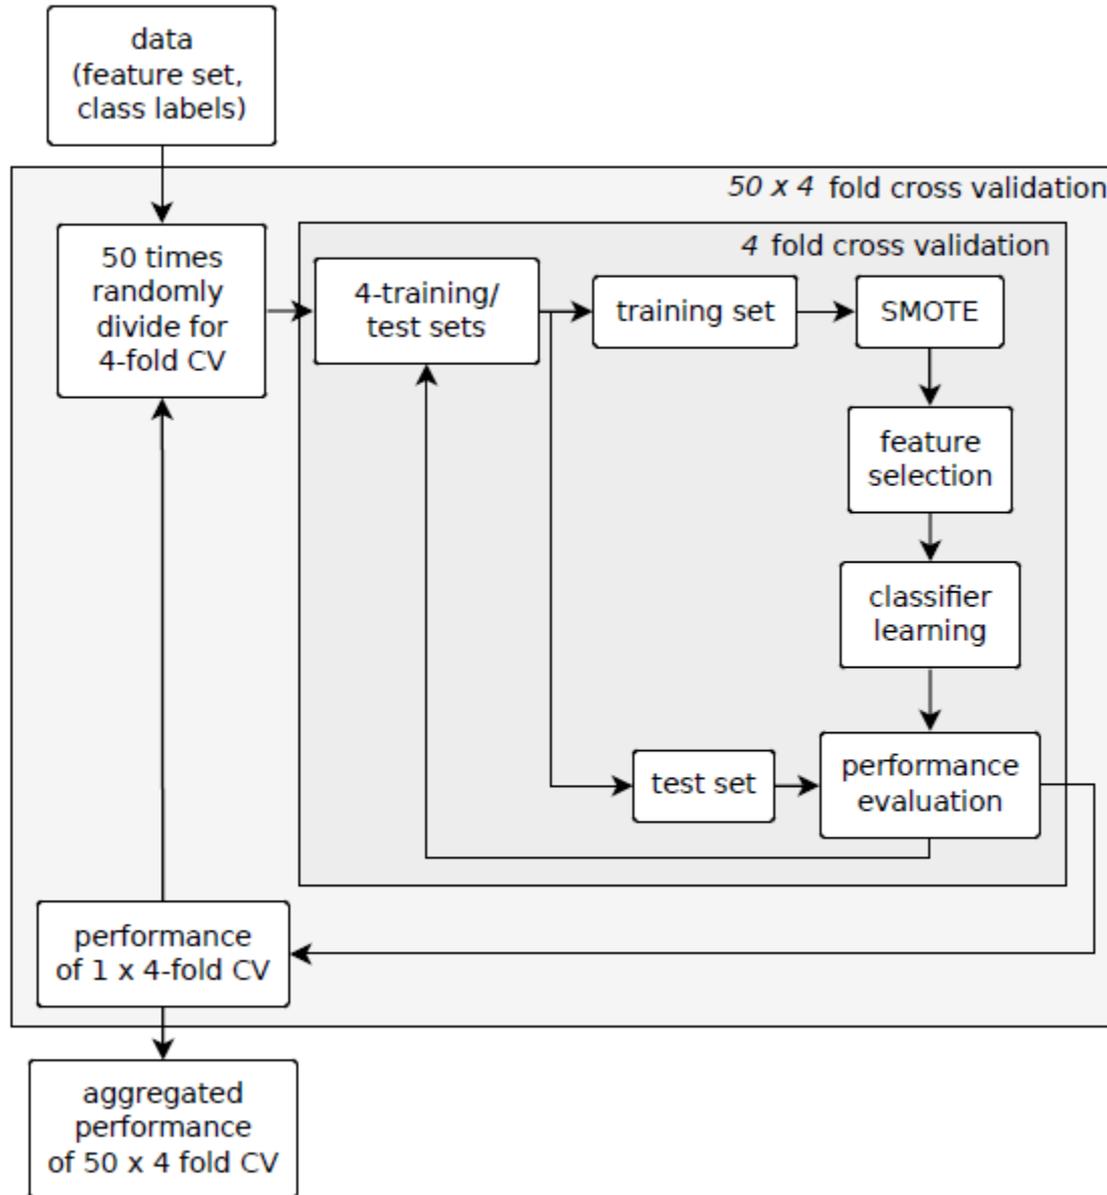


Features

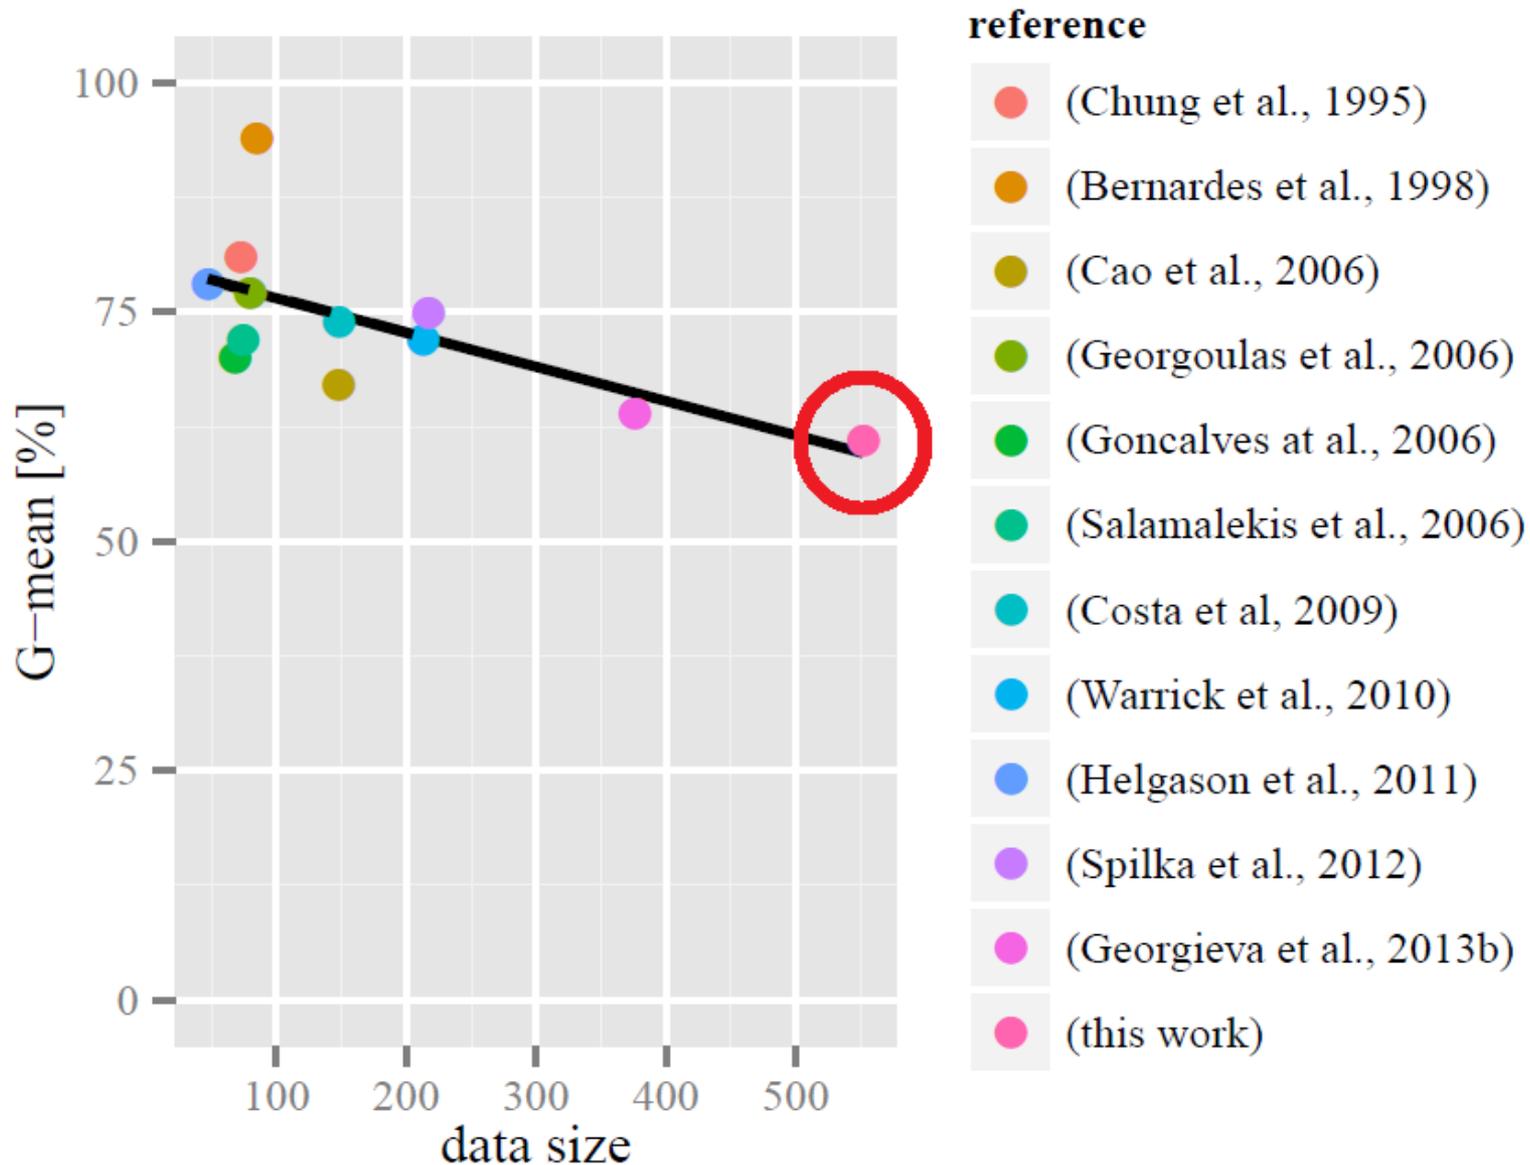
- ❖ Morphological features (FIGO) (5)
- ❖ Time-domain (6)
- ❖ Freq.-domain (13)
- ❖ HRV (4)
- ❖ Wavelet (15)
- ❖ Nonlinear (12)
- ❖ In total 55 features



Classification



Comparison of results



Shared database of path. cases



- ❖ We need a common ground to compare
- ❖ Getting the data is cumbersome and unrewarding job
- ❖ But most hospitals now have electronic CTG records
- ❖ There is no „perfect database“ yet

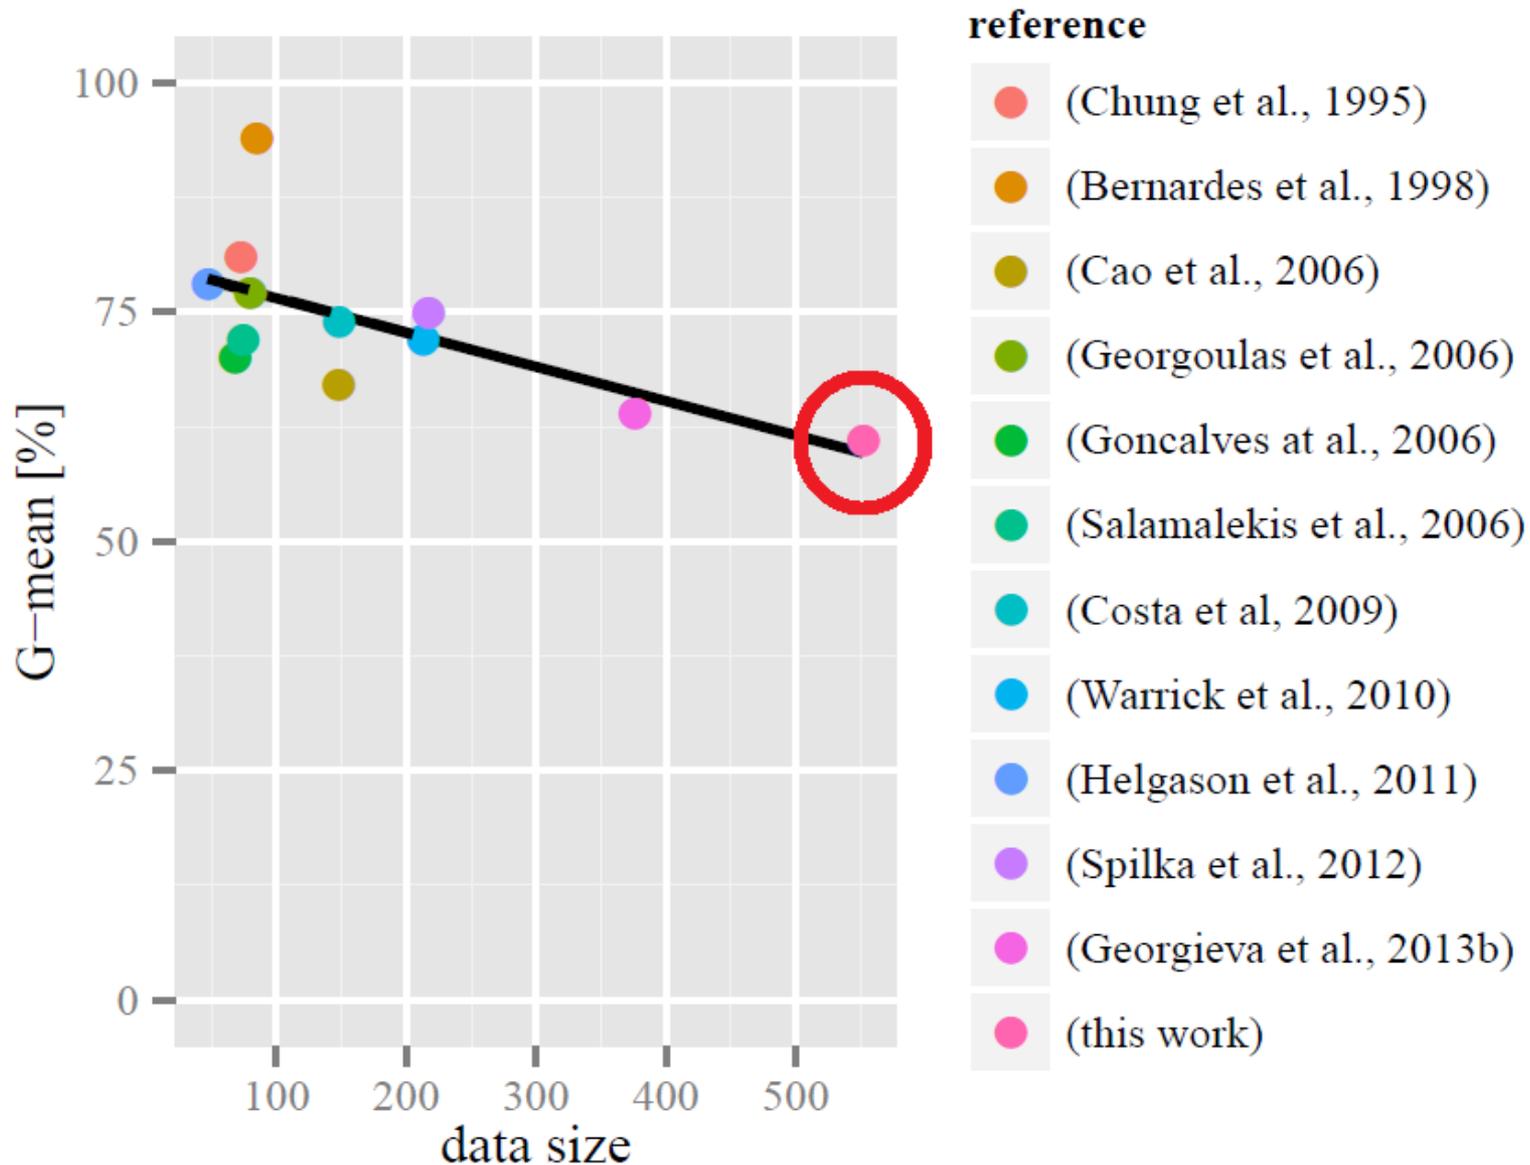
- ❖ Experience shows that joining different approaches brings improvement across the board (kaggle.com)
- ❖ Individual phase followed by joint effort phase
- ❖ Could we build one together?



Outcome measures

Man-machine comparison

Comparison of results



Classification (3)



❖ Selected features

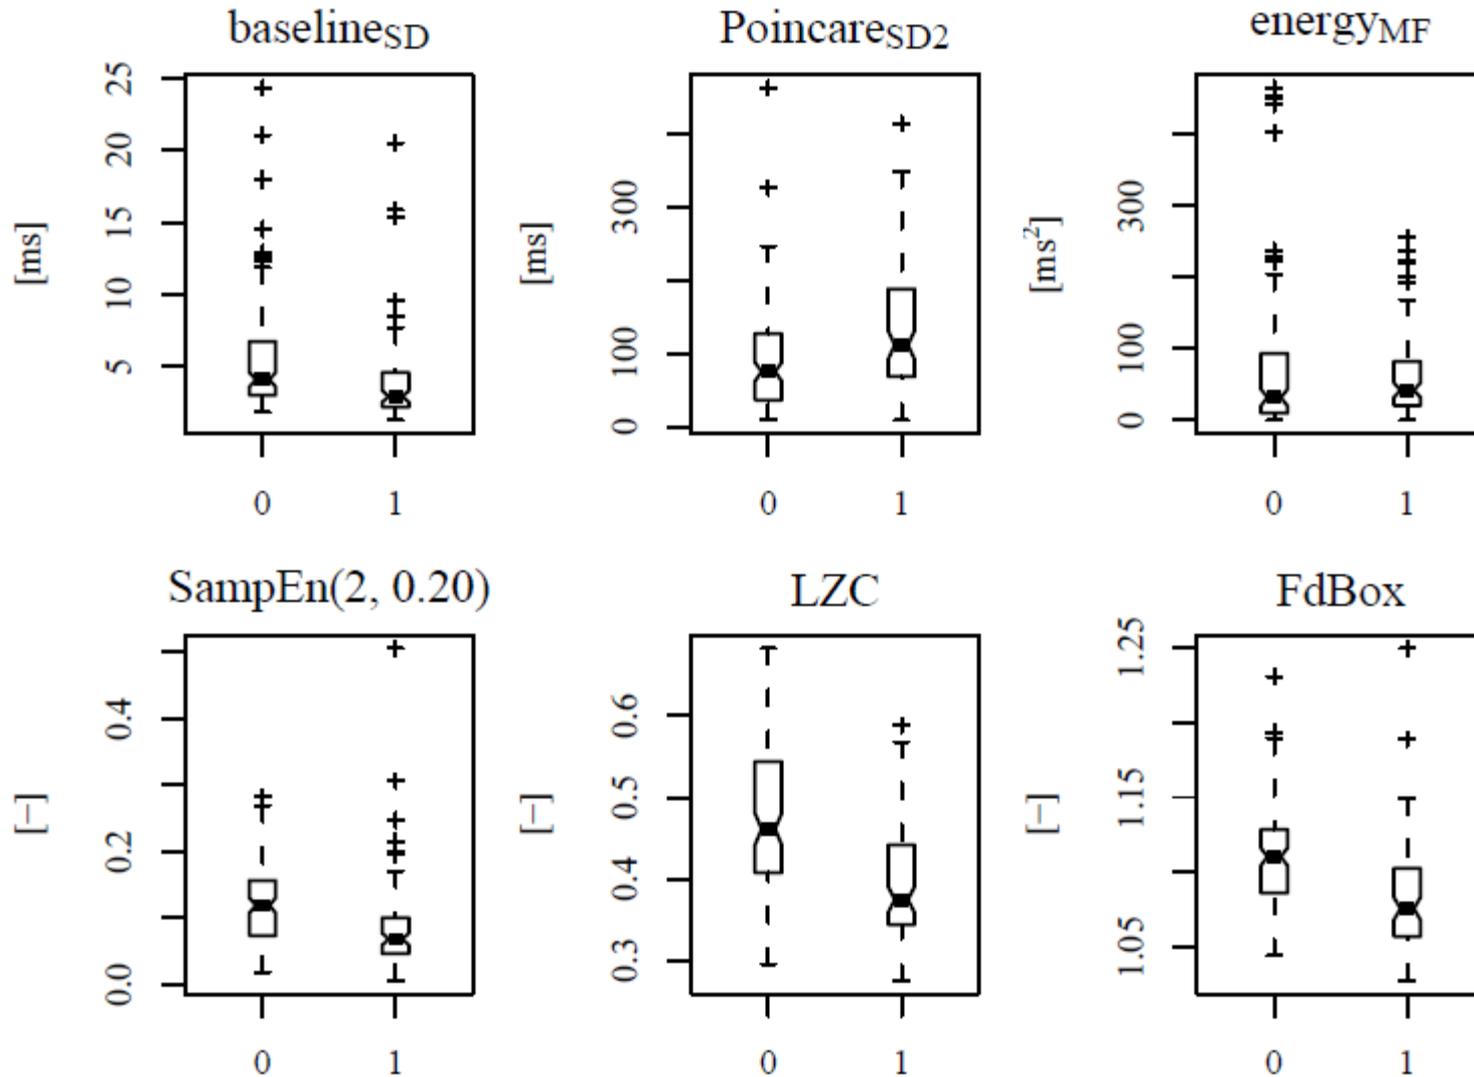
- ❖ Low spectral bands
- ❖ Decelerations
- ❖ Poincare plot SD2

Naive Bayes

SVM

sensitivity		60 (53–67)		53 (47–60)
specificity		75 (72–77)		78 (75–80)
precision		23 (20–25)		23 (20–26)
F-measure		33 (29–36)		33 (28–37)

Results – obj. annotation (2)



Clinical evaluation vs. pH



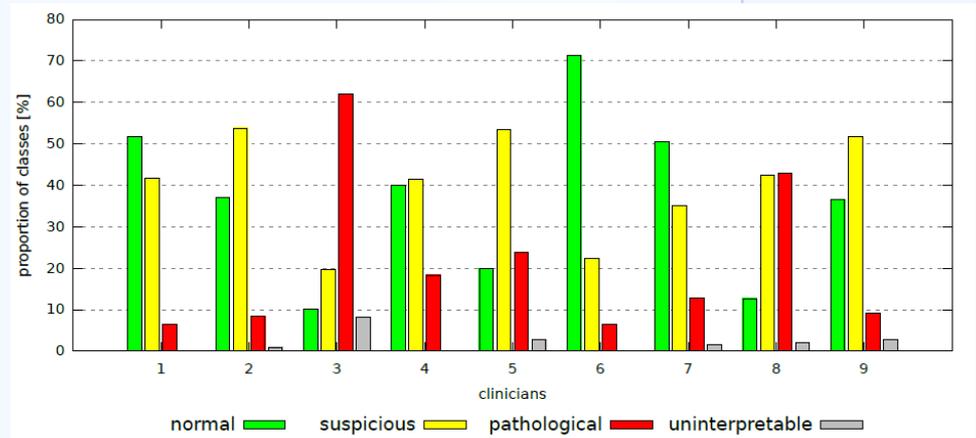
❖ Real-life CTG evaluation comparison vs. pH

❖ Variability

❖ Overall poor sensitivity

❖ Sensitivity drops Step3 -> Step4

❖ Why?



Annotation	Objective	Step 1		Step 2		Step 3		Step 4	
		SE	SP	SE	SP	SE	SP	SE	SP
majority voting	pH ≤ 7.05	29 (12-54)	92 (88-95)	41 (20-65)	86 (81-90)	86 (45-99)	86 (79-90)	38 (18-63)	94 (91-97)
	BD ≥ 12	30 (9-62)	92 (87-95)	50 (22-78)	86 (81-90)	50 (3-94)	83 (76-88)	22 (4-56)	93 (89-96)
	Apgar < 7	50 (10-90)	91 (87-94)	50 (10-90)	85 (80-89)	100 (5-100)	83 (76-89)	75 (25-99)	93 (90-96)
hospital records	pH ≤ 7.05	41 (20-65)	94 (91-97)	41 (20-65)	94 (90-97)	40 (15-71)	93 (88-96)	N/A	N/A
	BD ≥ 12	60 (29-85)	94 (91-97)	60 (29-85)	94 (90-96)	25 (1-75)	92 (87-95)	N/A	N/A
	Apgar < 7	0 (0-53)	92 (88-95)	0 (0-53)	92 (87-95)	33 (2-86)	92 (87-95)	N/A	N/A

Clinical evaluation vs. pH



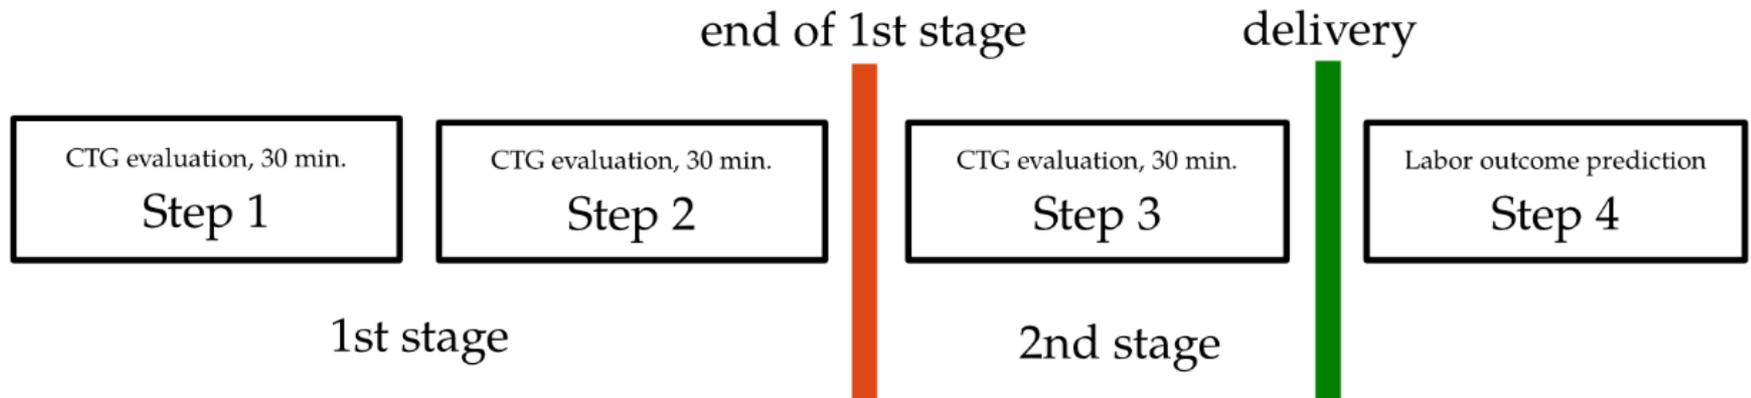
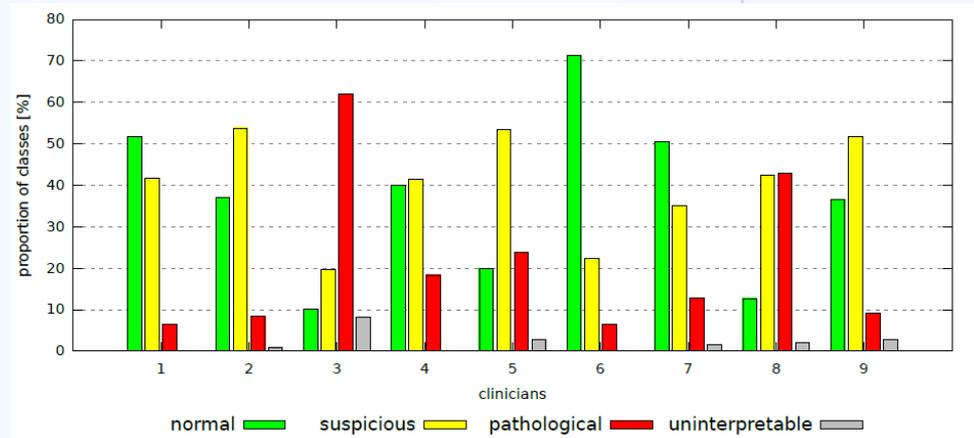
❖ Real-life CTG evaluation comparison vs. pH

❖ Variability

❖ Overall poor sensitivity

❖ Sensitivity drops Step3 -> Step4

❖ Why?



Clinical evaluation vs. pH



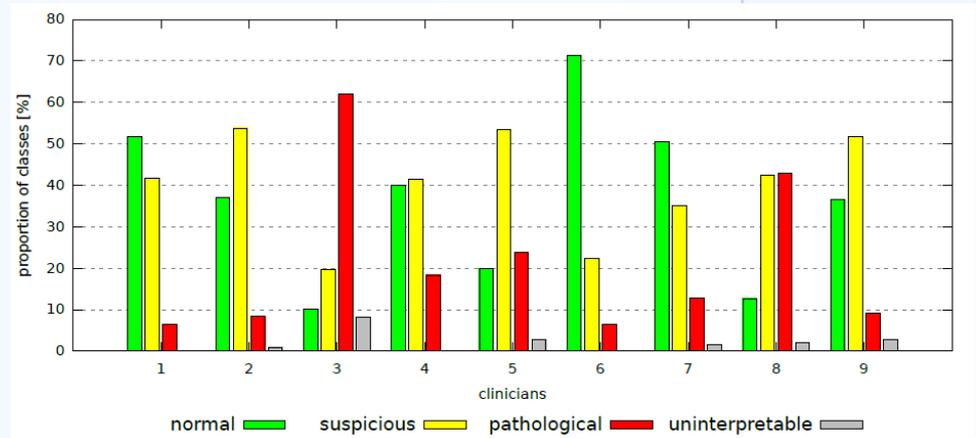
❖ Real-life CTG evaluation comparison vs. pH

❖ Variability

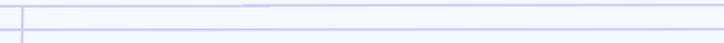
❖ Overall poor sensitivity

❖ Sensitivity drops Step3 -> Step4

❖ Why?



Annotation	Objective	Step 1		Step 2		Step 3		Step 4	
		SE	SP	SE	SP	SE	SP	SE	SP
majority voting	pH ≤ 7.05	29 (12-54)	92 (88-95)	41 (20-65)	86 (81-90)	86 (45-99)	86 (79-90)	38 (18-63)	94 (91-97)
	BD ≥ 12	30 (9-62)	92 (87-95)	50 (22-78)	86 (81-90)	50 (3-94)	83 (76-88)	22 (4-56)	93 (89-96)
	Apgar < 7	50 (10-90)	91 (87-94)	50 (10-90)	85 (80-89)	100 (5-100)	83 (76-89)	75 (25-99)	93 (90-96)
hospital records	pH ≤ 7.05	41 (20-65)	94 (91-97)	41 (20-65)	94 (90-97)	40 (15-71)	93 (88-96)	N/A	N/A
	BD ≥ 12	60 (29-85)	94 (91-97)	60 (29-85)	94 (90-96)	25 (1-75)	92 (87-95)	N/A	N/A
	Apgar < 7	0 (0-53)	92 (88-95)	0 (0-53)	92 (87-95)	33 (2-86)	92 (87-95)	N/A	N/A

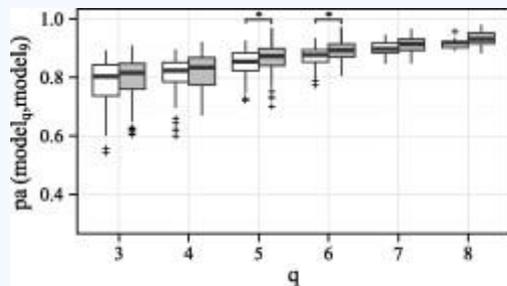


Latent class analysis

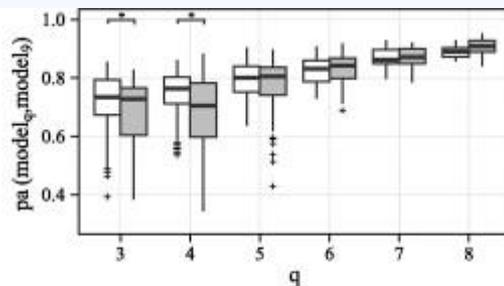


- ❖ The latent class analysis (LCA) is used to estimate the true (unknown/hidden) evaluation of CTG and to infer weights of individual clinicians' evaluation – the latent class model (LCM).
- ❖ The LCM considers clinical evaluation as a finite mixture of multinomial distributions.
- ❖ Finite mixture models have fixed number of parameters and the standard method to estimate these parameters is expectation maximization (EM) algorithm.

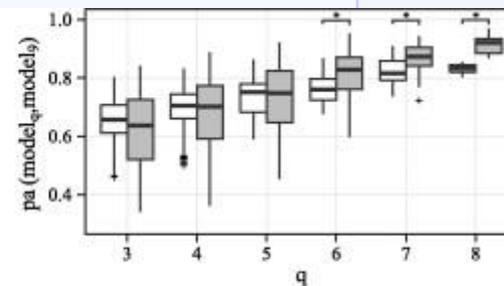
Latent class models



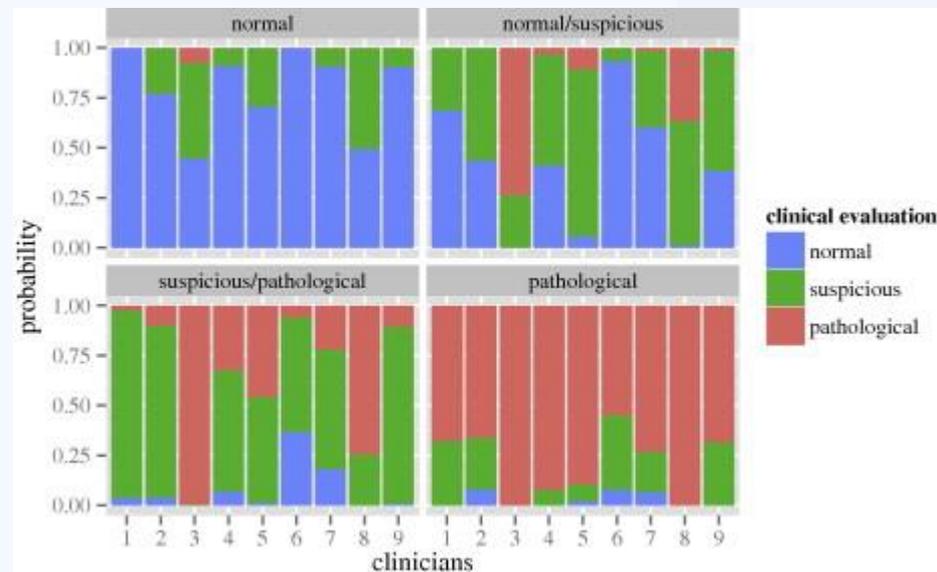
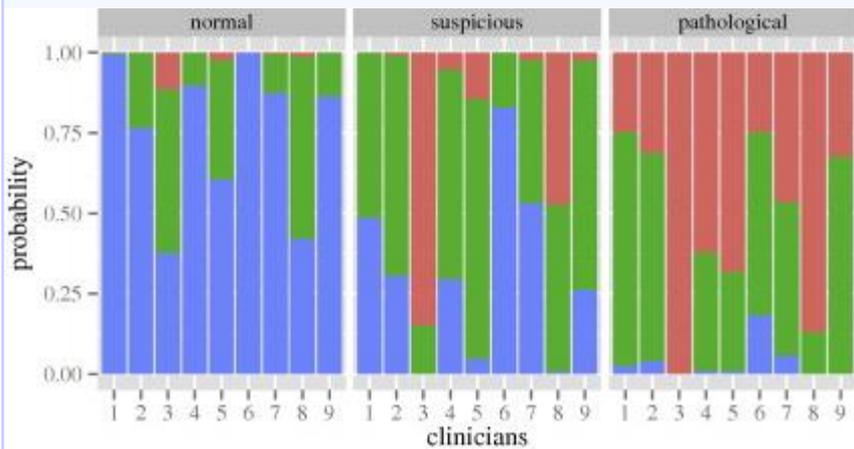
model MV LCM
(a) normal



model MV LCM
(b) suspicious



model MV LCM
(c) pathological





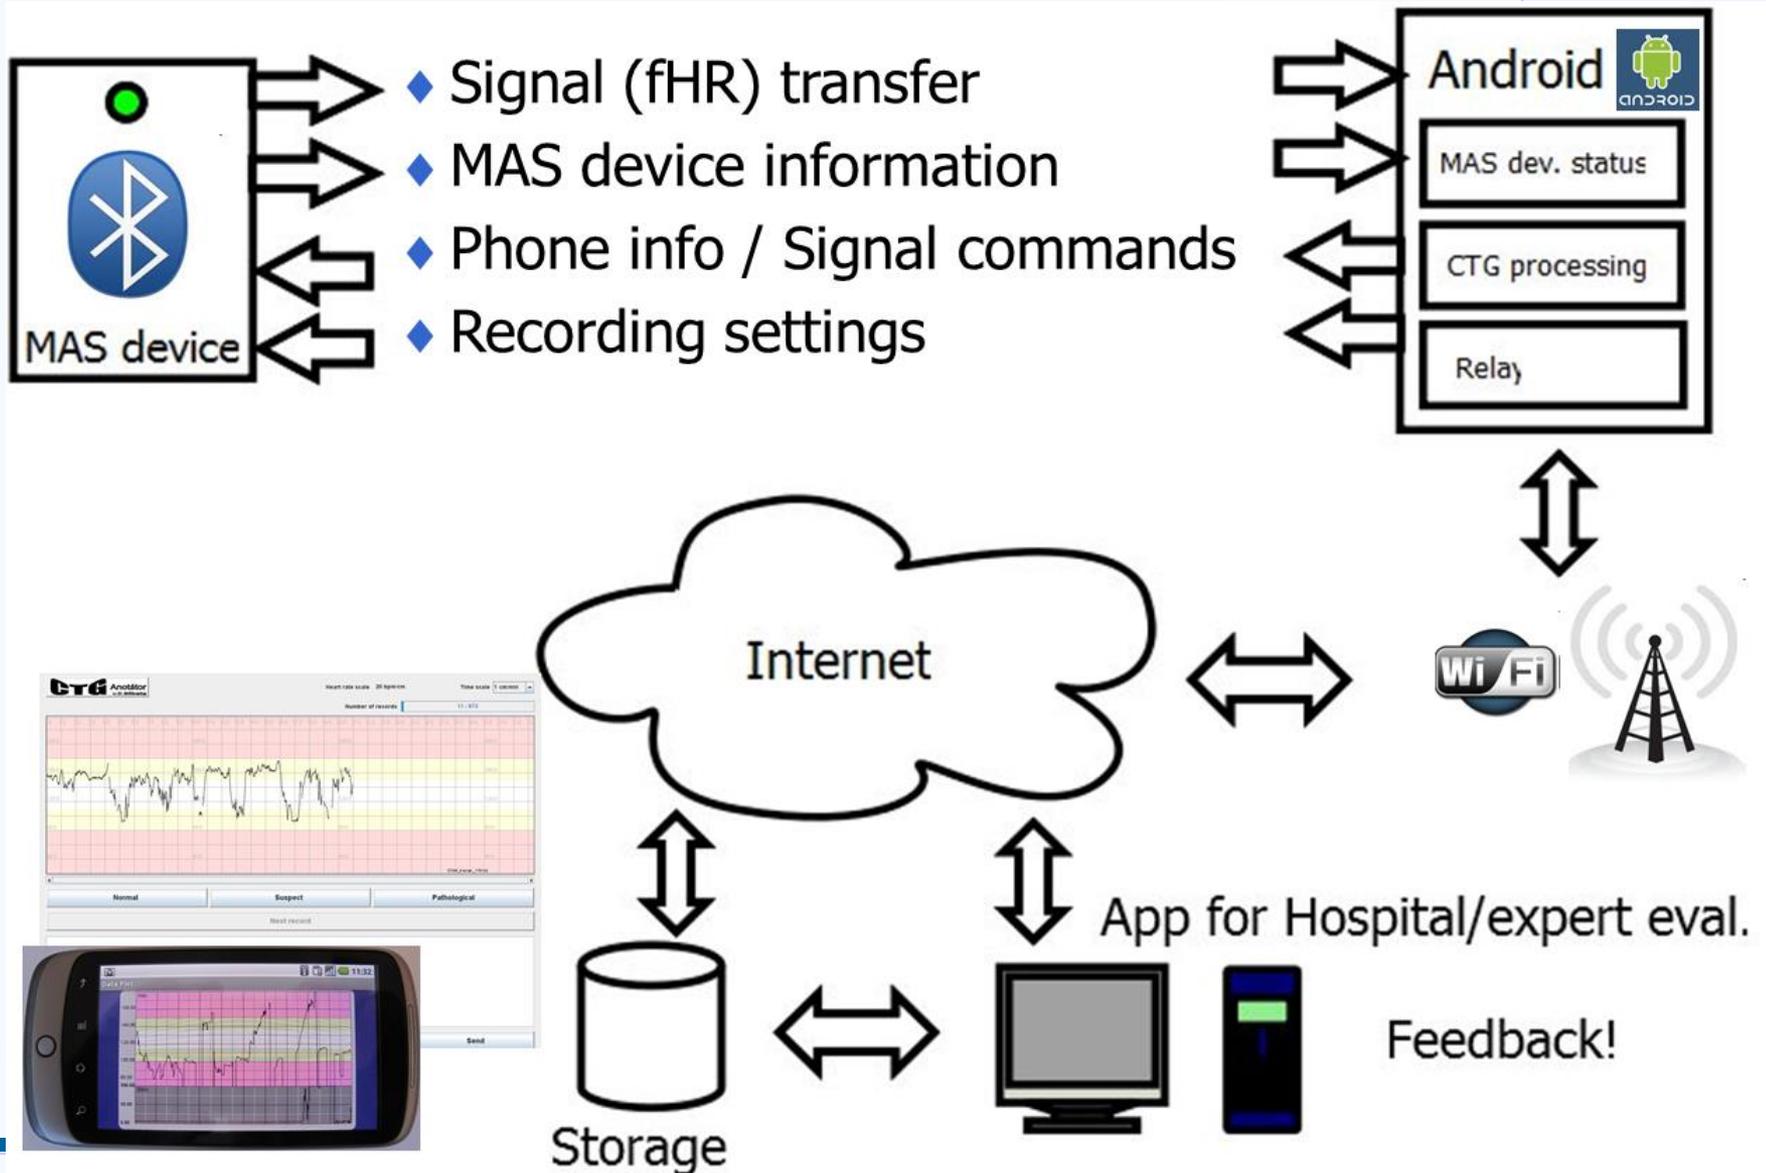
Case studies – different experiments / projects in the field of CTG processing



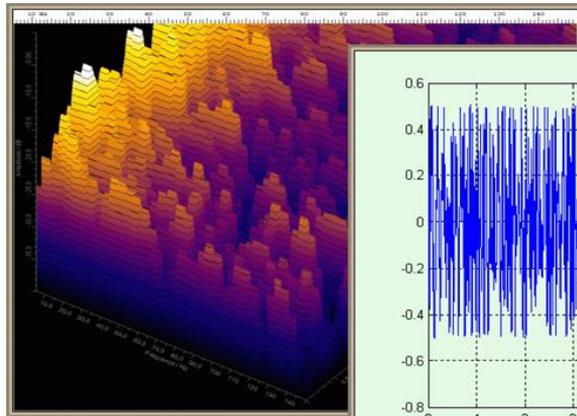
“Case study ” 3: Mobile CTG

(with Siemens A.G. Austria)

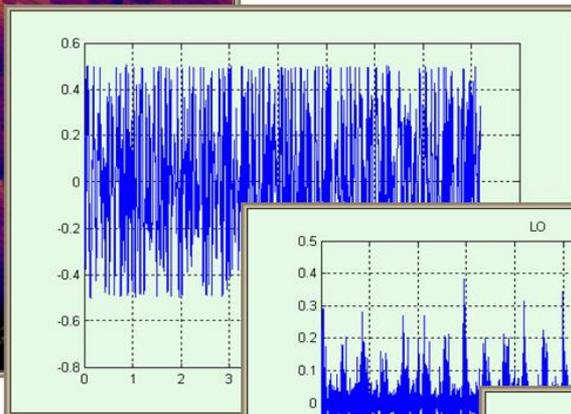
General schema of mCTG



Phonography signal processing

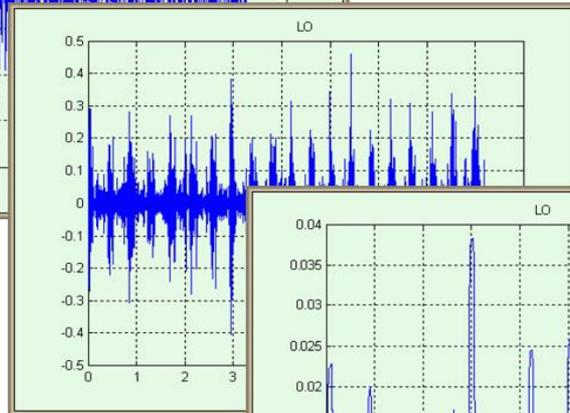


frequency domain

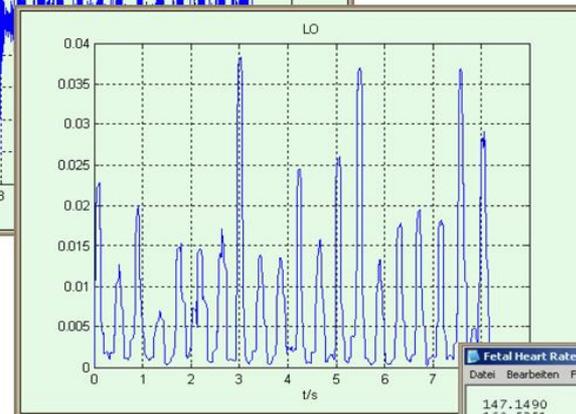


time domain

input signal



filtered



RMS

fetal heart rate

signal processing

MAS mCTG **D2**





**“Case study ” 5:
OB information system –
The Delivery Book**

(by Michal Huptych@CTU)

Electronic delivery book

❖ The application has been deployed as pilot version.



Elektronická porodní kniha v0.99

Nový Editovat Hledat Filtr Statistiky Export do PDF O programu

Předchozí Stránka 1 / 3 Následující

č. rok	č. měsíc	č. den	Jméno a příjmení	Příjmení dítěte	Datum	Čas	Pohlaví	Váha	Délka	Číslo nov.	Týden + den
1	1	1	Aa ---		08.01.2014	11:23	---	---	---	---	--- + ---
2	2	1	bbb ---		09.01.2014	13:45	---	---	---	---	--- + ---
3	3	1	cc ---								
4	4	2	Nol Fyhl								
5	5	1	Ert ---								
6	6	2	dd ---								
7	7	3	e e								
8	8	4	Rui Rui								
9	9	5	Fghj Fgj								
10	10	1	Cvb Cvb								
11	11	2	Rut Utr								
12	12	1	Ret Ert								
13	13	2	Vgh Jukl								
14	14	3	Rasd Tery								
15	15	1	Gg ---								
16	16	2	Fasd Hjgk								
17	17	3	H H								
18	18	4	Ff ---								
19	19	5	Vbn Mnb								
20	20	1	Frk Mrk								

Editor

Jméno rodičky: Ert Ret

Rodička / Příjem Porod Diagnózy/Operace/Pracovníci Novorozenec Neonatologie

Porod

1. Datum porodu den.měsíc.rok 13.01.2014 Kalendář Poloha plodu

Čas porodu hodina:minuta 11:45 Výsledek porodu

Týden těhot. Rozsah 20 - 45 +Dni Rozsah 0 - 6 Krevní ztráta 0 - 5000 ml Indukovaný porod

Porodní doby 1.,2.,3., celková Patologický porod Zobraz protokol

Anestezie Místo porodu Medikace

Doprovod u porodu Poloha matky při porodu

Informace se zobrazují zde

Předchozí Následující Poznámky Uložit do databáze

Přihlášen: as. Lukáš Hruban, FN Brno Obilní trh

Odhlásit Aktualizovat (Ctrl+R) Rozšířená tabulka





Editor

Jméno rodičky: Ggg Ggg, č. porodopisu: 111232

Rodička / Příjem Porod Diagnózy/Operace/Pracovníci Novorozenec Neonatologie

Rodička

Příjmení: Ggg
 Jméno: Ggg
 Rodná čísla: 10.000.000
 Úlice: Na Korane
 Číslo popisné: 122, C. orientační: 21
 Stát: CZ, PSČ: 100
 Město:

Příjem

Datum přijetí: 08.02.2014
 Číslo přijetí: 821
 Důvod přijetí: odložit PV
 Četnost por.: 2 dvojčata
 Gravidita: I, Parita: První
 Číslo porodopisu: 111232

Informace se zobrazují zde

Předchozí Následující Poznámky Uložit do databáze

a)

Editor

Jméno rodičky: Ggg Ggg, č. porodopisu: 111232

Rodička / Příjem Porod Diagnózy/Operace/Pracovníci Novorozenec Neonatologie

Porod

1. Datum porodu: 08.02.2014
 2. Čas porodu: 12:35
 Těhotenství: 39 týdnů, 4 dny
 Porodní doby: 01:25, 00:20, 01:48
 Anestezie: spinální
 Doprovod u porodu: Poloha matky: standardní

Poloha plodu: křížem pánevím
 Výsledky porodu: živé doročené dítě
 Krevní ztráta: 200 ml
 Patologický porod: Zložitý protokol
 Medicace:

Por je formálně vyplněno správně

Předchozí Následující Poznámky Uložit do databáze

b)

Editor

Jméno rodičky: Ggg Ggg, č. porodopisu: 111232

Rodička / Příjem Porod Diagnózy/Operace/Pracovníci Novorozenec Neonatologie

Novorozenec

1. Číslo novor.: 002, Pohlaví: žena
 2. Délka: 57 cm, Váha: 3200 g
 Apgar: 9, 9, 9
 pH arteriální: 7,21, pH venózní: 7,14
 BE arteriální: -1,54, BE venózní: -2,07
 Příjemní oběť:

Děsť je v pořádku

Předchozí Následující Poznámky Uložit do databáze

c)

Editor

Jméno rodičky: Ggg Ggg, č. porodopisu: 111232

Rodička / Příjem Porod Diagnózy/Operace/Pracovníci Novorozenec Neonatologie

Neonatologie

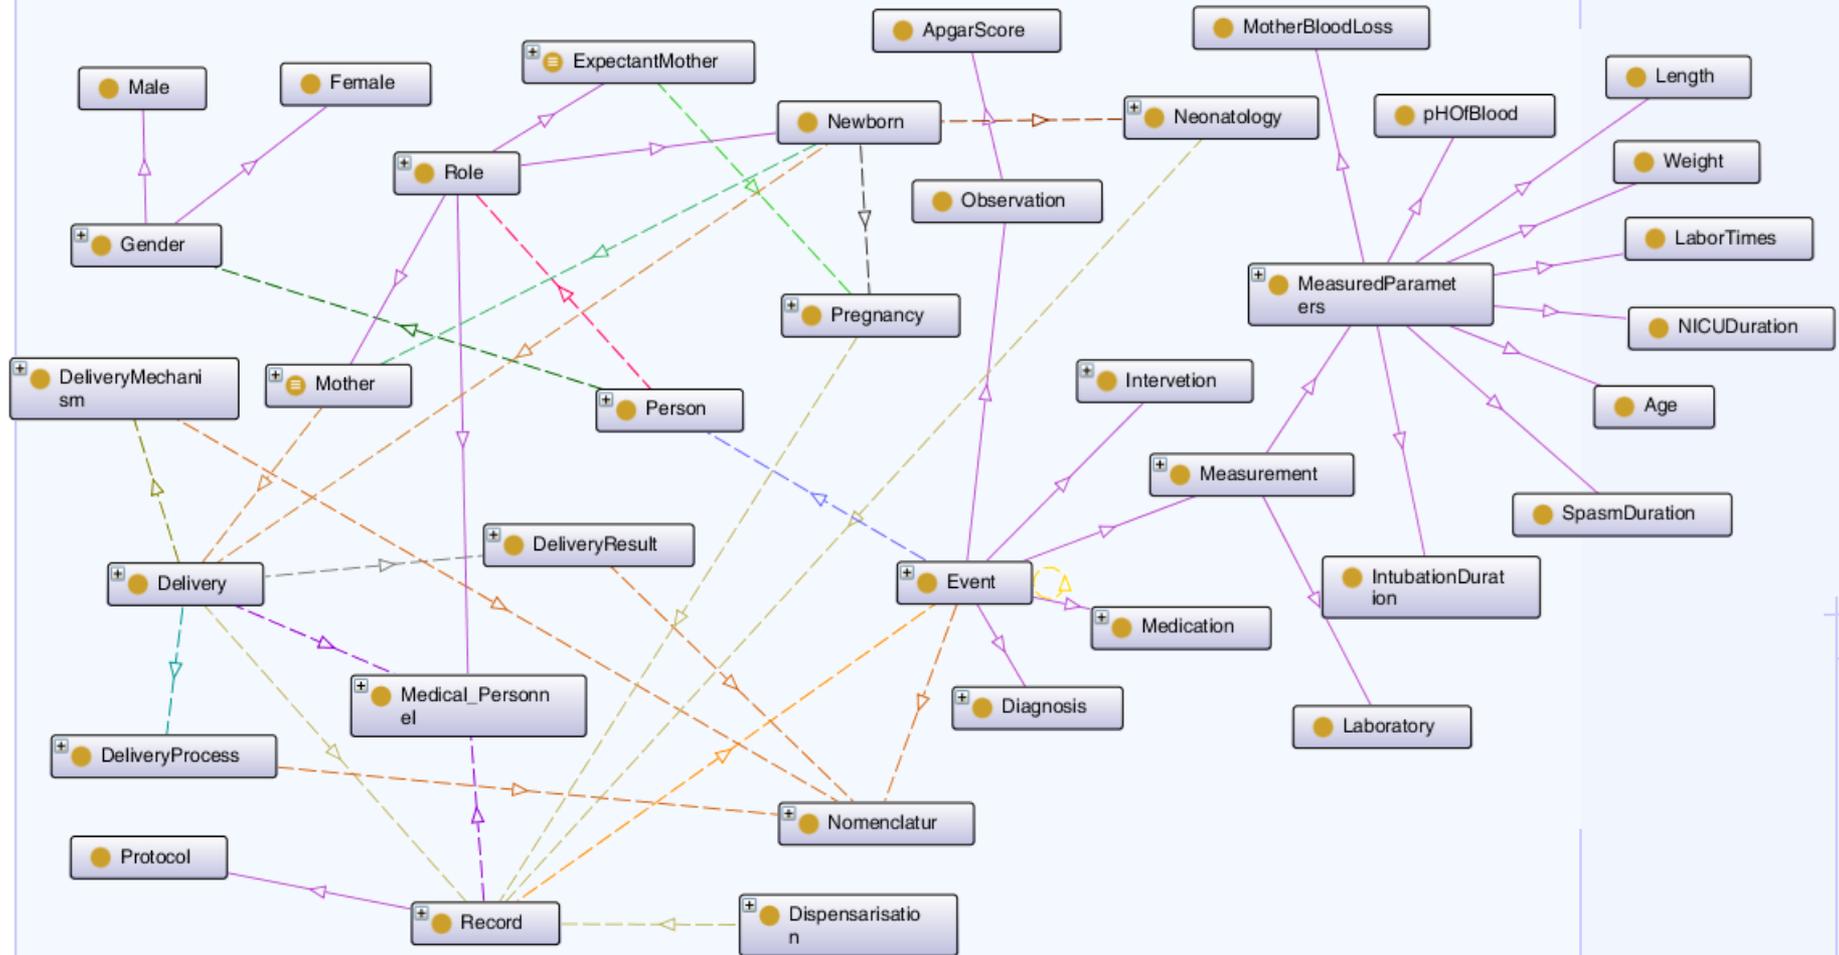
1. Datum přijetí: 08.02.2014
 2. Diagnóza při propuštění:
 Propuštění do péče na: 08.02.2014
 Hosp. na JIP:
 Intubace:
 Křídle:
 Umrt. novorozence:
 Disperantzace:
 Kardologie
 Neurologie

Typ zařízení, ve kterém je prováděno sledování.

Předchozí Následující Poznámky Uložit do databáze

d)

Domain model in obstetrics





**“Case study ” 6:
Clustering of FHR using
SAX**

**(with
George Georgoulas@TEI of Epirus)**



Srdce

Přes fyziologii, snímání a klasifikaci k budoucímu vývoji
v aplikované elektrokardiologii

Václav Chudáček

Přehled přednášky



I. Úvod do úvodu - co je to srdce?

- Co říkají encyklopedie

II. Srdce z morfologického a funkčního pohledu

- Anatomie srdce
- Elektrofyzologie srdce
- Akční potenciál
- Pacemakerové buňky
- Převodní systém srdeční
- „Vznik“ EKG

III. EKG

- Svodové systémy pro měření EKG
- EKG křivky
- Počítačový popis EKG

Přehled přednášky (2)



IV. Typy měření EKG – principy a přístroje

- Standardní 12ti svodové EKG
- Holter
- Automatický defibrilátor
- Multisvodové EKG (BSPM)
- Echokardiografie
- A-EGM
- Kardiotokografie a HRV
- Telemedicína

V. Nemoci srdce (patoelektrofyzologie) a jejich léčba

- Poruchy rytmu
- Infarkt myokardu

VI. Umělé srdce

Přehled přednášky



I. Úvod do úvodu - co je to srdce?

- Co říkají encyklopedie

II. Srdce z morfologického a funkčního pohledu

- Anatomie srdce
- Elektrofyzologie srdce
- Akční potenciál
- Pacemakerové buňky
- Převodní systém srdeční
- „Vznik“ EKG

III. EKG

IV. Přístroje k měření EKG

V. Nemoci srdce (patoelektrofyzologie) a jejich léčba

VI. Umělé srdce

Encyklopedické základy



„The heart is the beginning of life; the sun of the microcosm, even as the sun in his turn might well be designated the heart of the world; for it is the heart by whose virtue and pulse the blood is moved, perfected, made apt to nourish, and is preserved from corruption and coagulation; it is the household divinity which, discharging its function, nourishes, cherishes, quickens the whole body, and is indeed the foundation of life, the source of all action... The heart, like the prince of a kingdom, in whose hands lie the chief and highest authority, rules over all.“

William Harvey, 1628

- ❖ Srdce (lat. cor, řec. kardia) u člověka je dutý svalnatý ústroj, kterýž zvláštními přepážkami a chlopněmi je rozdělen jednak na pravou a levou část čili zkrátka na pravé (cor dextrum s. venosum) a levé s. (cor sinistrum s. arteriosum), z nichž každé opětně na síň i komoru.
- ❖ Velikost jeho i podoba se srovnává s pěstí, jindy s kuželem nepravidelně oploštělým, kterýž zpodinou se obrací vzhůru i v pravo, otupeným hrotem pak vpřed dolů a na stranu levou, kdež jeho úder bývá v 5. mezižebří u bradavky zřetelný.
- ❖ Objem s. je proměnlivý; průměrná váha bývá 275 g a příčný obvod 250 mm.
- ❖ Umístěno je za kostí hrudní v předním oddílu meziplící (mediastinum) ve vaku srdečním naléhajíc na střední oddíl bránice.

Reference: Ottův slovník naučný
2003

Encyklopedické základy (2)



- ❖ Při poslouchání srdce stetoskopem ozvy slyšitelné jako lub-dub
 - ◆ První ozva (lub) je způsobena zrychlením/zpomalením krve a vibracemi srdce v okamžiku uzavření trojicípe a mitrální chlopně.
 - ◆ Druhá srdeční ozva (dub) je způsobena zrychlením/zpomalením krve a vibracemi srdce v okamžiku uzavření plicní a aortální chlopně.
- ❖ Srdeční frekvence každého z nás se mění v závislosti na věku
 - ◆ 130-140-100-60 od novorozence po dospělého
- ❖ Menší zvířata mají rychlejší srdeční akci...
 - ◆ Plejtvákovec šedý – 9bpm
 - ◆ Tuleň obecný – 10bpm při potápění a 140bpm na souši
 - ◆ Slon 25bpm
 - ◆ Člověk 70bpm
 - ◆ Vrabec 500bpm
 - ◆ Rejsek 600bpm
 - ◆ Kolibřík 1,200bpm ve visu (dožívá se až 15ti let!!!)

Encyklopedické základy (3)



❖ Srdce v číslech

- ◆ Průměrně srdce pumpuje 70ml v jednom stahu
- ◆ Průměrná srdeční frekvence je 72 beatů za minutu
- ◆ V průběhu dne je to tedy více než 100 000krát.
- ❖ Za jeden rok je to téměř 38 milionů stahů
- ❖ V 70ti letech vám srdce bilo v průměru více než 2,5 miliardkrát!
- ❖ Srdce přepumpuje v průměru 5 litrů za minutu
 - ◆ 7200 litrů za den
 - ◆ 2,628,000 litrů za týden
 - ◆ 184,086,000 litrů za 70let života

To není vůbec špatné na 4,5 kg pumpu!

Přehled přednášky



I. Úvod do úvodu - co je to srdce?

- Co říkají encyklopedie

II. Srdce z morfologického a funkčního pohledu

- Anatomie srdce
- Elektrofyziologie srdce
- Akční potenciál
- Pacemakerové buňky
- Převodní systém srdeční
- „Vznik“ EKG

III. EKG

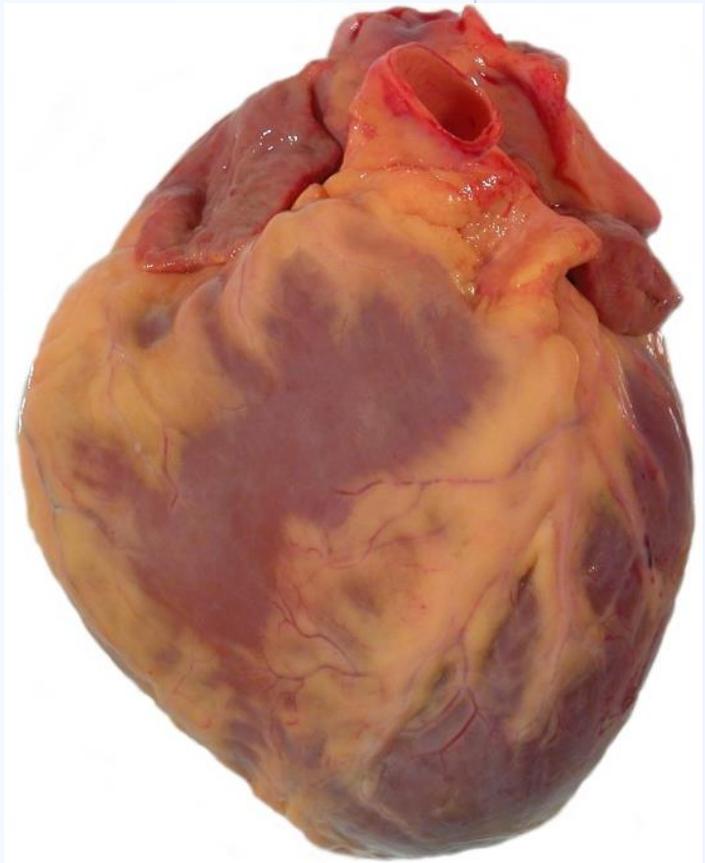
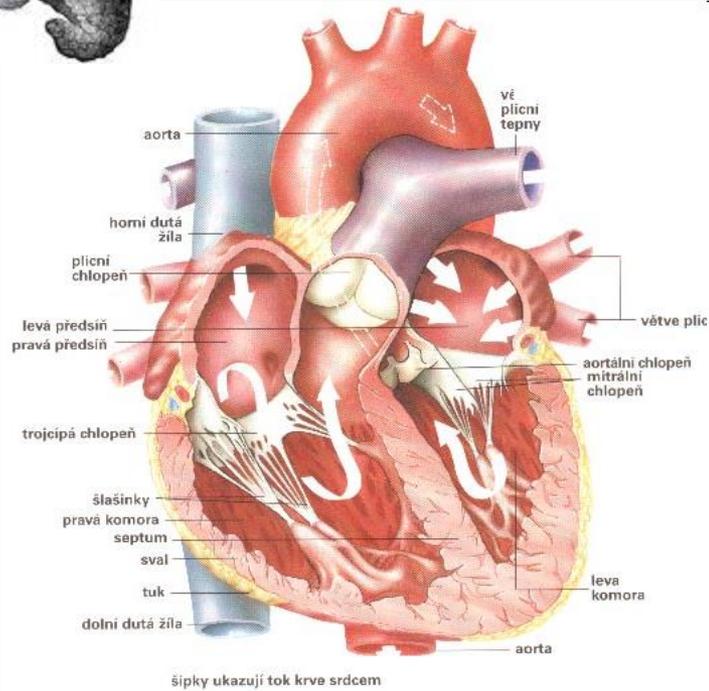
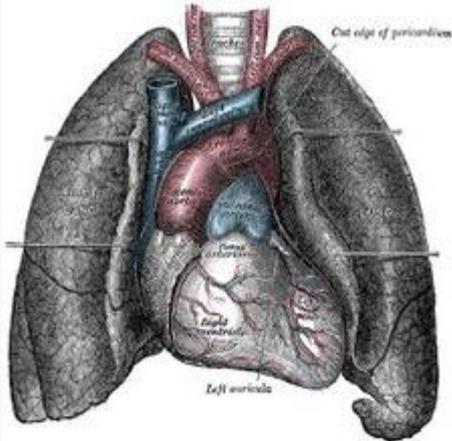
- Svodové systémy pro měření EKG
- EKG křivky
- Počítačový popis EKG

IV. Přístroje k měření EKG

V. Nemoci srdce (patoelektrofyziologie) a jejich možná léčba

VI. Umělé srdce

Anatomie srdce



Reference: Wikipedia -

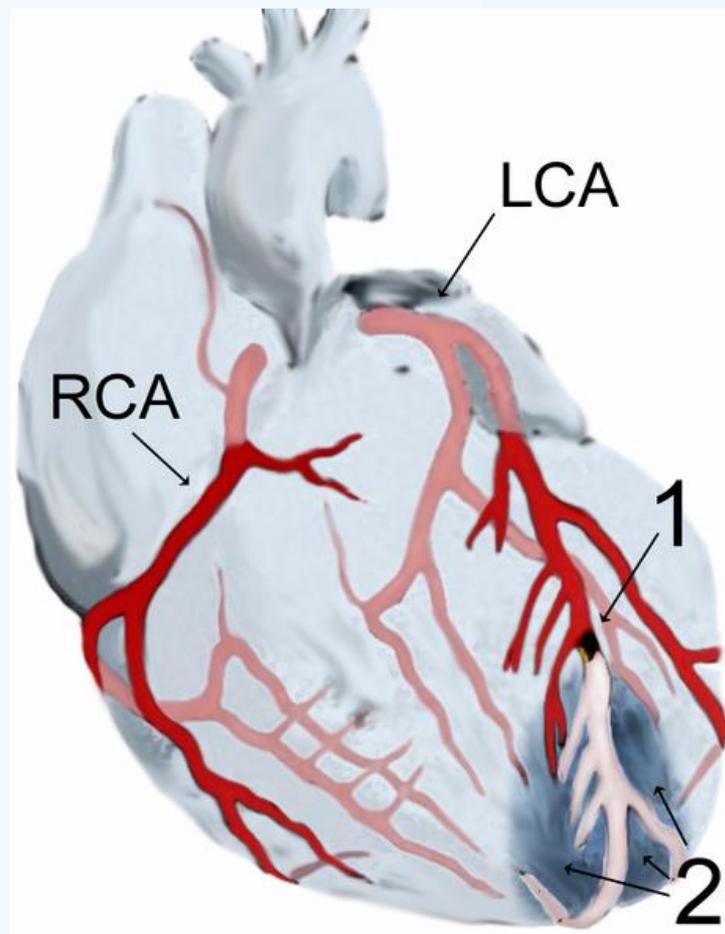
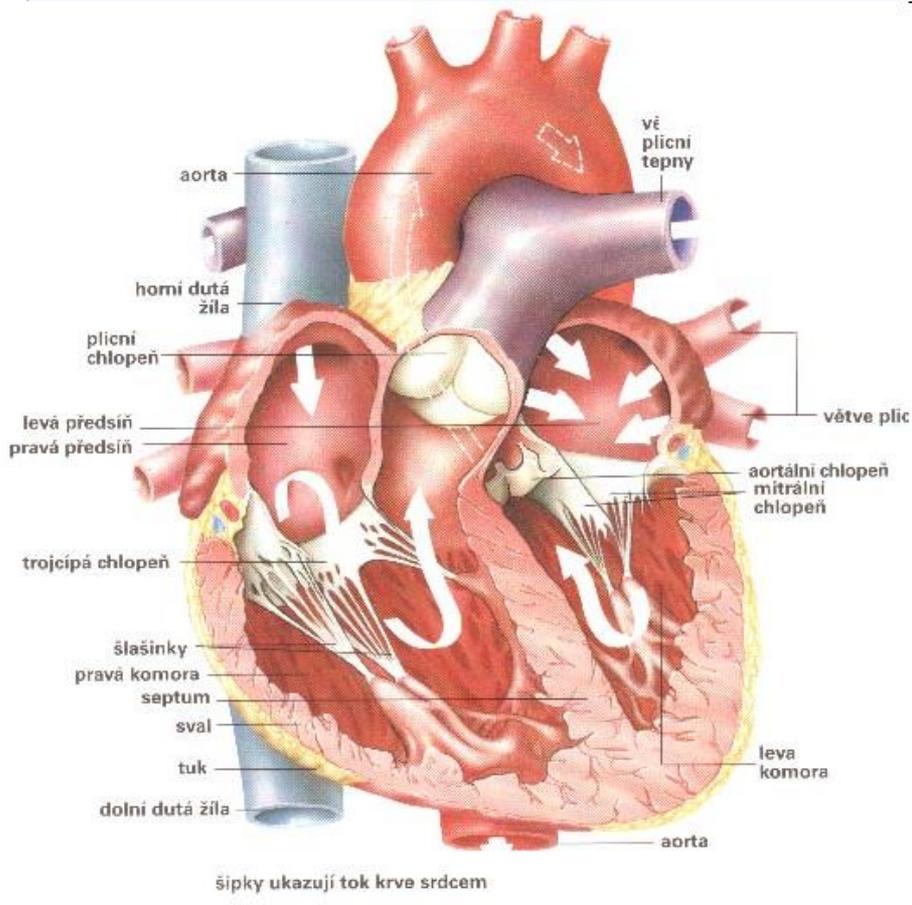
<http://cs.wikipedia.org/wiki/Srdce>

FNHK -

<http://www.fingerland.cz/img/aktivita/srdce1.jpg>

MCKK - <http://mckk.pardubice.cz/Srdce.jpg>

Anatomie srdce (2)



Reference: Wikipedia -

http://cs.wikipedia.org/wiki/Infarkt_myokardu

MCKK - <http://mckk.pardubice.cz/Srdce.jpg>

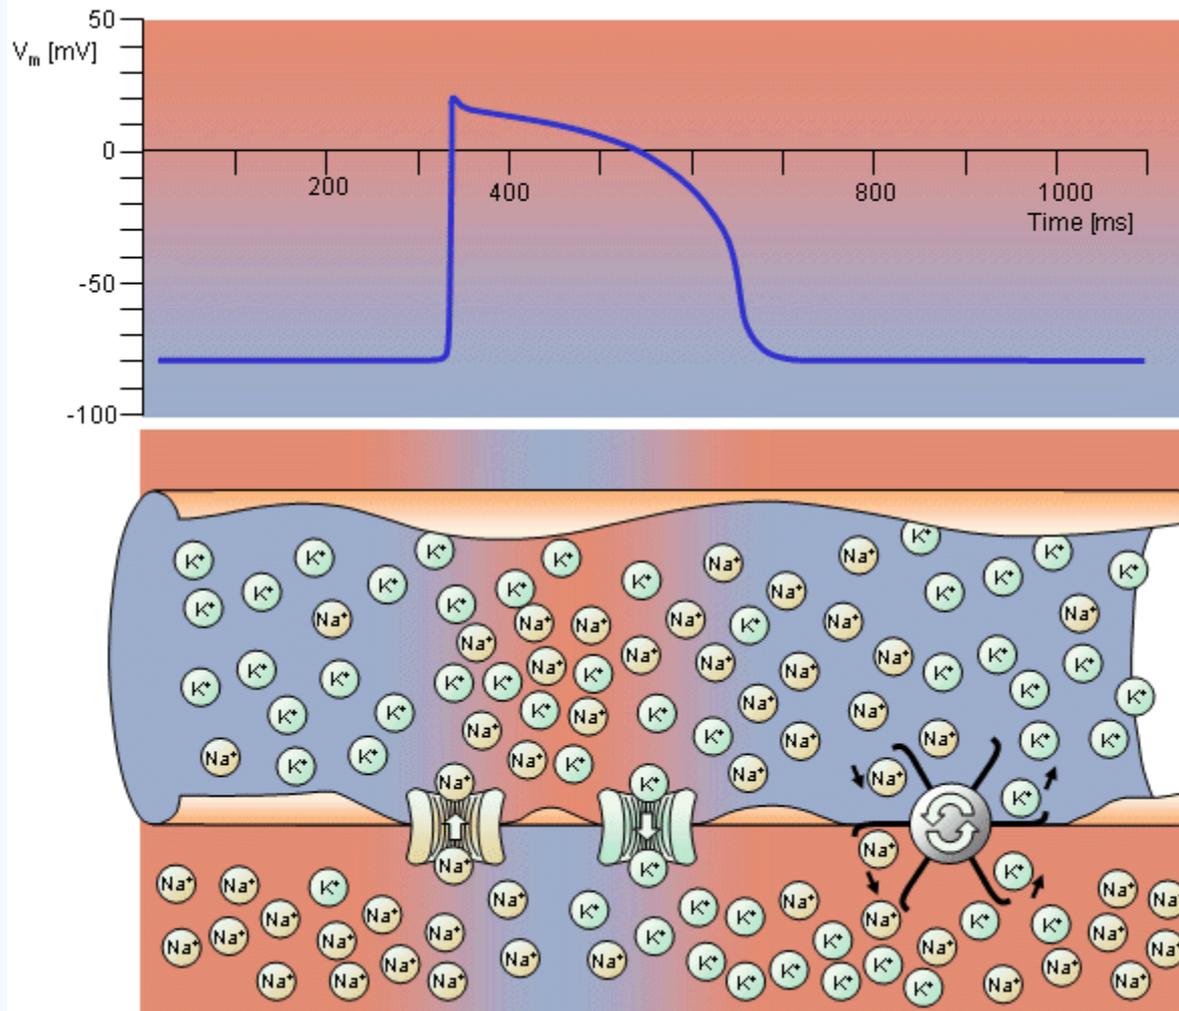
Elektrofyzologie srdce



❖ Srdeční buňky

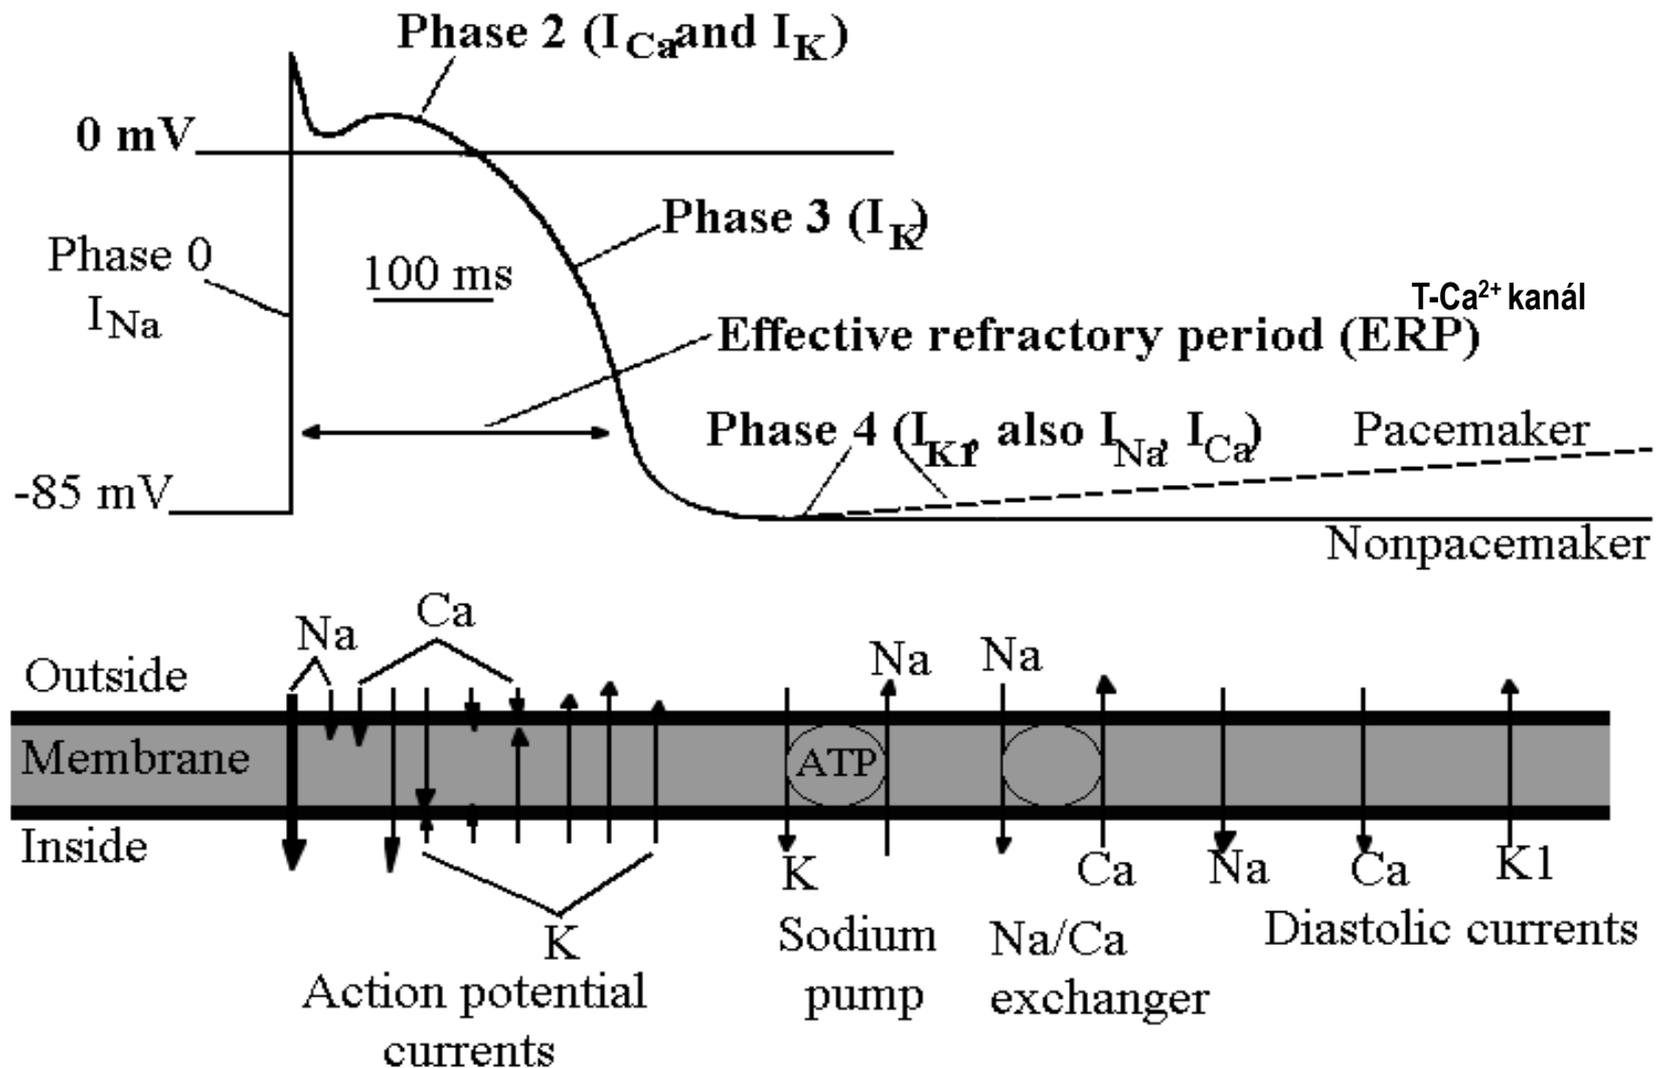
- ◆ Membránový potenciál kardiomyocytů je dán distribucí (koncentrací) Na^+ , K^+ , Ca^{2+} , Cl^- vně/uvnitř srdeční buňky
- ◆ V klidovém stavu distribuce náboje na obou stranách membrány není rovnovážná (homogenní)
- ◆ Klidový membránový potenciál -85 mV (+ vnějšek, - vnitřek b.)
- ◆ Na^+ : vně 140 mM, uvnitř 10-15 mM
- ◆ K^+ : vně 4 mM, uvnitř 140 mM
- ◆ *Příčinou nerovnováhy v rozdělení náboje je klidová neprostupnost membrány pro ionty a rovnováhu udržující mechanismy*
- ◆ Vzrušivost myokardu - vznik akčního potenciálu
 - ❖ Selektivní a časově harmonizovaná prostupnost membrány

Elektrofyzologie srdce (2)



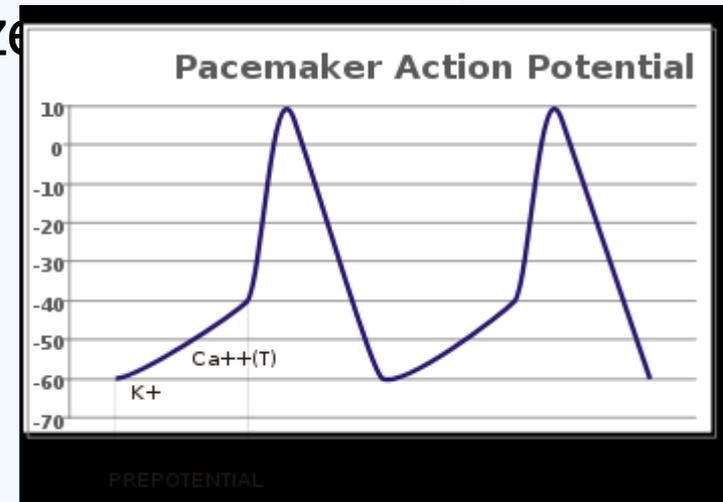
Reference: BioElectromagnetism -
<http://www.bem.fi/>

Elektrofyzologie srdce (3)



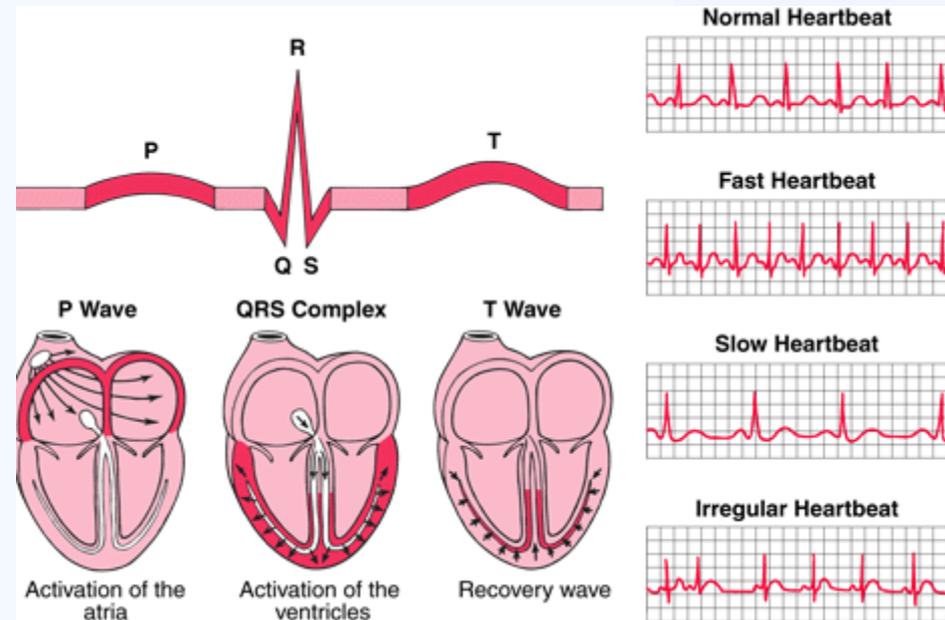
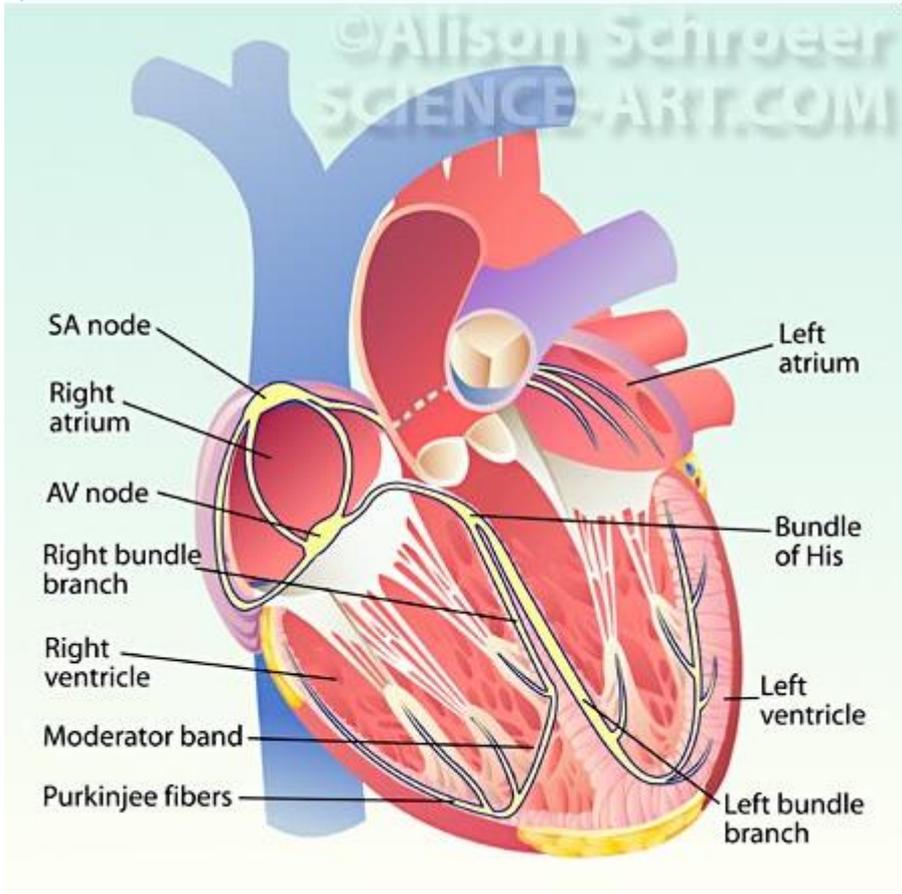
Pacemakerové buňky

- ❖ Primární SinoAtriální uzel (SA)
 - ◆ 100 bpm
 - ◆ Ovlivňován sympatikem a parasympatikem +/-
 - ◆ Adrenalin/noradrenalin přímý efekt
- ❖ Sekundární AtrioVentrikulární uzel
 - ◆ 40-60 bpm
- ❖ Terciální – Hisův svazek
 - ◆ 30-40 bpm



- ❖ Změna permeability membrány vůči draslíku
- ❖ „Funny current“ - sodík

Převodní systém srdeční

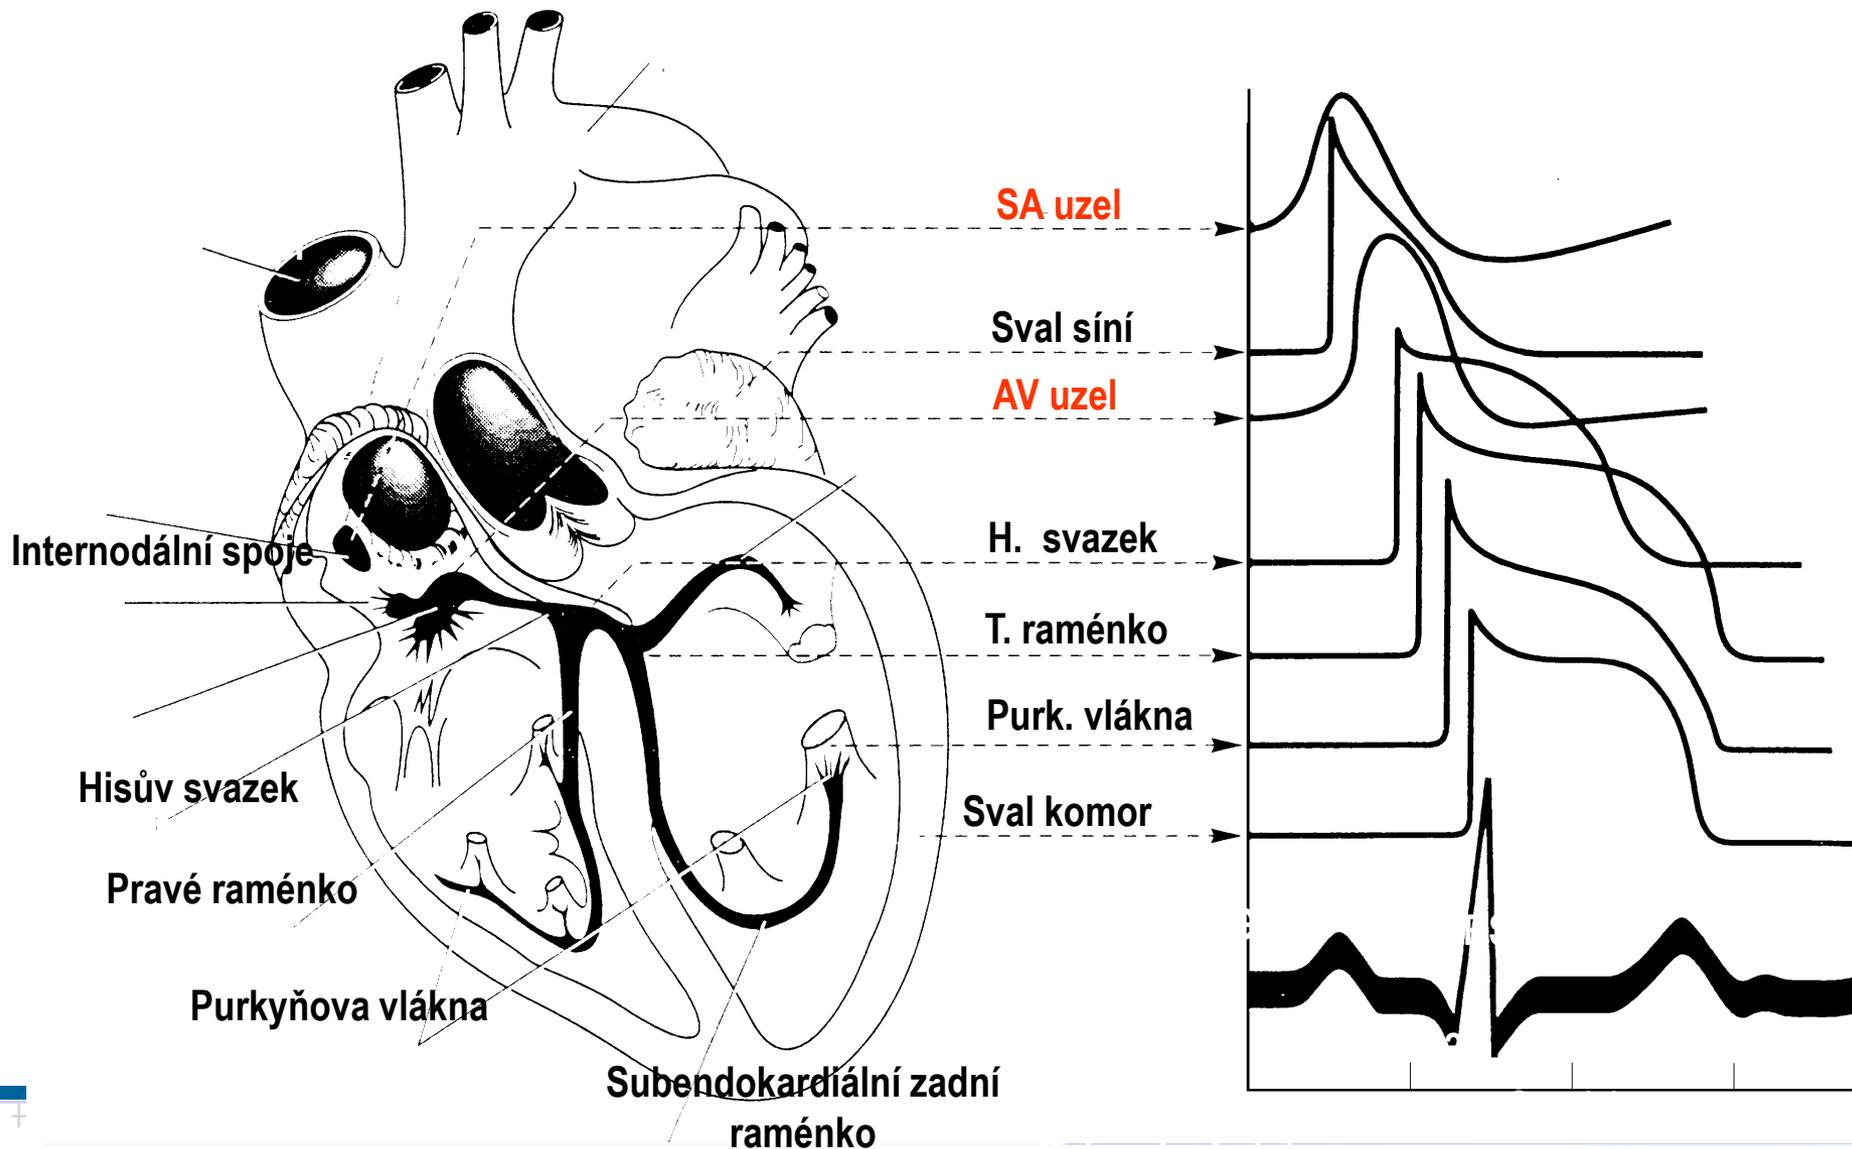


Reference: ScienceArt - www.science-art.com/

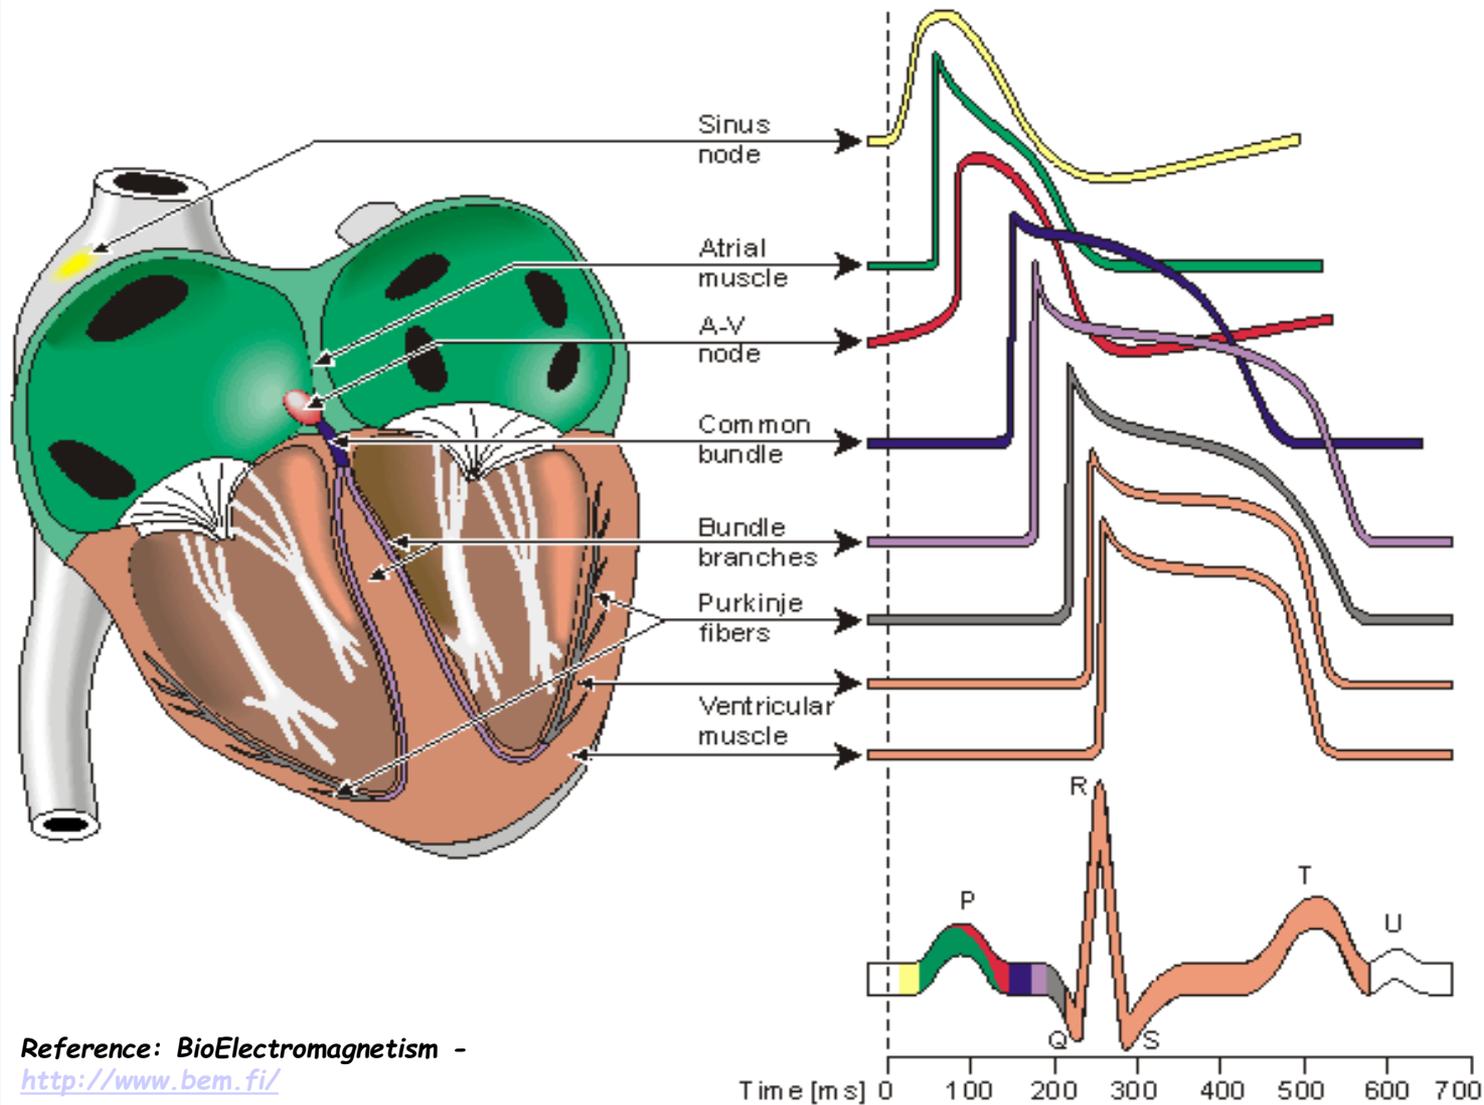
PAFO -

<http://www.pafo.co.uk/cms/>

Převodní systém srdeční (2)



Převodní systém srdeční (3)

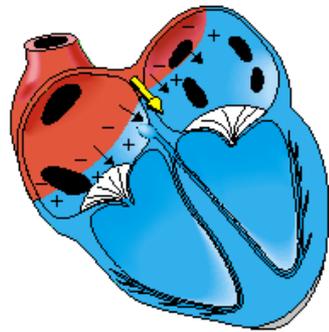


Reference: BioElectromagnetism -
<http://www.bem.fi/>

Vznik EKG signálu



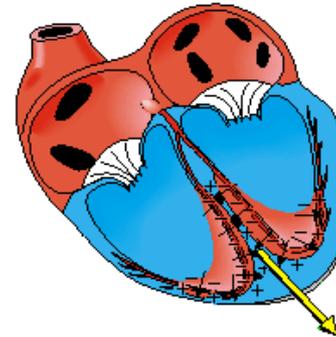
ATRIAL
DEPOLARIZATION
80 ms



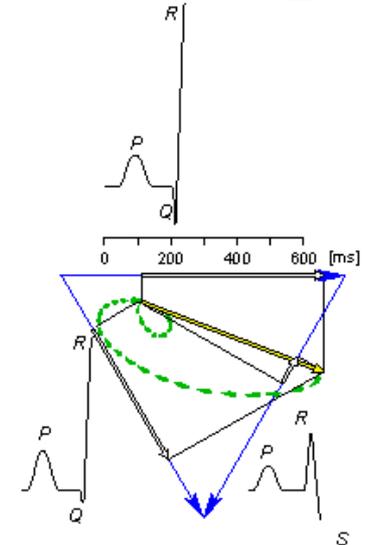
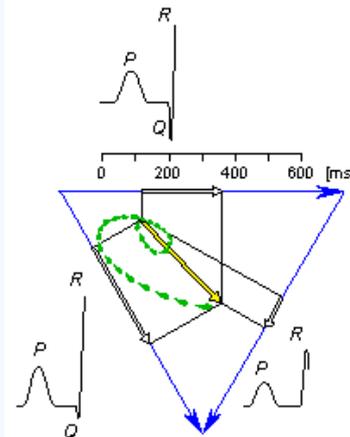
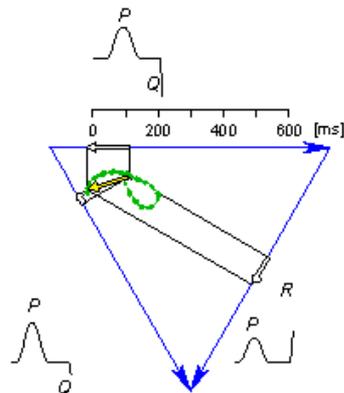
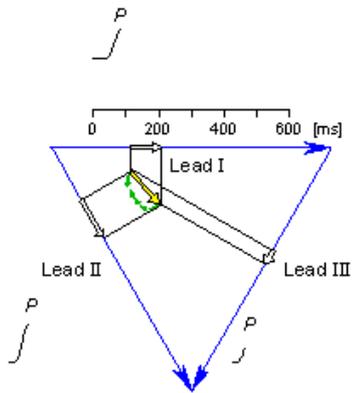
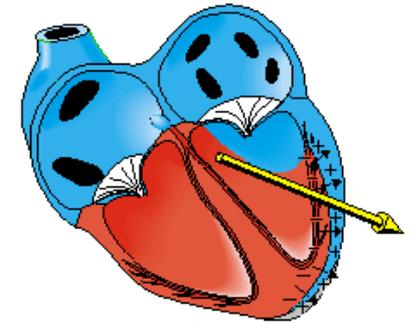
SEPTAL
DEPOLARIZATION
220 ms



APICAL
DEPOLARIZATION
230 ms



LEFT VENTRICULAR
DEPOLARIZATION
240 ms



Reference: BioElectromagnetism -
<http://www.bem.fi/>

Vznik EKG signálu (2)

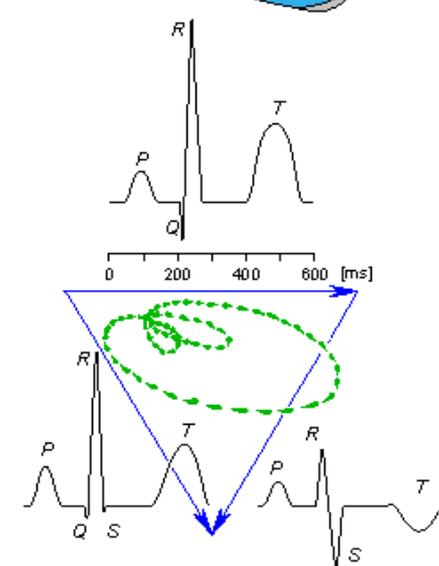
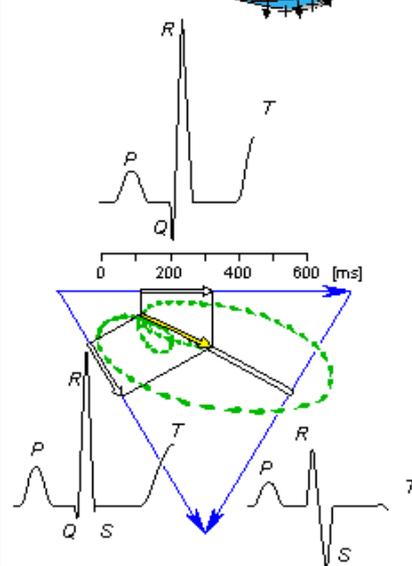
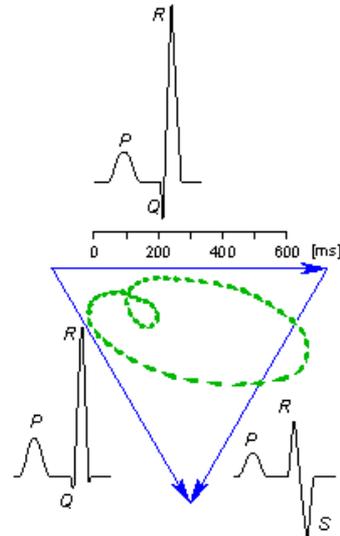
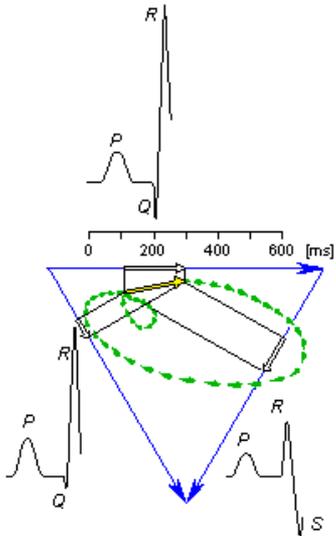
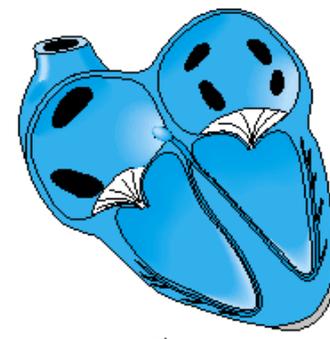
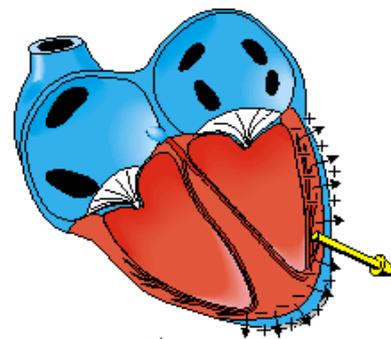
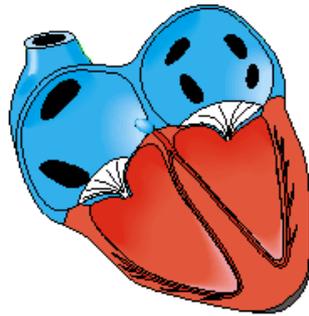
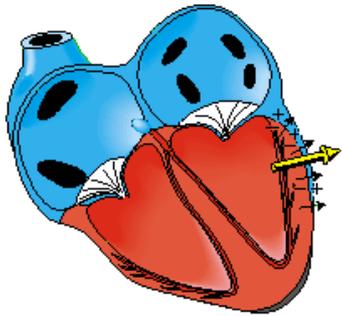


LATE LEFT VENTRICULAR
DEPOLARIZATION
250 ms

VENTRICLES
DEPOLARIZED
350 ms

VENTRICULAR
REPOLARIZATION
450 ms

VENTRICLES
REPOLARIZED
600 ms



Reference: BioElectromagnetism -
<http://www.bem.fi/>

Přehled přednášky



I. Úvod do úvodu - co je to srdce?

II. Srdce z morfologického a funkčního pohledu

- Anatomie srdce
- Elektrofyziologie srdce
- Akční potenciál
- Pacemakerové buňky
- Převodní systém srdeční
- „Vznik“ EKG

III. EKG

- Svodové systémy pro měření EKG
- EKG křivky
- Počítačový popis EKG

IV. Typy měření EKG – principy a přístroje

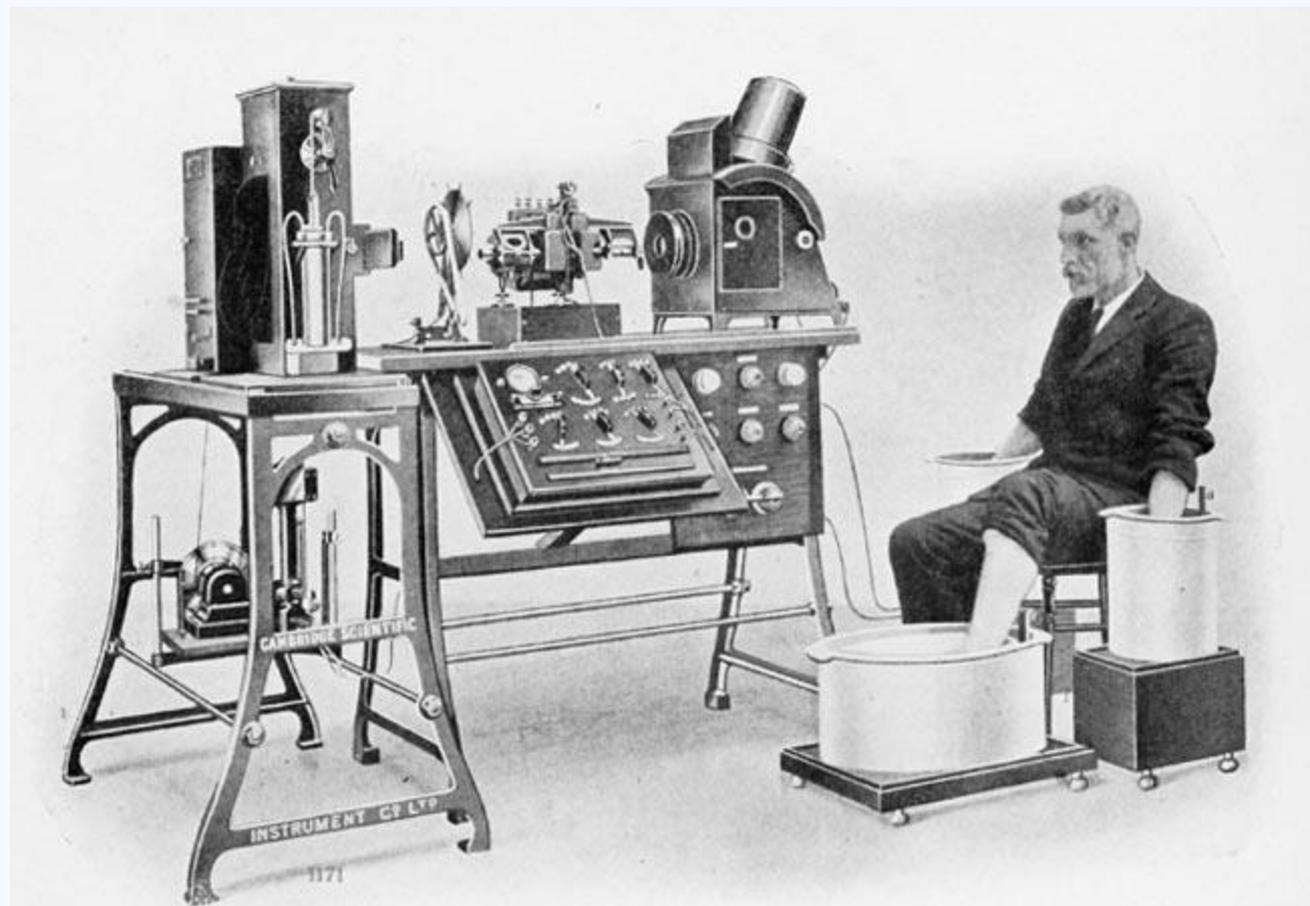
- Standardní 12ti svodové EKG
- Holter
- Automatický defibrilátor
- Multisvodové EKG (BSPM)
- Echokardiografie
- A-EGM
- Kardiotokografie a HRV
- Telemedicína

V. Nemoci srdce (patoelektrofyziologie) a jejich možná léčba

- Poruchy rytmu
- Infarkt myokardu

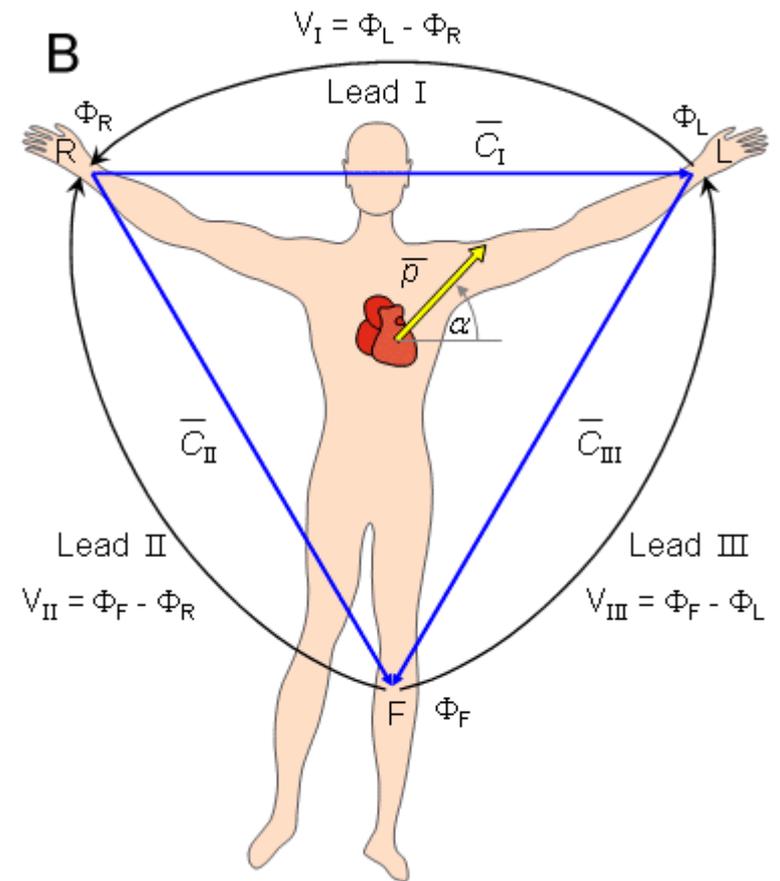
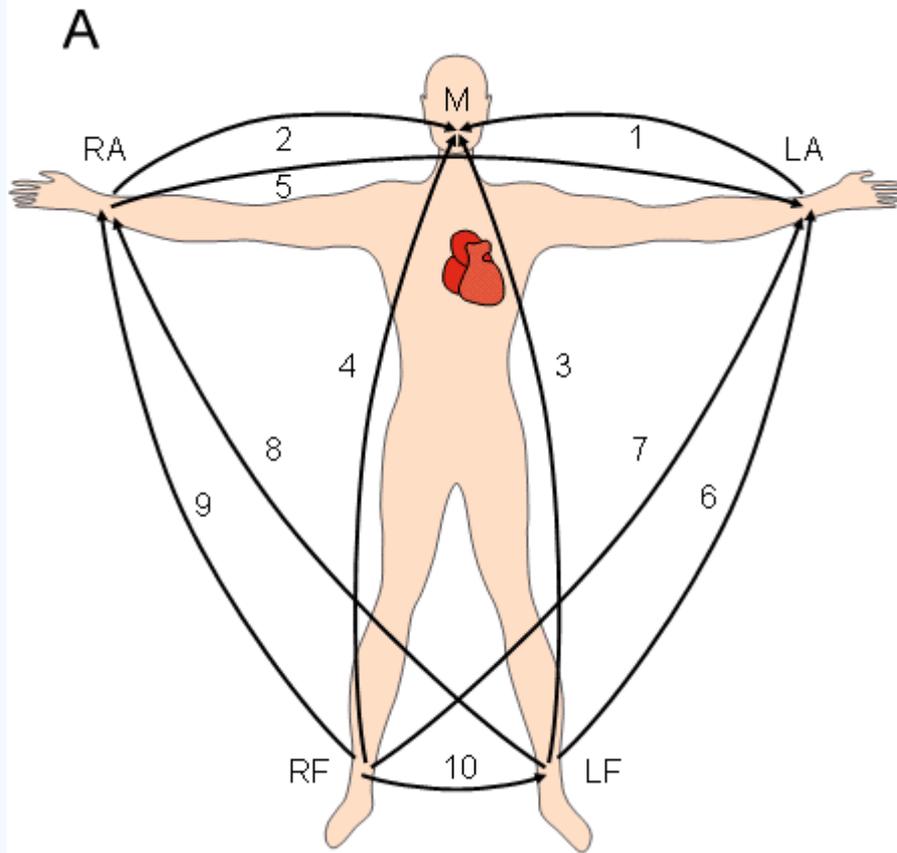
VI. Umělé srdce

Měření EKG



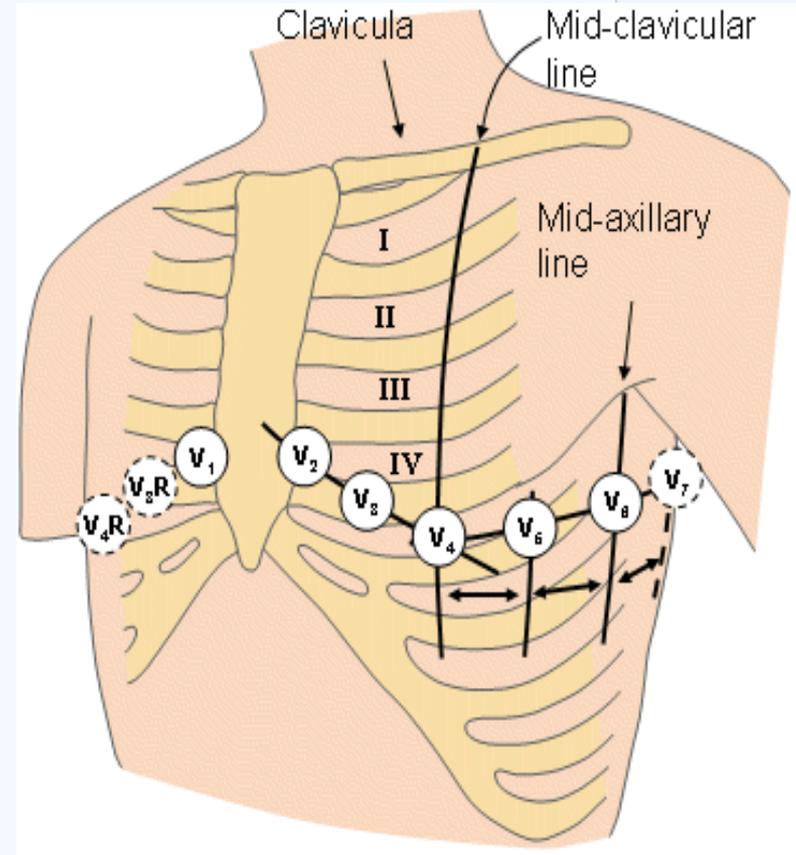
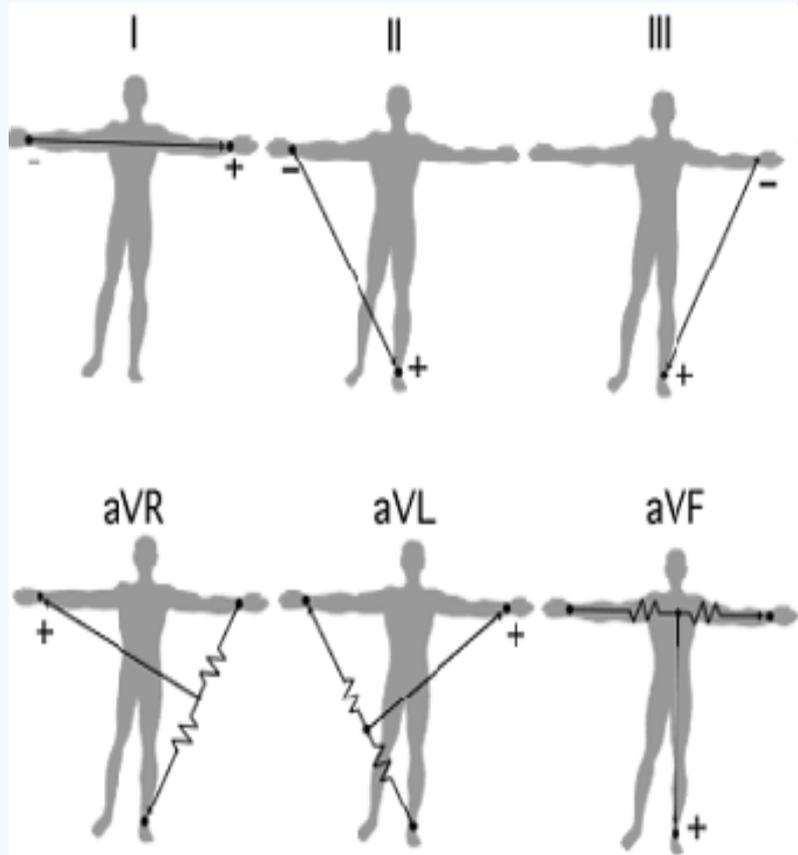
PHOTOGRAPH OF A COMPLETE ELECTROCARDIOGRAPH, SHOWING THE MANNER IN WHICH THE ELECTRODES ARE ATTACHED TO THE PATIENT, IN THIS CASE THE HANDS AND ONE FOOT BEING IMMERSSED IN JARS OF SALT SOLUTION

Svodové systémy



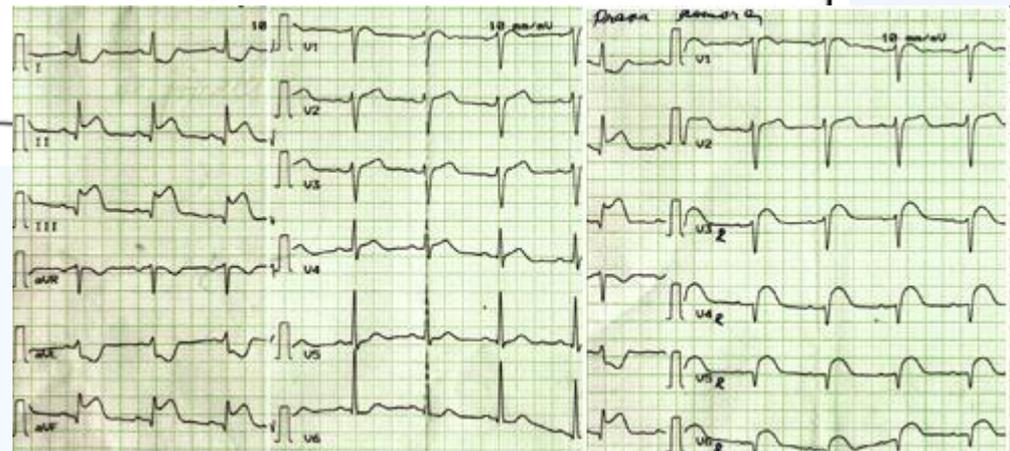
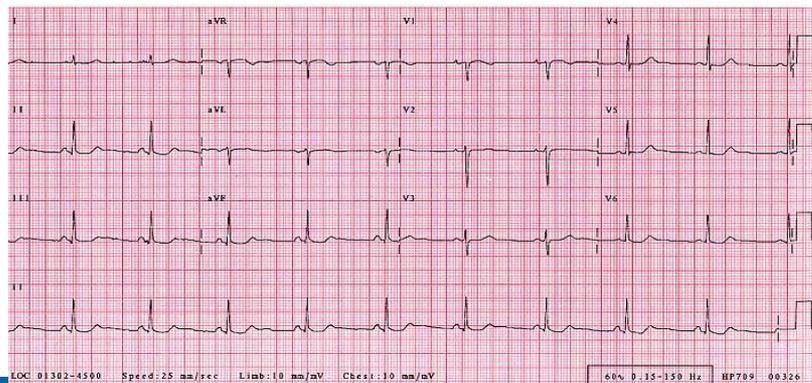
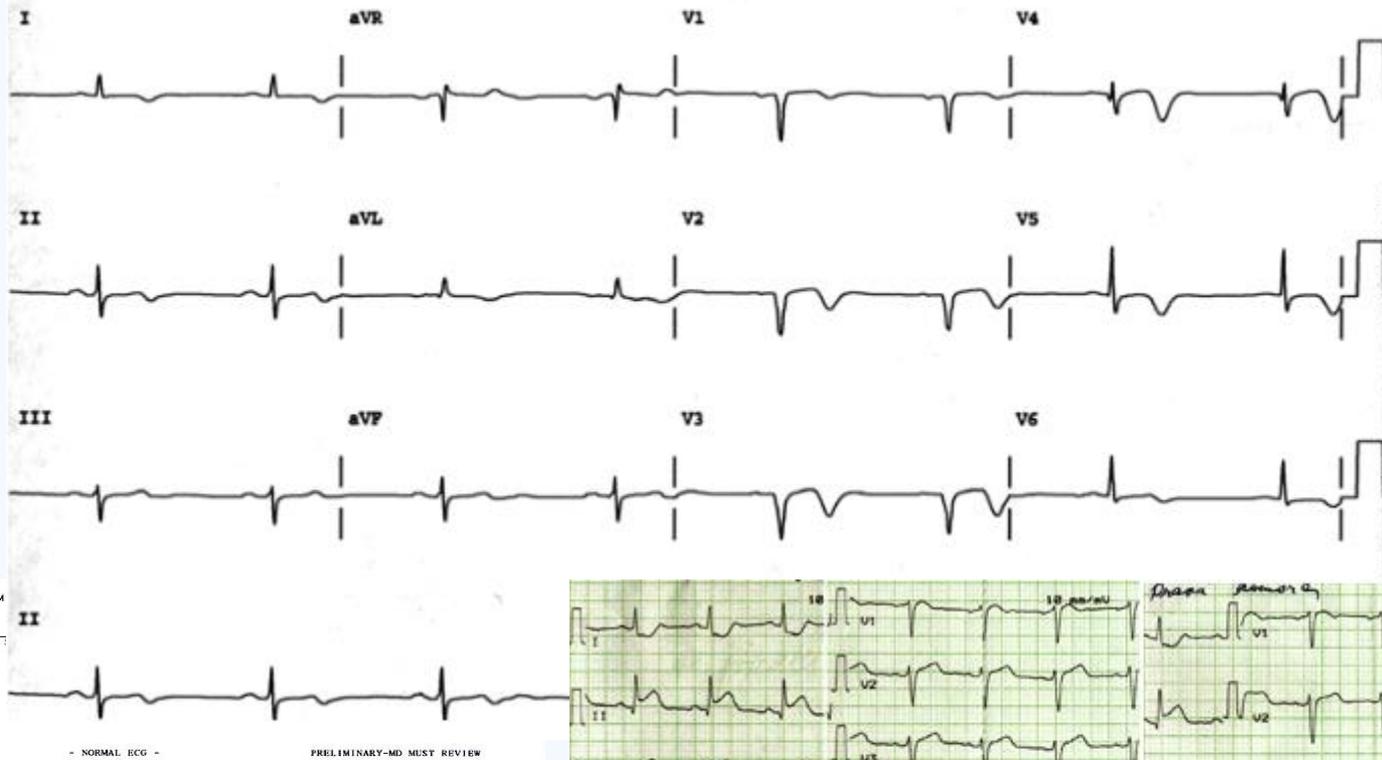
Reference: BioElectromagnetism -
<http://www.bem.fi/>

Bipolární a unipolární svody



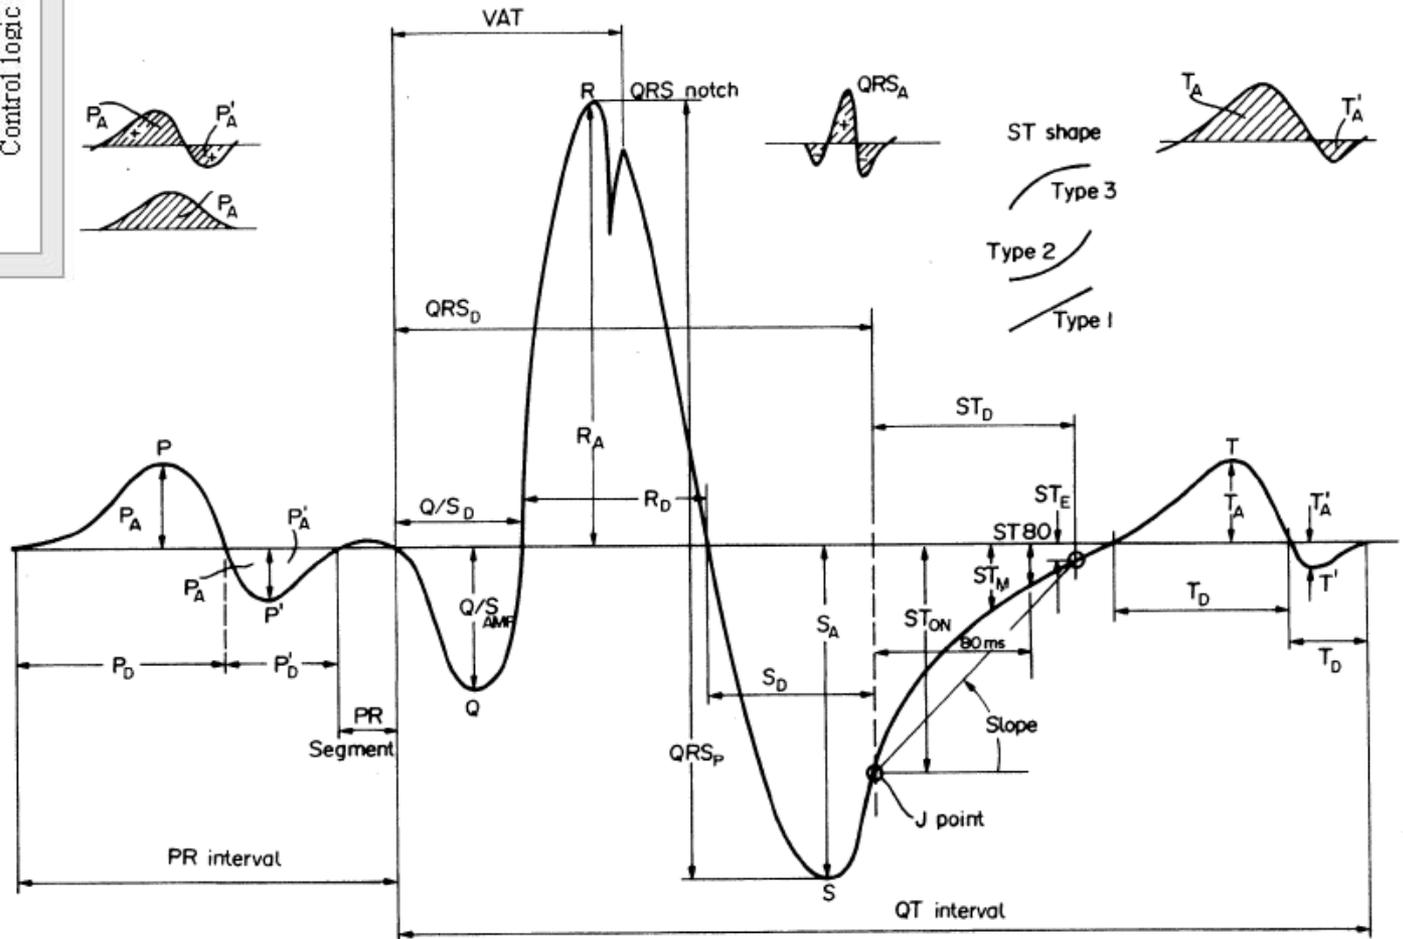
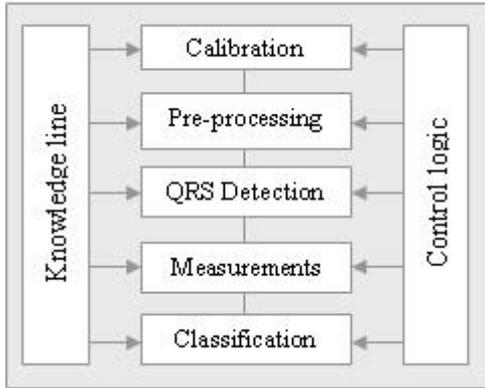
Reference: BioElectromagnetism -
<http://www.bem.fi/>

EKG křivky



Reference: <http://www.stefajir.cz/>
<http://www.zzs.cz/odbtem/>

Počítačový popis EKG



Přehled přednášky



I. Úvod do úvodu - co je to srdce?

II. Srdce z morfologického a funkčního pohledu

III. EKG

- Svodové systémy pro měření EKG
- EKG křivky
- Počítačový popis EKG

IV. Typy měření EKG – principy a přístroje

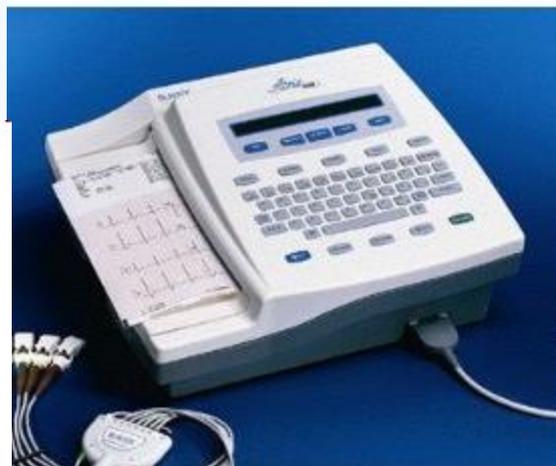
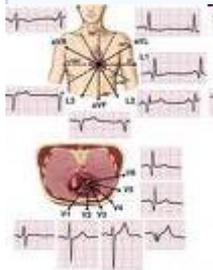
- Standardní 12ti svodové EKG
- Holter
- Automatický defibrilátor
- Multisvodové EKG (BSPM)
- Echokardiografie
- A-EGM
- Kardiotokografie a HRV
- Telemedicína

V. Nemoci srdce (patoelektrofyzologie) a jejich možná léčba

- Poruchy rytmu
- Infarkt myokardu

VI. Umělé srdce

12-ti svodové EKG

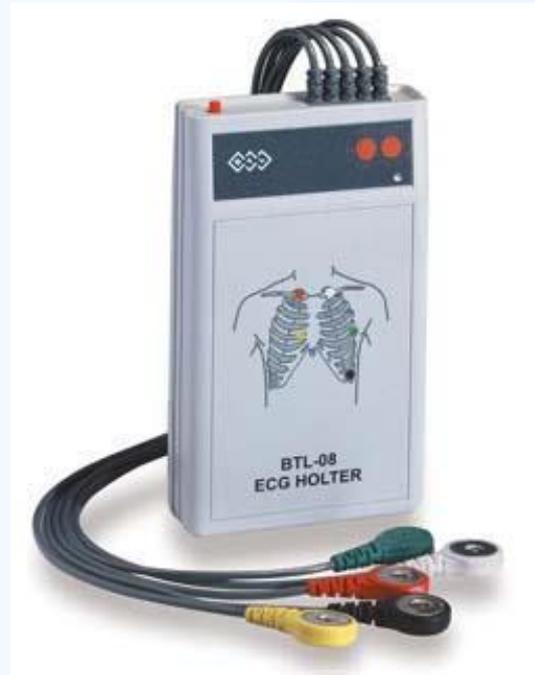


Automatický defibrilátor

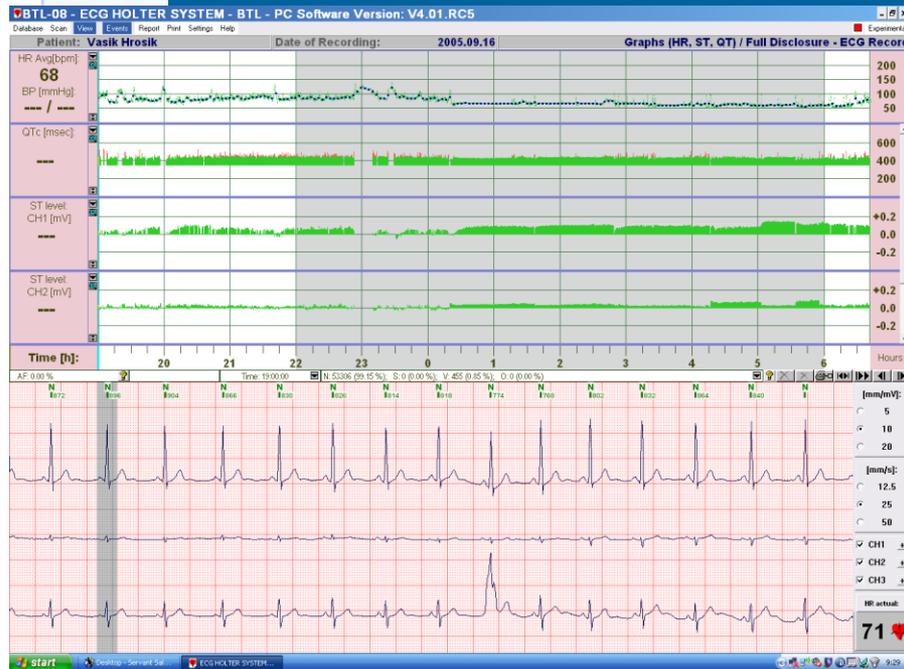


Holterovské EKG

- ❖ Dlouhodobé záznamy, 24-48 hodin, zjednodušený svodový systém
- ❖ Holterovské vs. 12ti svodové EKG:
 - ◆ Nevýhody
 - ❖ Méně svodů
 - ❖ Více šumu
 - ❖ Větší problémy s rozměřováním vln
 - ❖ Pohybové artefakty
 - ❖ Větší dynamicita RR intervalů
 - ◆ Výhody
 - ❖ Větší časový rozsah
 - ❖ Užitečné pro detekci arytmií
 - ❖ Pokrývá všemožnou lidskou aktivitu



Holterovské EKG (2)

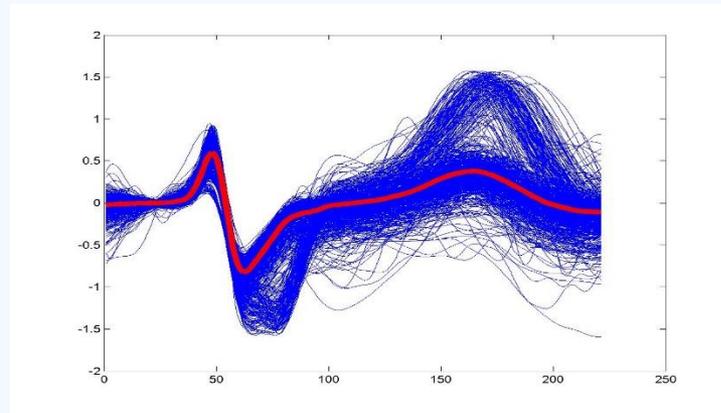


❖ Velká variabilita kvality signálu



❖ Velká robustnost detektoru vln je potřebná k detekci jednotlivých EKG vln.

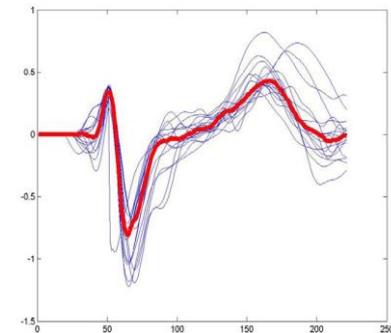
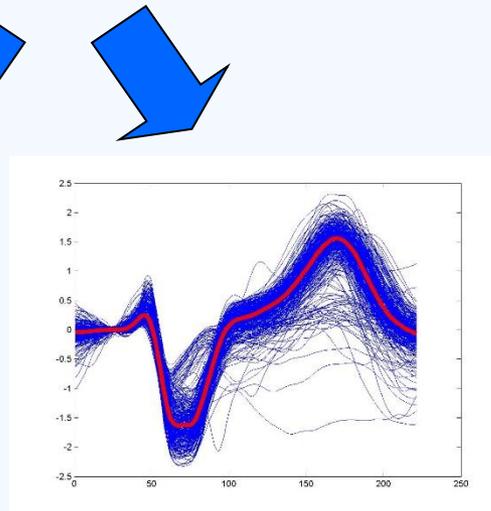
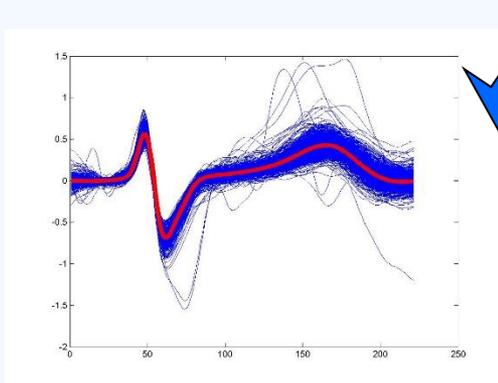
Holterovské EKG (3)



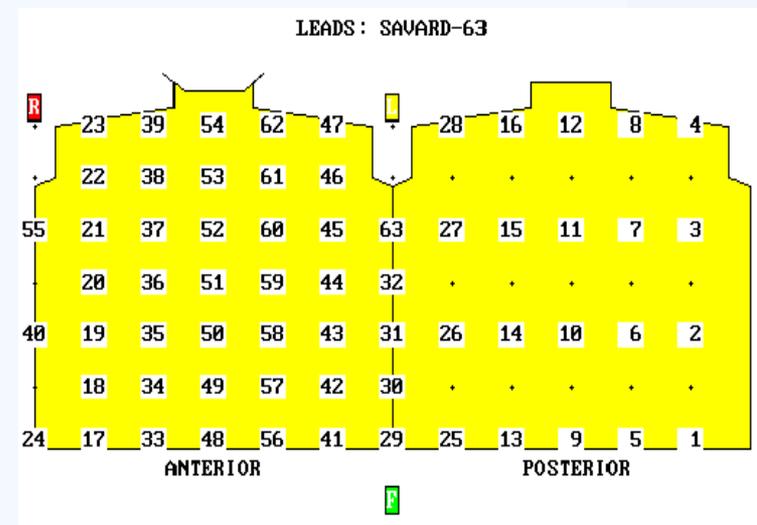
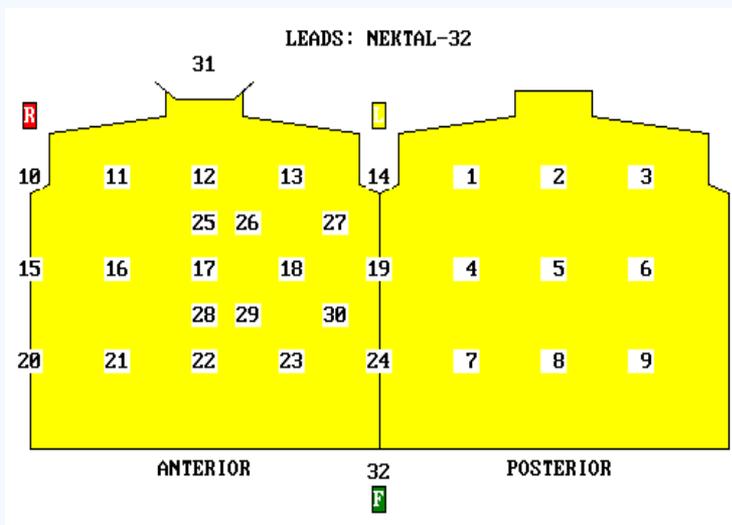
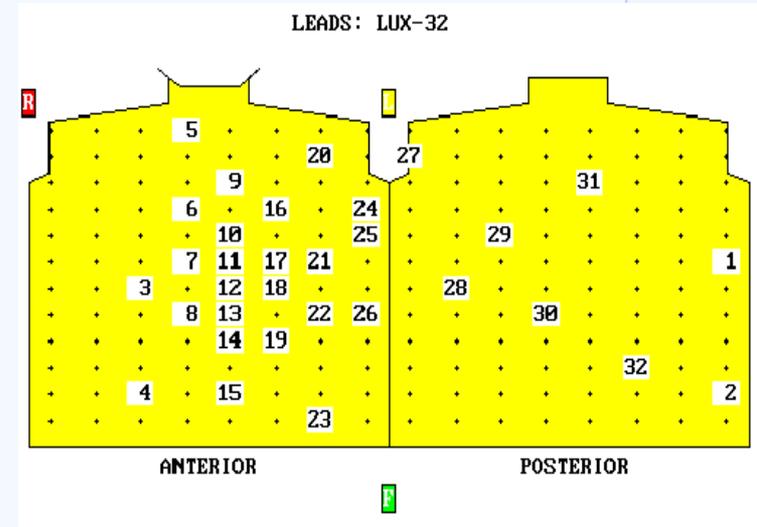
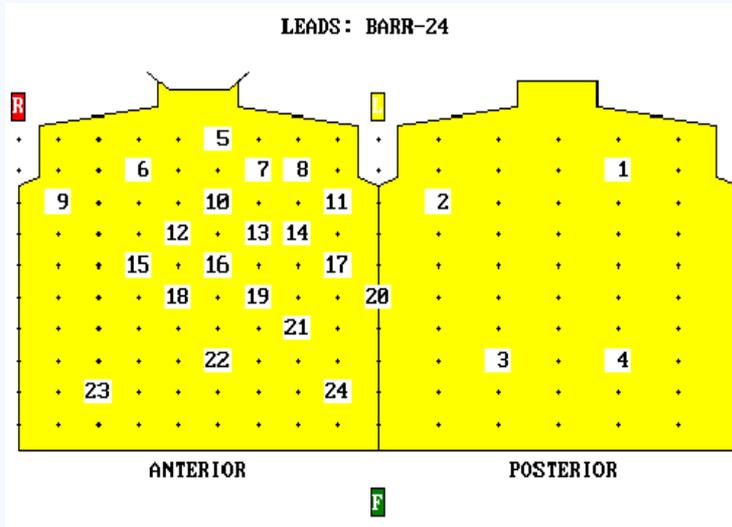
❖ Shlukování beatů z EKG záznamů

❖ Median vypočítaný na základě změřených parametrů

❖ **Cíl:** Diagnosticky vázané skupiny pro preciznější diagnostiku

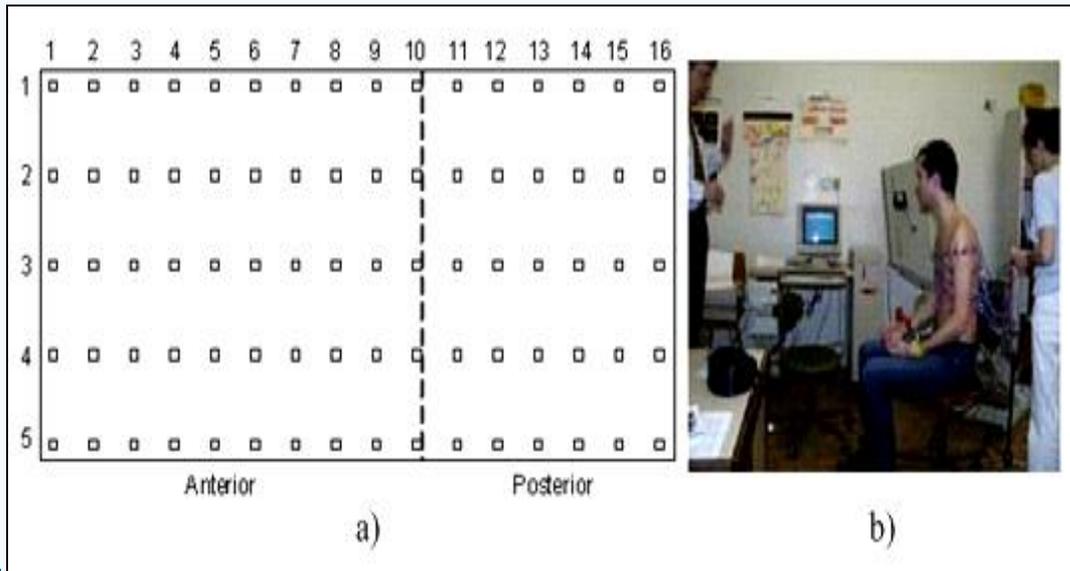


Mapování potenciálů z hrudníku



BSPM

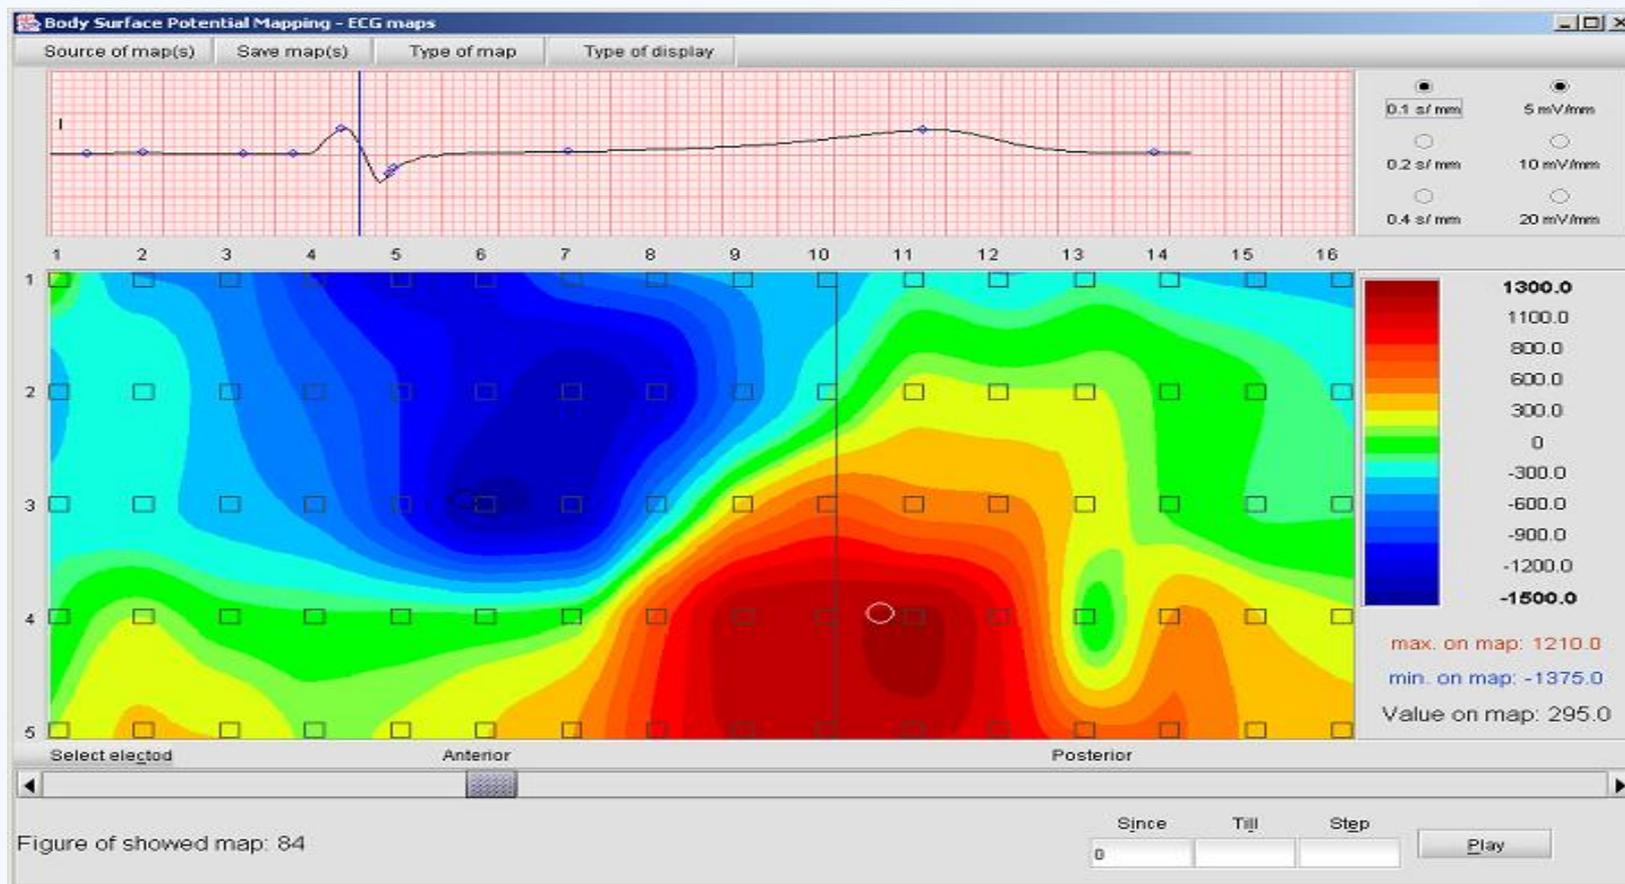
- ❖ 80 unipolárních elektrod je rozmístěno ekvidistantně na hrudníku v matici 16x8 elektrod – Československý výrobek Cardiac 112.2
- ❖ 128 elektrod v matici BioSemi na FÚ 1.LF UK
- ❖ Předzpracování signálu může využívat různé metody – např. waveletovou transformaci
- ❖ Příznaky se dají vyhledávat na vytvořených mapách – viz následující průsvitky





Isopotenciálové mapy

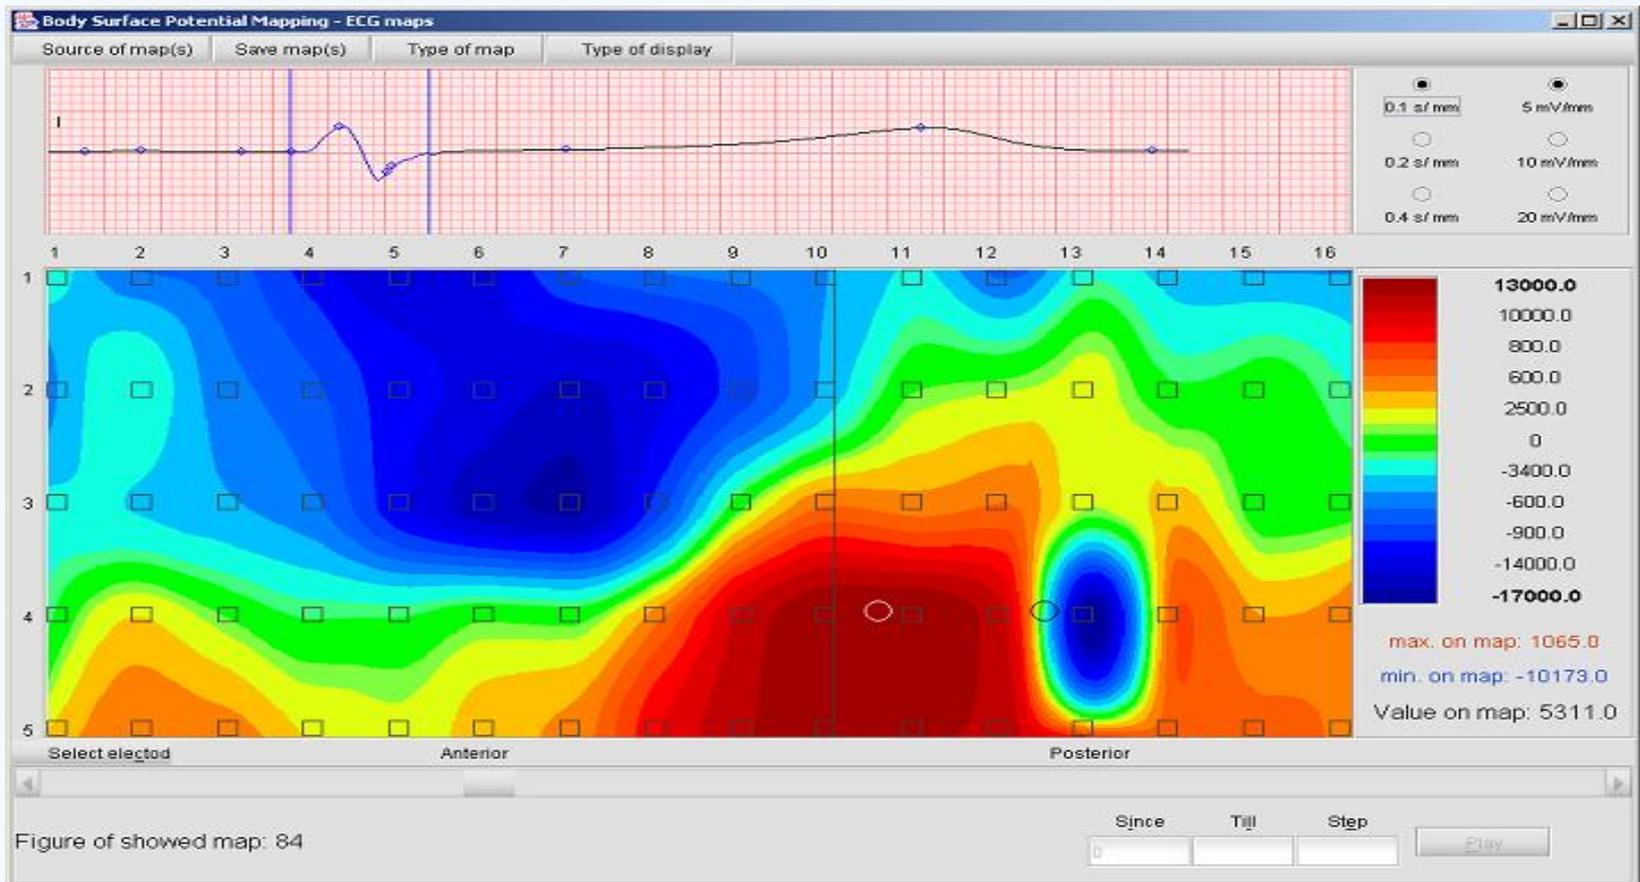
❖ Základní typ map definován jako $P_i = U_i(t)$, $t = \text{konst.}$, $i = 1, 2, \dots, n$



Isointegrální mapy



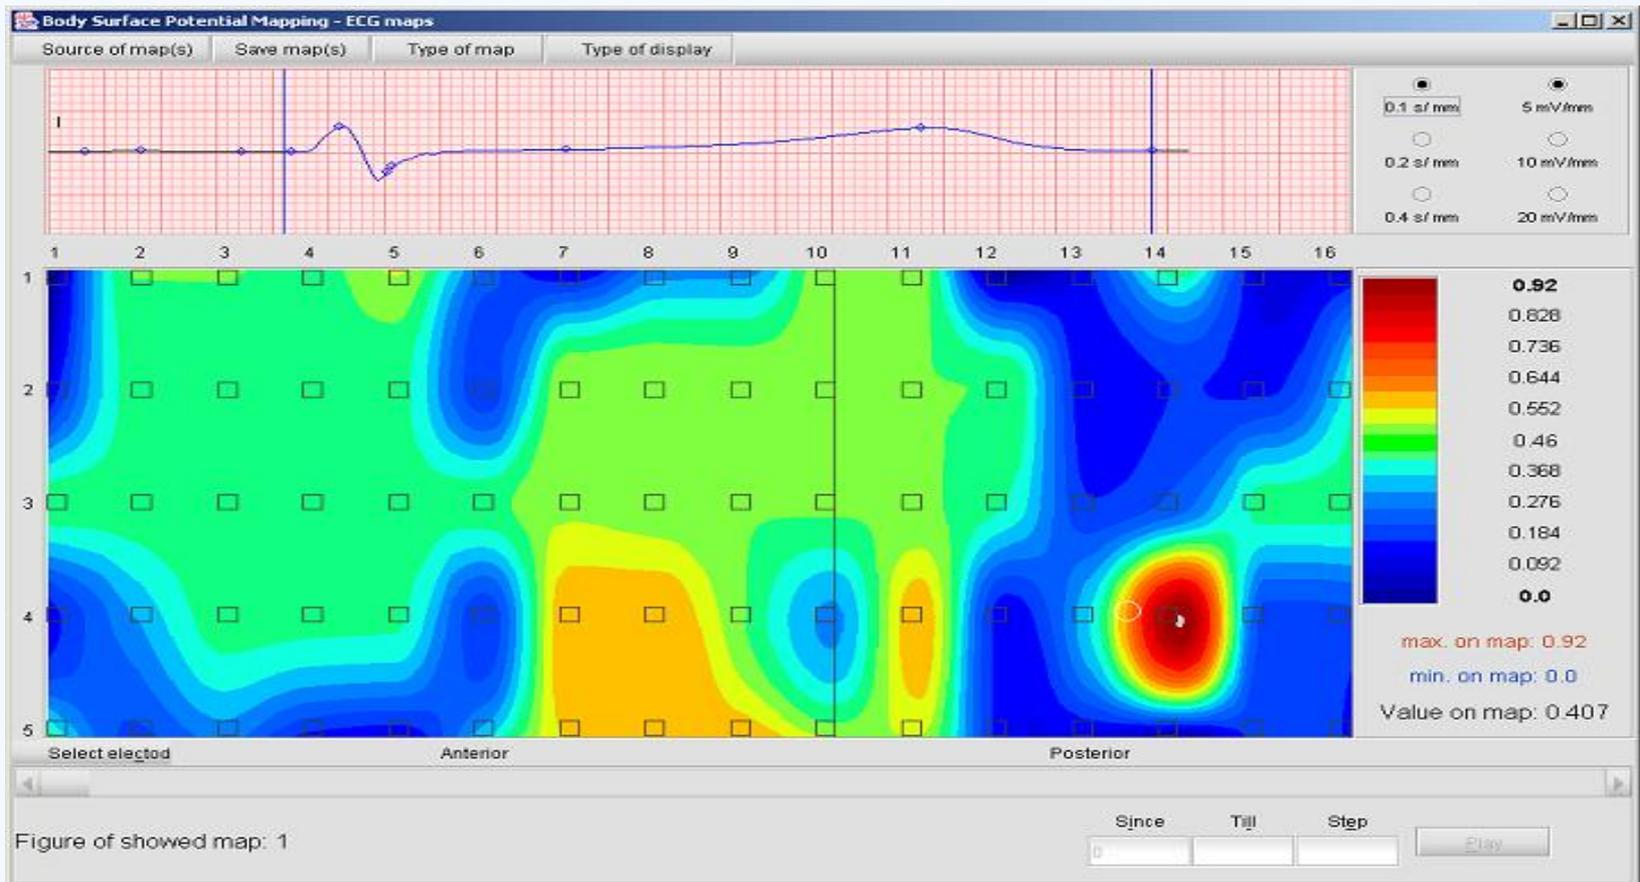
❖ Mapy jsou vypočteny jako $P_i = \int_{t_1}^{t_2} U_i(t) dt$



Isochronní mapy



Mapy jsou vypočteny jako $T_i = f(U_i(t))$

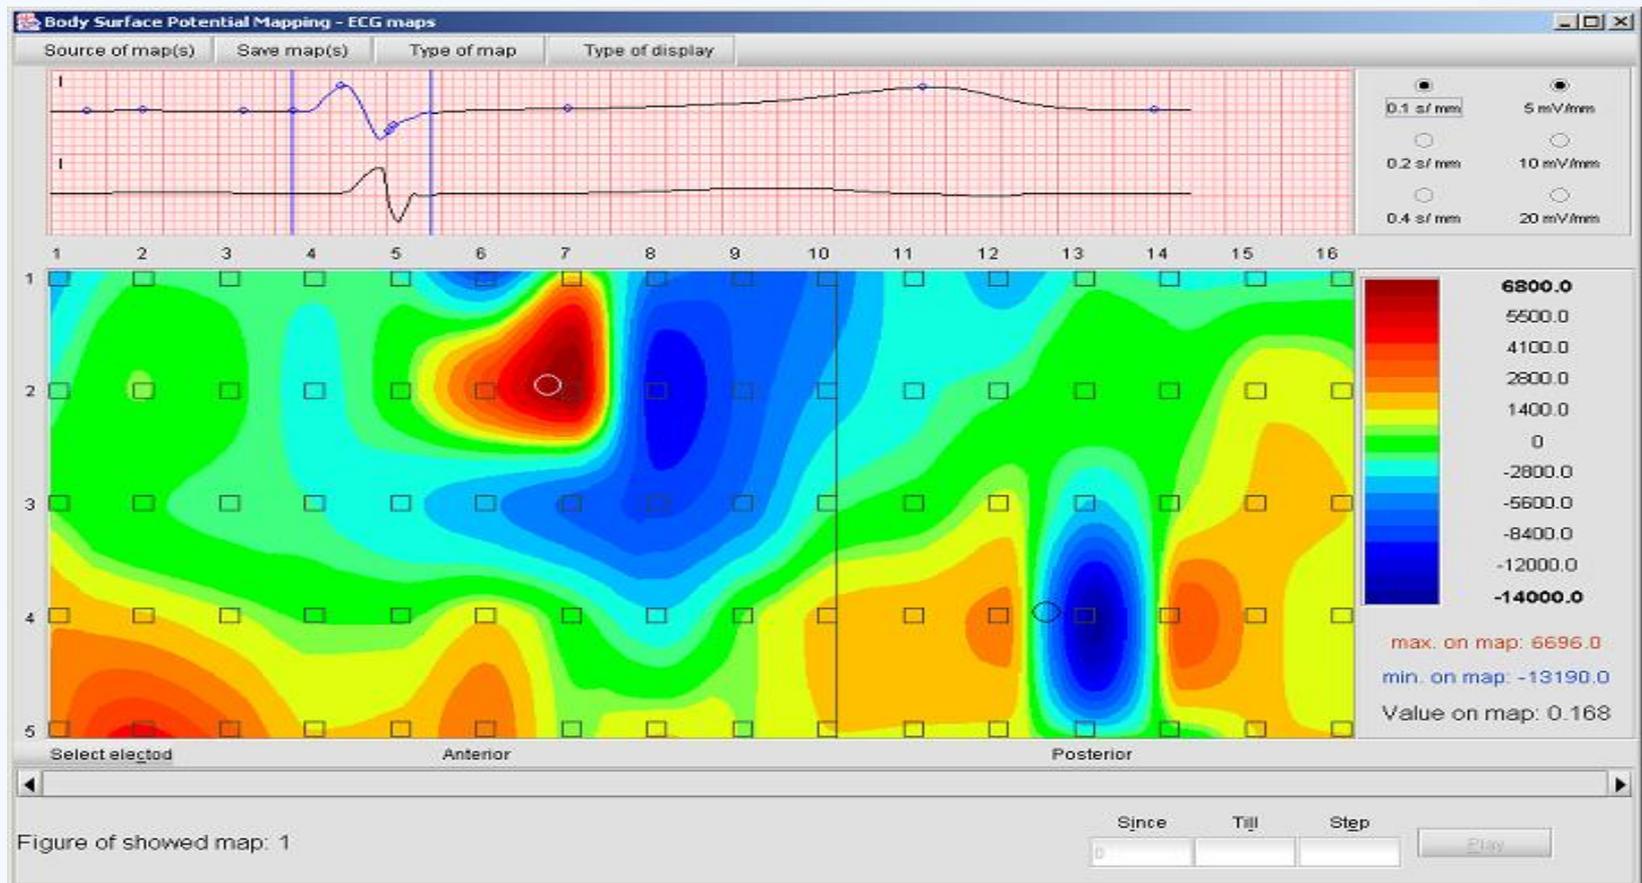


Rozdílové mapy



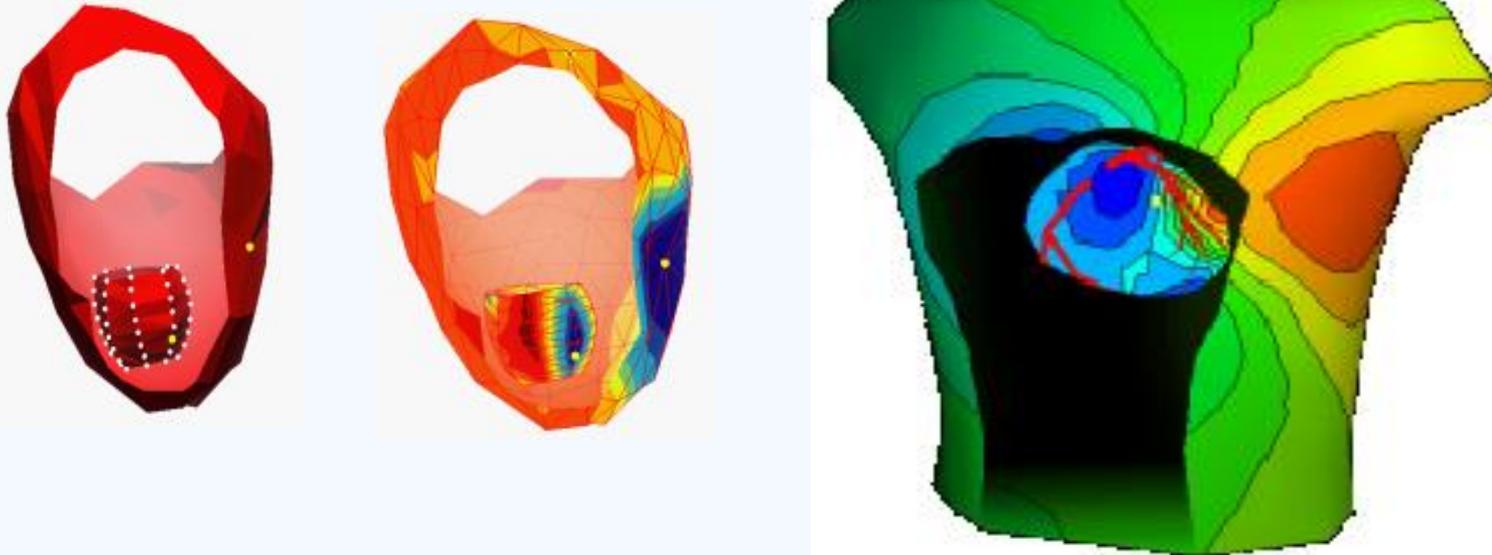
❖ Mapy jsou vypočteny na základě rozdílu dvou isointegrálních map

$$D_i = U_{i1} - U_{i2}, \text{ resp } P_{i1} - P_{i2}$$



3D mapování, inverzní úloha

- ❖ Vizualizace srdeční aktivity na epikardu
- ❖ Měření může být provedeno přímo na srdci
- ❖ Může být vypočteno z BSPM
- ❖ Vede k inverzní úloze elektrokardiografie
- ❖ Vyhledávání ložisek arytmií



Zpracování BSPM záznamů



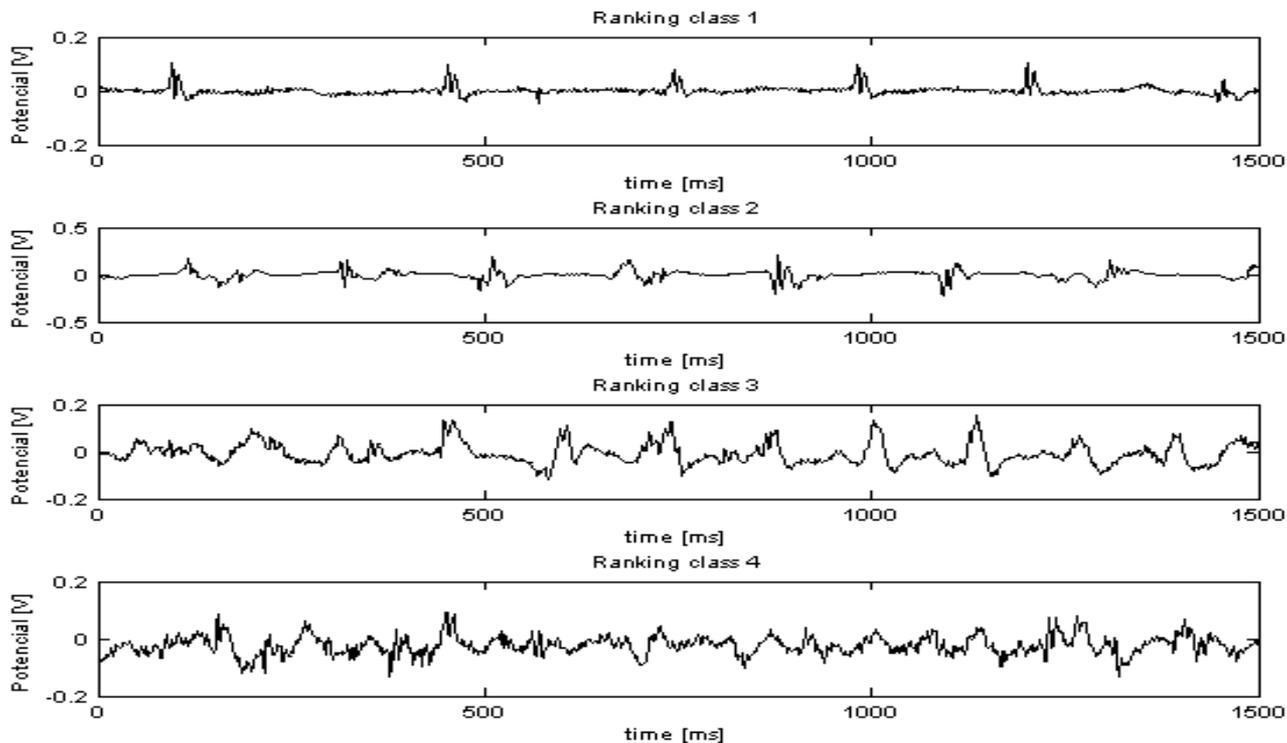
- ❖ Inverzní úloha:
 - ◆ Řešení úlohy přepočtu povrchových potenciálů na srdce
 - ◆ Problematika elmag. pole
 - ◆ Vliv těla - nutnost znát umístění a natočení srdce
 - ◆ Spojeno s CT nebo MRI vyšetřením
- ❖ Předpokládané využití především ve fyziologii arytmiických změn
- ❖ Hledání (určení) umístění nekrotické tkáně na srdci po infarktu

Zpracování BSPM záznamů (2)



Zpracování A-EGM

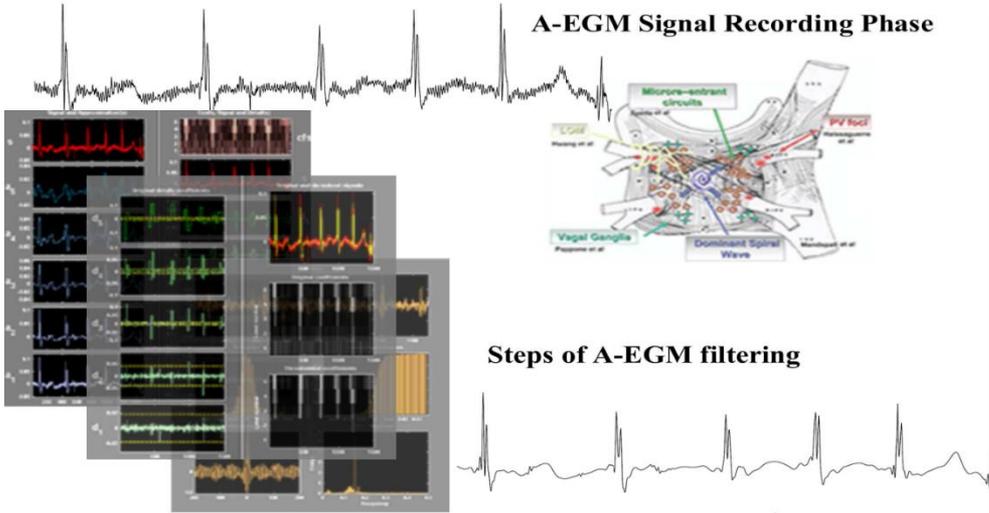
- ❖ Signály získané z měření uvnitř srdce při katetrizaci – atrial electrograms (A-EGMs)
- ❖ Podle signálu lze určit podíl daného bodu na arytmií



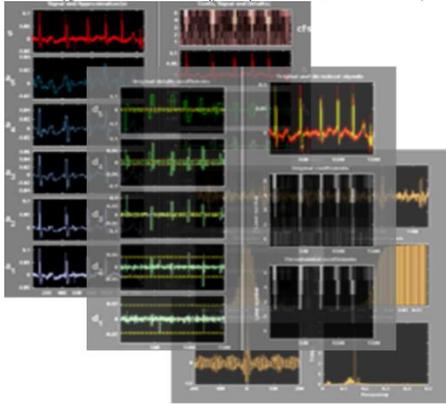
Zpracování A-EGM (2)



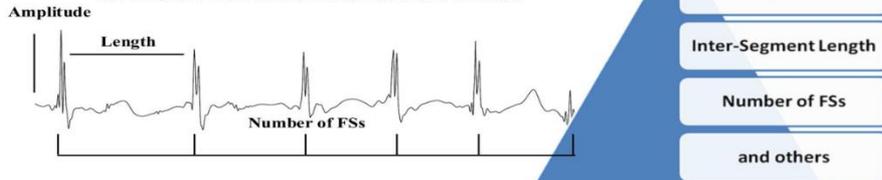
A-EGM Signal Recording Phase



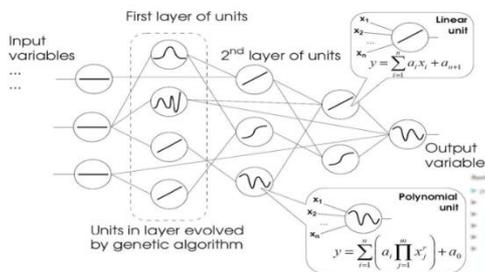
Steps of A-EGM filtering



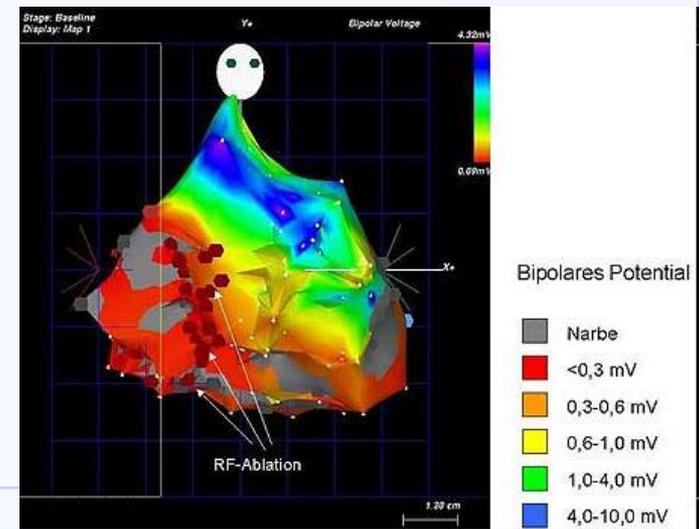
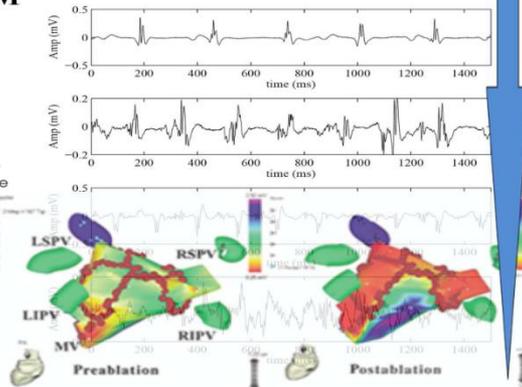
A-EGM Feature Extraction Phase



Regression or Classification of A-EGM

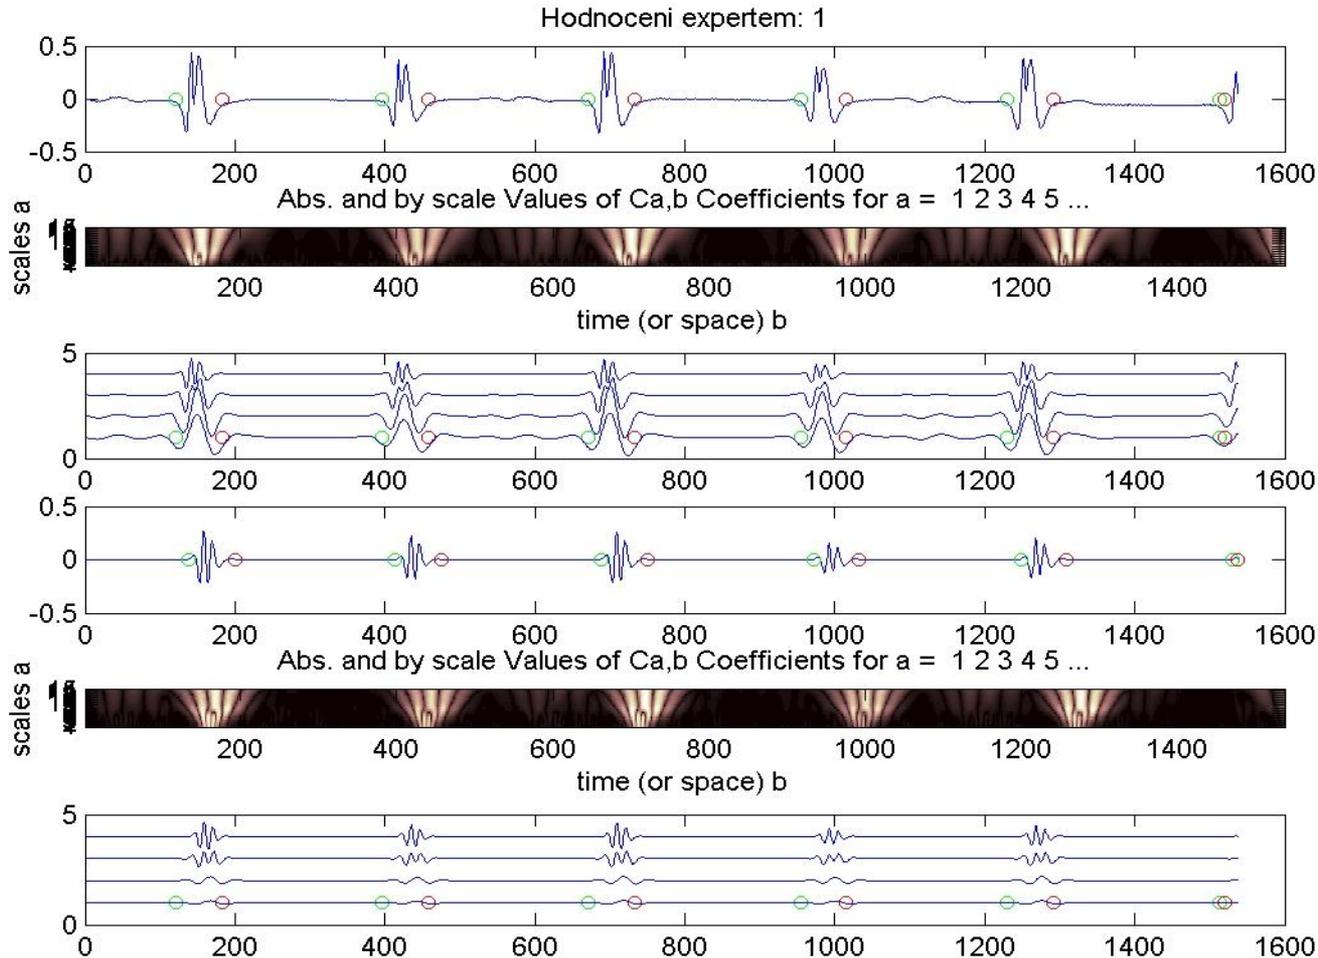


The Results



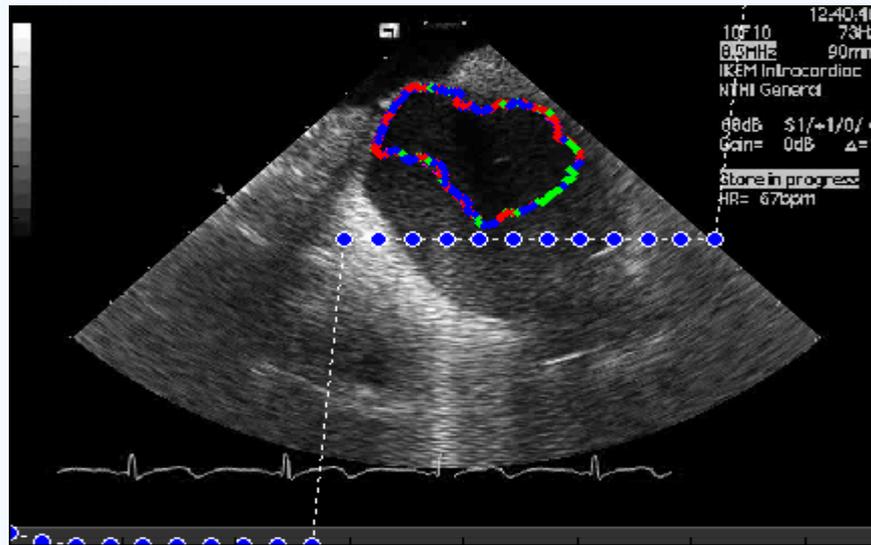
Zpracování A-EGM (3)

❖ Vzniká úloha automatického stanovení



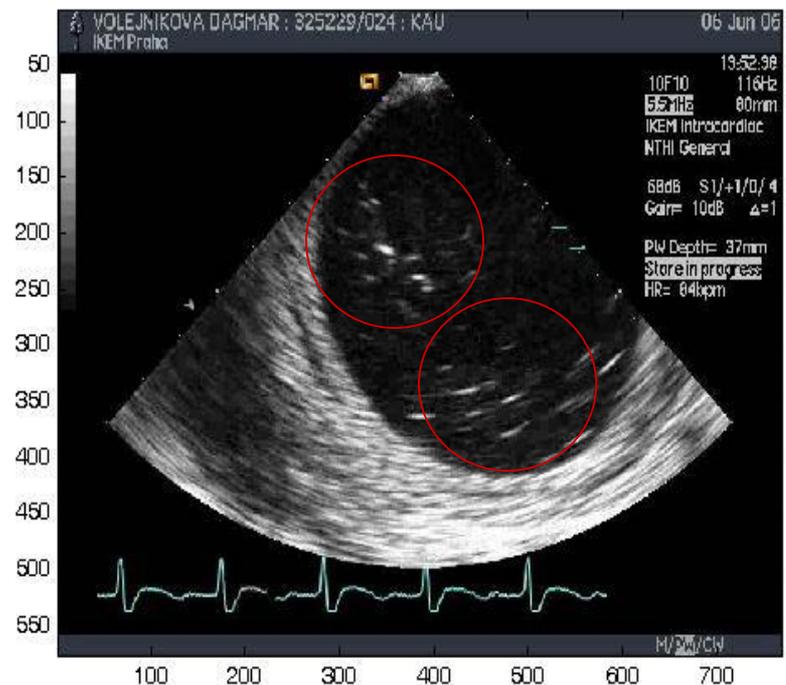
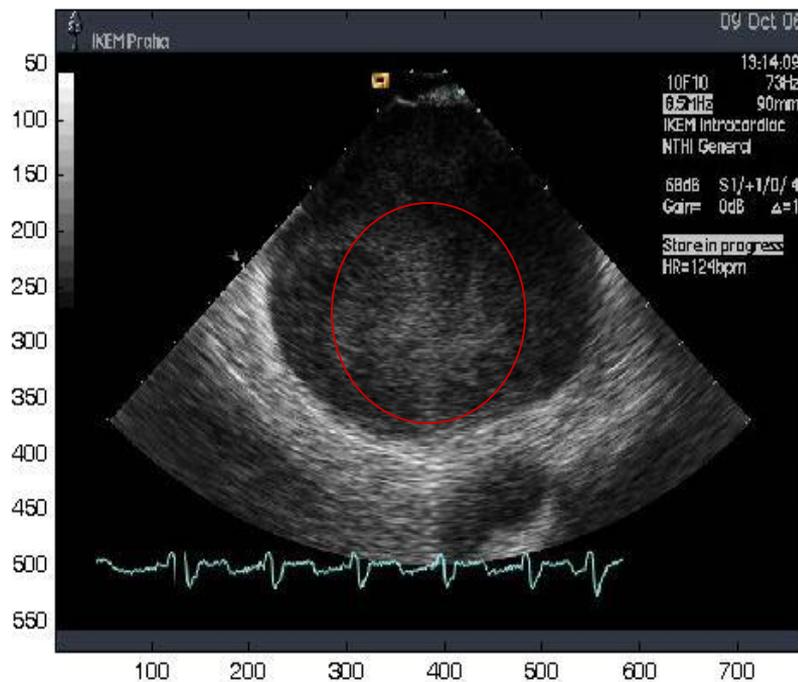
Echokardiografie

- ❖ Snímání srdce ze středu pravé síně – UZ na katetru
- ❖ Řešení automatického, resp. semi-automatického rozměření pro volumometrii
 - ◆ hledání okrajů pomocí aktivních kontur např. pomocí B-splajnů
 - ◆ Potřeba definovat spojitě a hladké hranice objektu
 - ◆ Inicializaci provádí uživatel → semi-automatická analýza

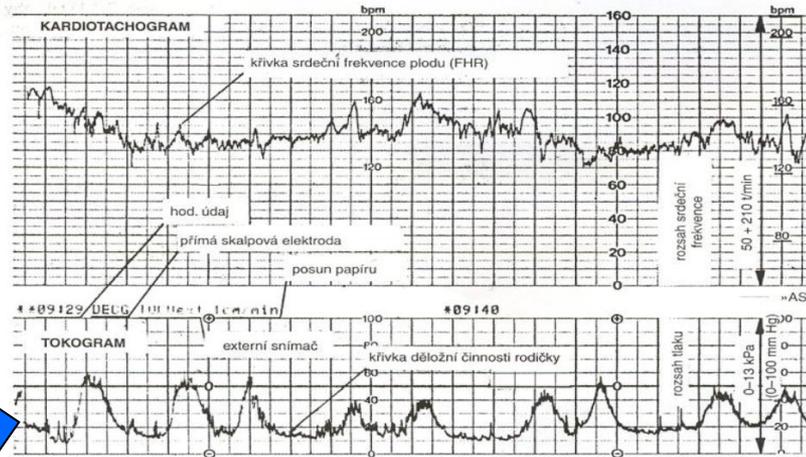
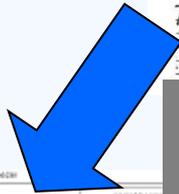
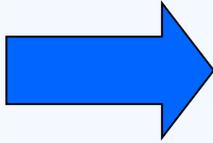


Echokardiografie

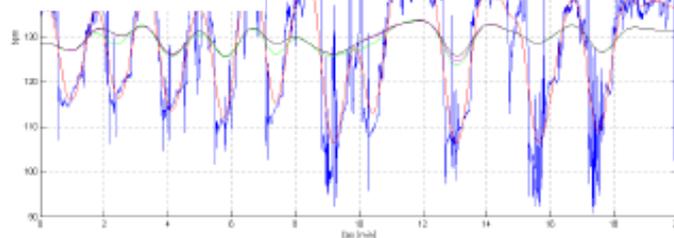
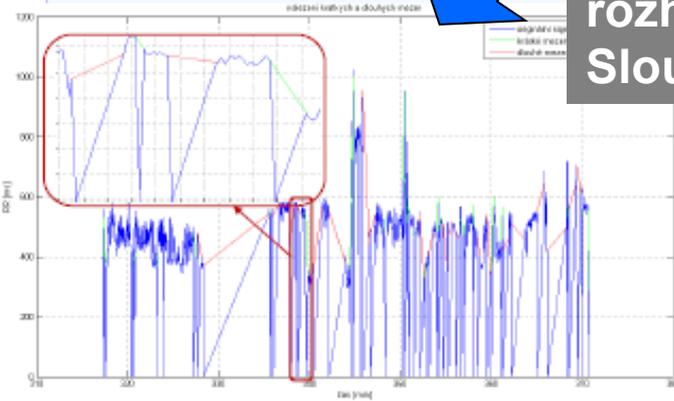
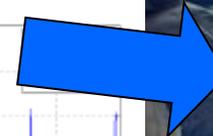
- ❖ Automatické určení výskytu tzv. kouře
- ❖ Není úplně jasná fyziologická podstata toho jevu
 - ◆ Jeho výskyt se ukazuje jako celkem důležitý diagnostický parametr
 - ◆ Velmi obtížné rozlišení výskytu kouře v obraze s vyšším šumem



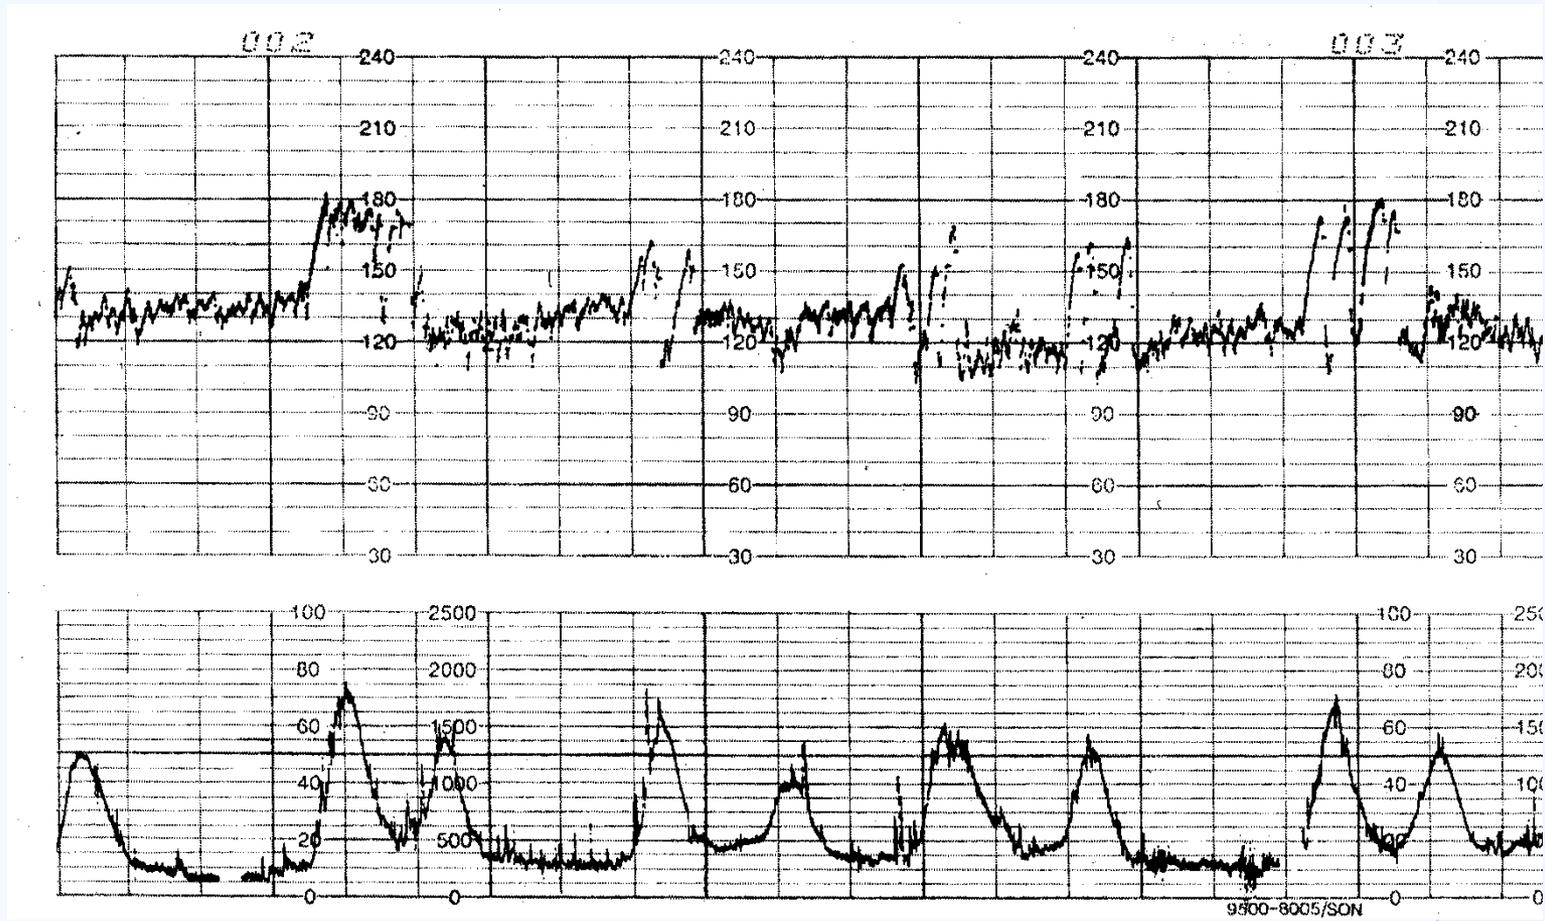
Kardiotokografie



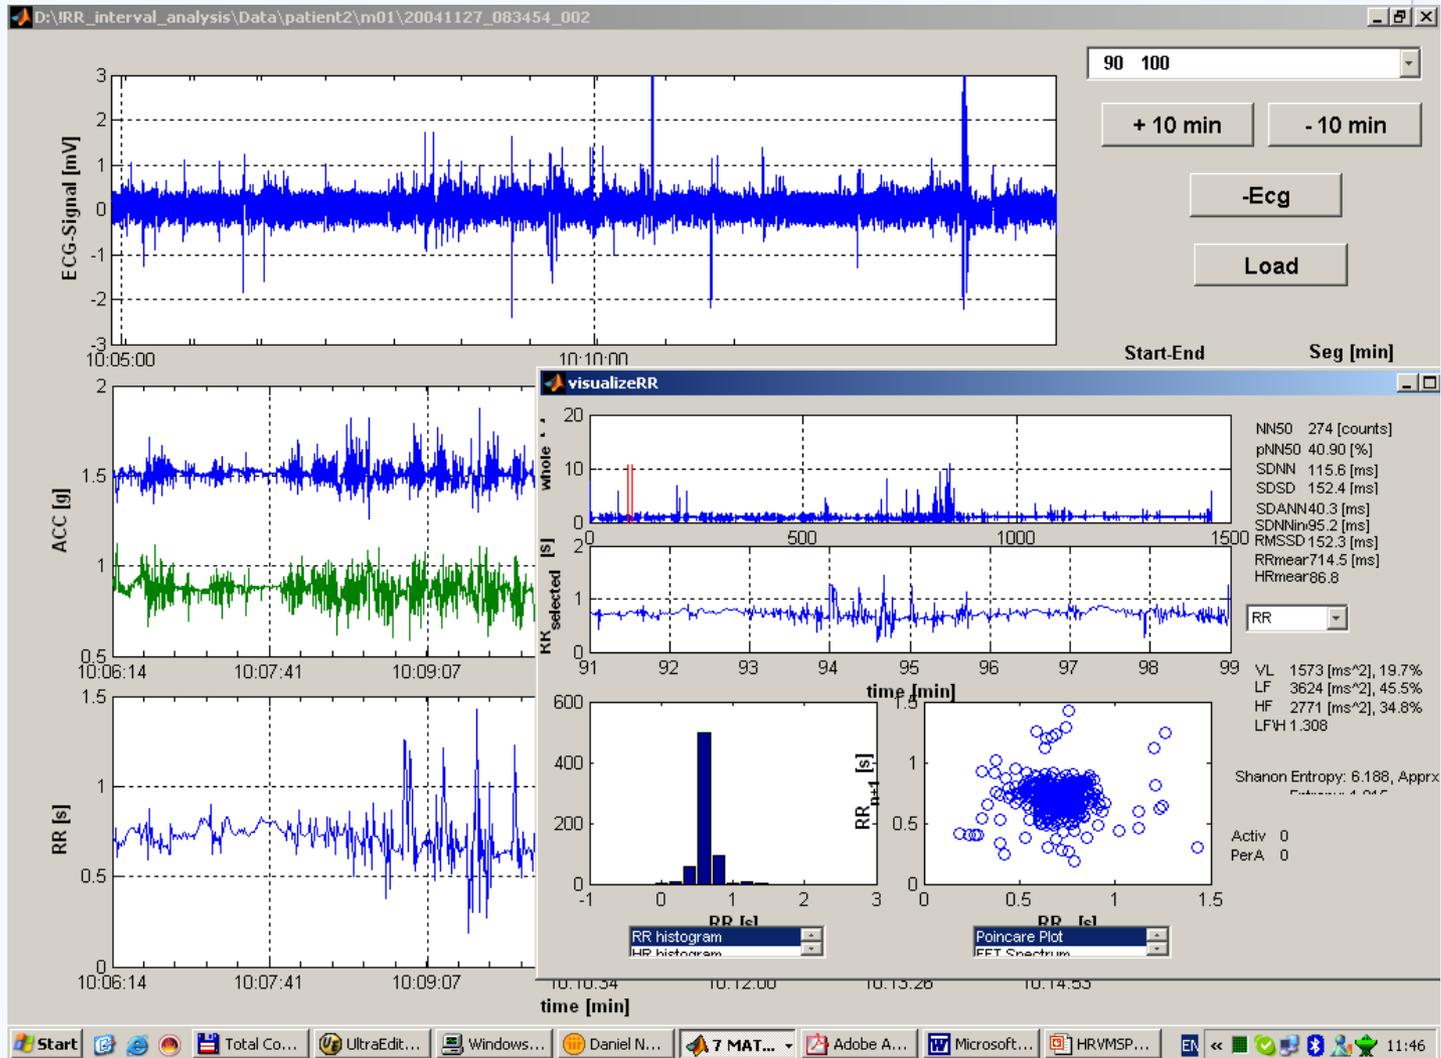
Algoritmy pro systém pro podporu rozhodování v porodnici.
Slouží k detekci hypoxie při porodu.



Kardiotokografie



HRV analýza



Trendy v elektrokardiografii



- ❖ Zaměřeno na prevenci
- ❖ Větší možnosti kontroly pacienta diagnostických nástrojů a jejich výsledků
- ❖ Nová metodika snímání EKG pro – sensory vetkané do oblečení
- ❖ Nové způsoby zpracování signálu na mobilních telefonech a PDAčkách
- ❖ Impulzem pro telemedicínské aplikace jsou rychlejší, levnější a spolehlivější sítě



Trendy v elektrokardiografii (2)



▣ Sensorické tílko



▣ PBM

▣ Základna



GPRS

Bluetooth



▣ Mobilní telefon



Zpracování EKG - PDA



ECG Arrhythmias
▼ Premature Atrial Contraction

Push Buttons explain the arrhythmia

Appears early (may be lost in the T wave). Has a different shape than the other P waves.

General P PRI QRS Rate Rhythm

ECG Arrhythmias
▼ Wandering Pacemaker

Zoom Buttons let you get a closer look

Pacemaker function wanders between sinus node, atria, and AV junction.

ECG Arrhythmias
▼ Normal Sinus Rhythm

Normal PR interval: between 0.12 second and 0.20 second (3 to 5 small boxes) and constant.

25 arrhythmias

ECG Arrhythmias

- Atrial Fibrillation
- Atrial Flutter
- Premature Atrial Contraction
- Wandering Pacemaker
- Junctional Rhythms
- Accelerated Junctional
- Junctional Escape Rhythm
- Junctional Tachycardia
- Premature Junctional Contr.
- Supraventricular Tachy
- Atrioventricular Blocks
- First Degree AV Block

Přehled přednášky

I. Úvod do úvodu - co je to srdce?

II. Srdce z morfologického a funkčního pohledu

III. EKG

IV. Typy měření EKG – principy a přístroje

- Standardní 12ti svodové EKG
- Holter
- Automatický defibrilátor
- Multisvodové EKG (BSPM)
- Echokardiografie
- A-EGM
- Kardiotokografie a HRV
- Telemedicína

V. Nemoci srdce (patoelektrofyzologie) a jejich možná léčba

- Poruchy rytmu
- Infarkt myokardu

VI. Umělé srdce



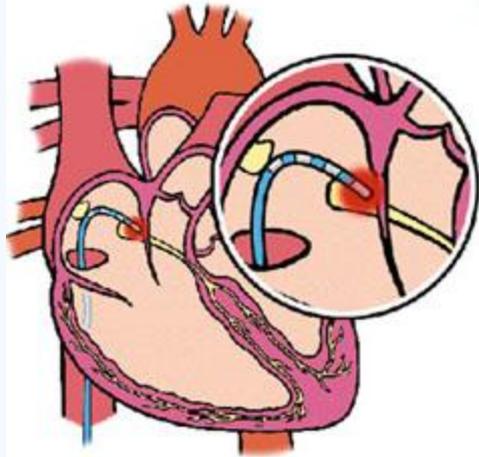
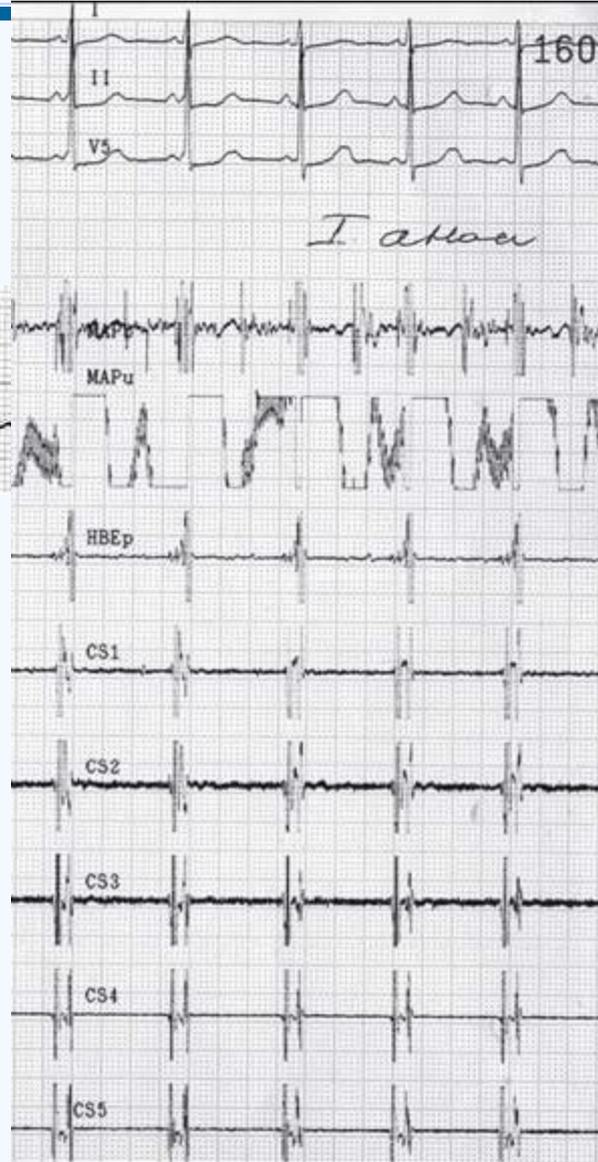
Onemocnění srdce



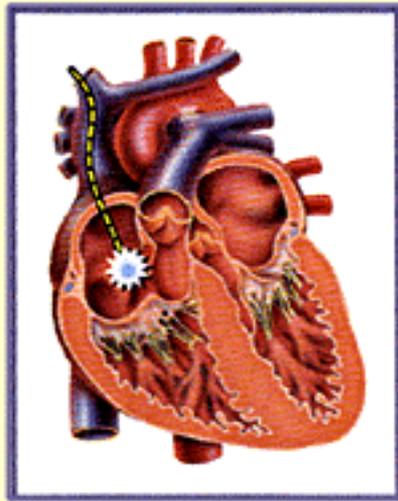
Významné onemocnění srdce:

- ◆ Ischemická choroba srdeční
 - ❖ Angina pectoris
- ◆ Infarkt myokardu
 - ❖ Rychlé odumírání bez přístupu kyslíku(krve)
- ◆ Congestive heart failure Městnavá choroba srdeční
 - ❖ Ztráta síly srdečního svalu
- ◆ Endocarditida and myocarditida
 - ❖ Záněť
- ◆ Srdeční arythmie
 - ❖ Nepravidelnost rytmu
- ◆ Vrozené vady
- ❖ Možné způsoby léčby
 - ◆ By-pass nebo angioplastika
 - ◆ Beta blokátory – snižují srdeční frekvenci a tlak
 - ◆ Nitroglycerin
 - ◆ Transplantace srdce
 - ❖ V roce 1967 v Groote Schuur Hospital v Kapském městě (JAR) bylo Christiaanem Barnardem poprvé implantováno umělé srdce lidskému pacientovi. (přežil 18 dní)

A-fib

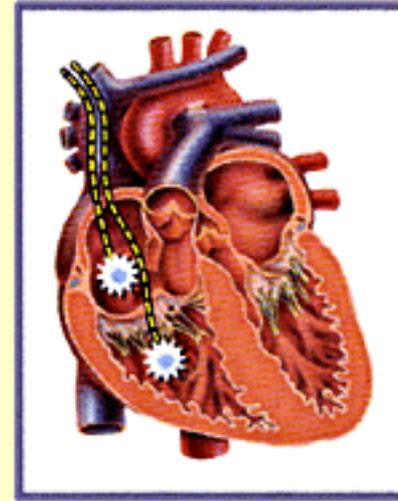
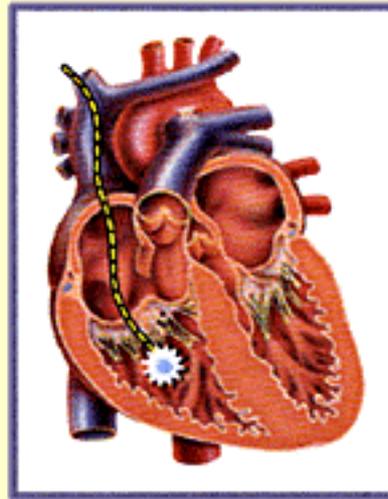


Pacemakery



Atrial Pacing
The pacing lead is inserted into the atrium to cause atrial depolarization.

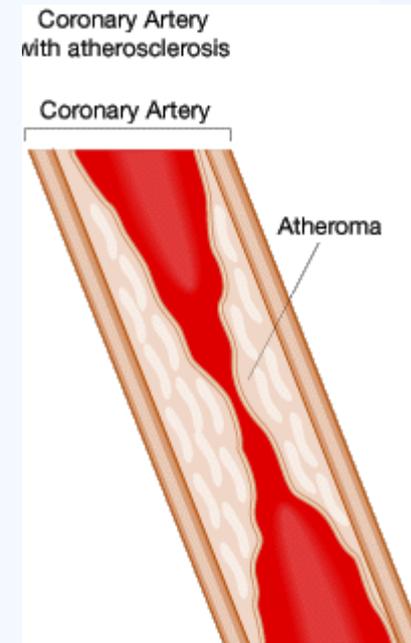
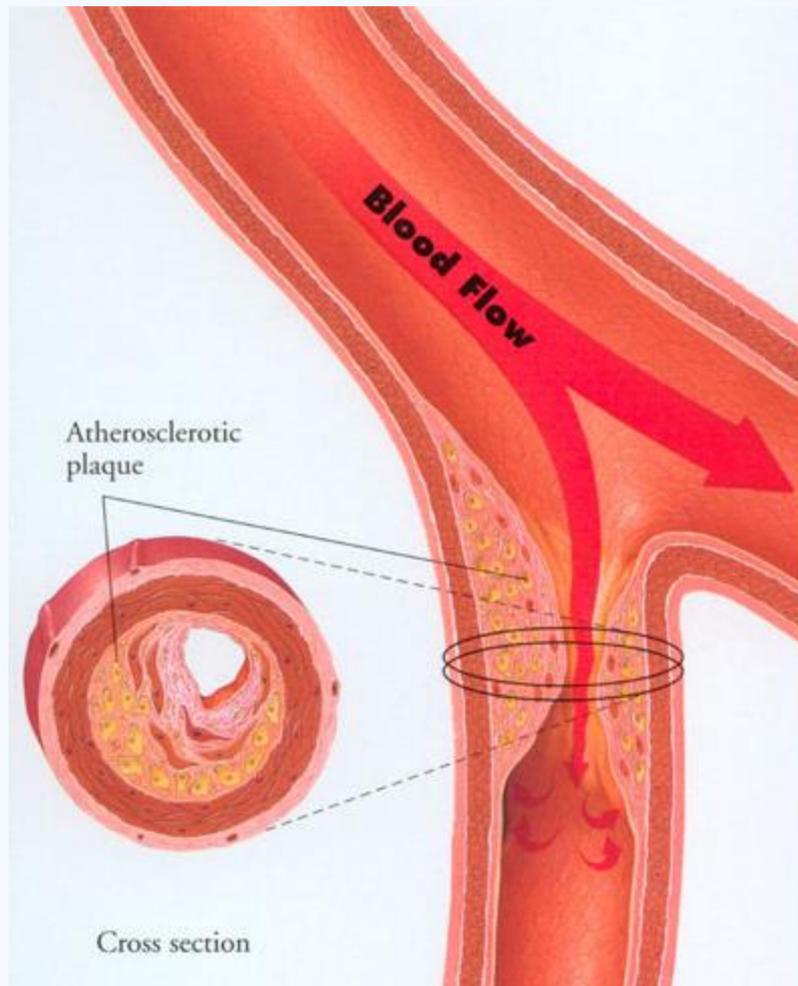
Ventricular Pacing
The pacing lead is inserted into the ventricle to cause ventricular depolarization



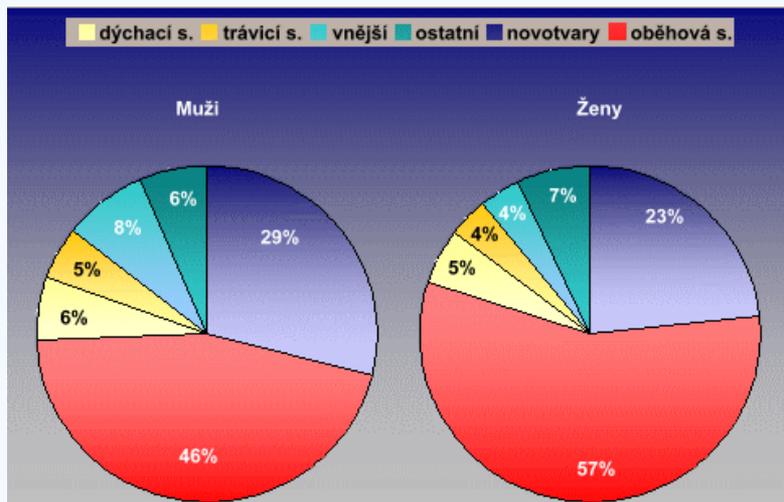
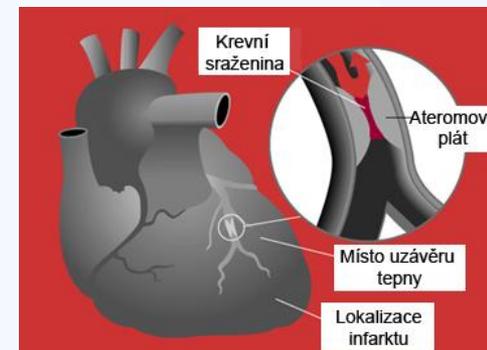
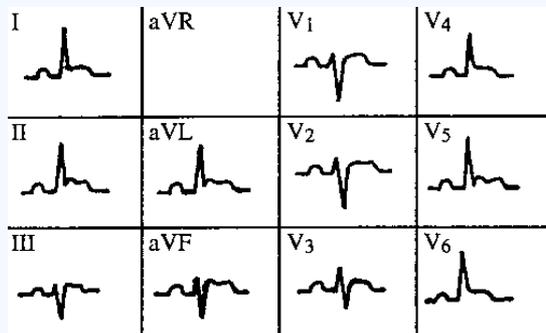
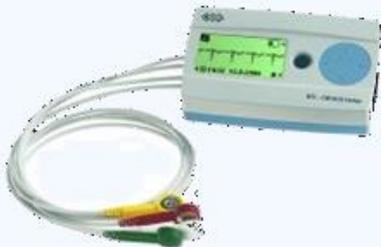
A-V Sequential Pacing
The pacing leads are inserted into both the atrium and ventricle stimulating at set intervals.

Pacemaker Lead Wire Replacement

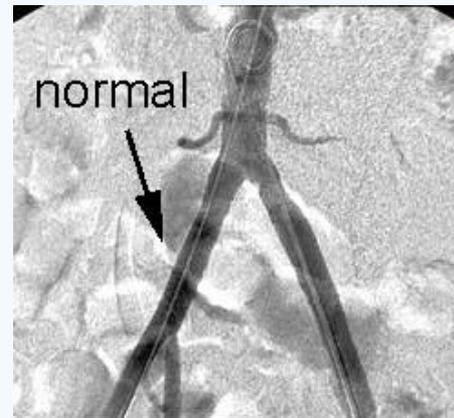
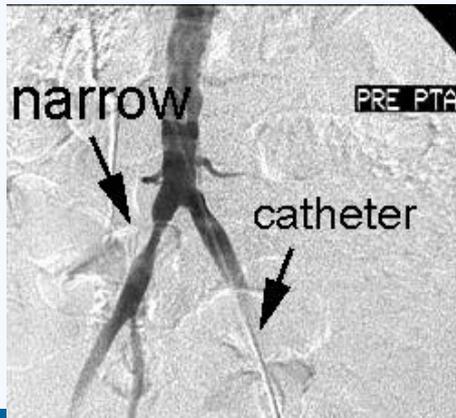
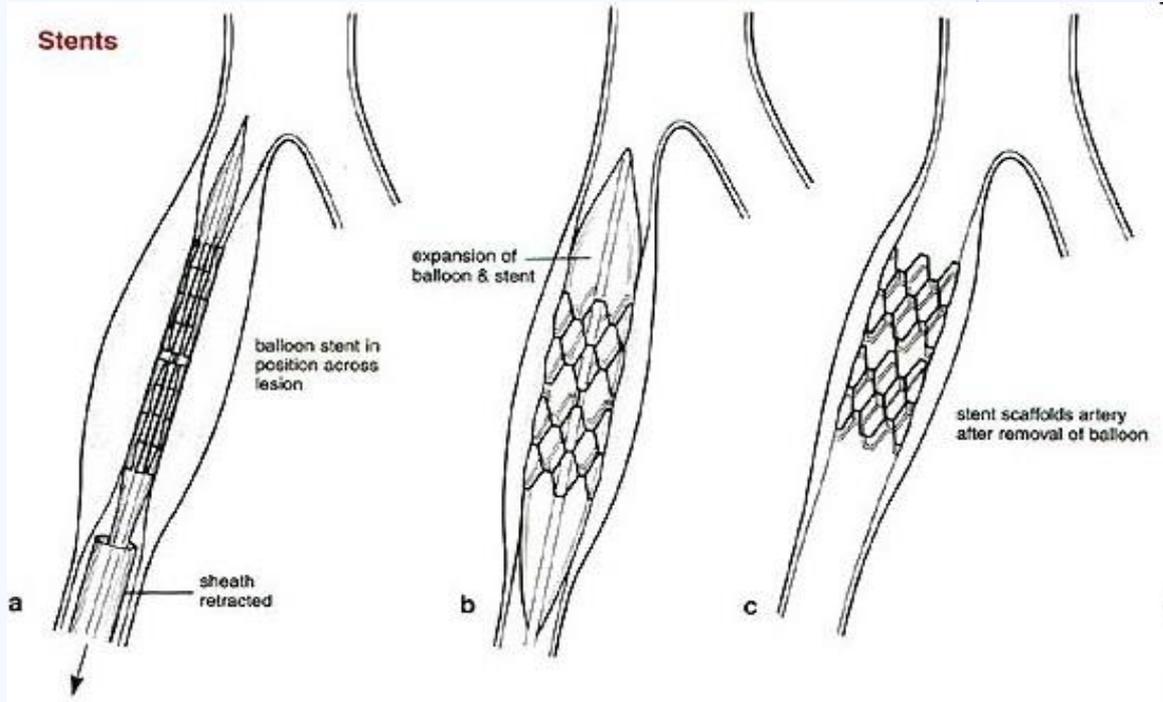
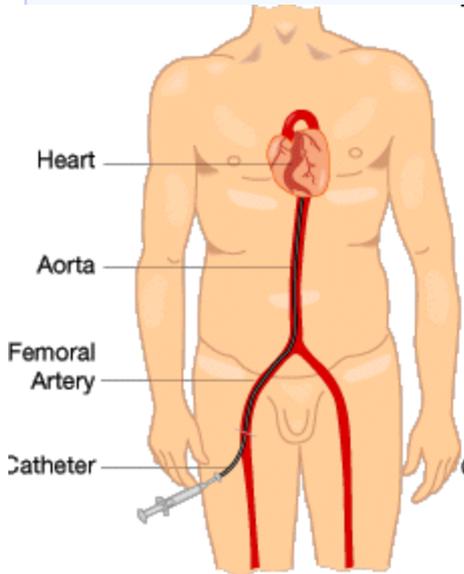
Okluze koronárních arterií



Infarkt myokardu



Stenty





Přehled přednášky



I. Úvod do úvodu - co je to srdce?

II. Srdce z morfologického a funkčního pohledu

III. EKG

IV. Typy měření EKG – principy a přístroje

V. Nemoci srdce (patoelektrofyzologie) a jejich léčba

- Poruchy rytmu
- Infarkt myokardu

VI. Umělé srdce



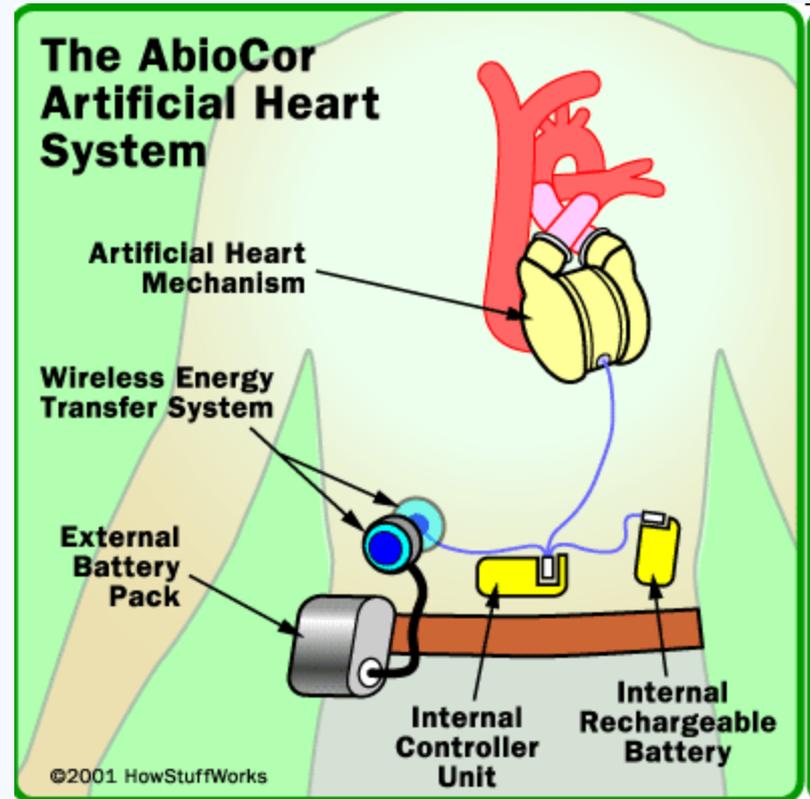
Umělé srdce



- ❖ Umělé srdce AbioCor, které je složeno z titanu a plastiku má vpustě do čtyř částí:
- ❖ Pravá síň
- ❖ Levá síň
- ❖ Aorta
- ❖ Plicnice

Celý systém AbioCor váží 0.9 kg

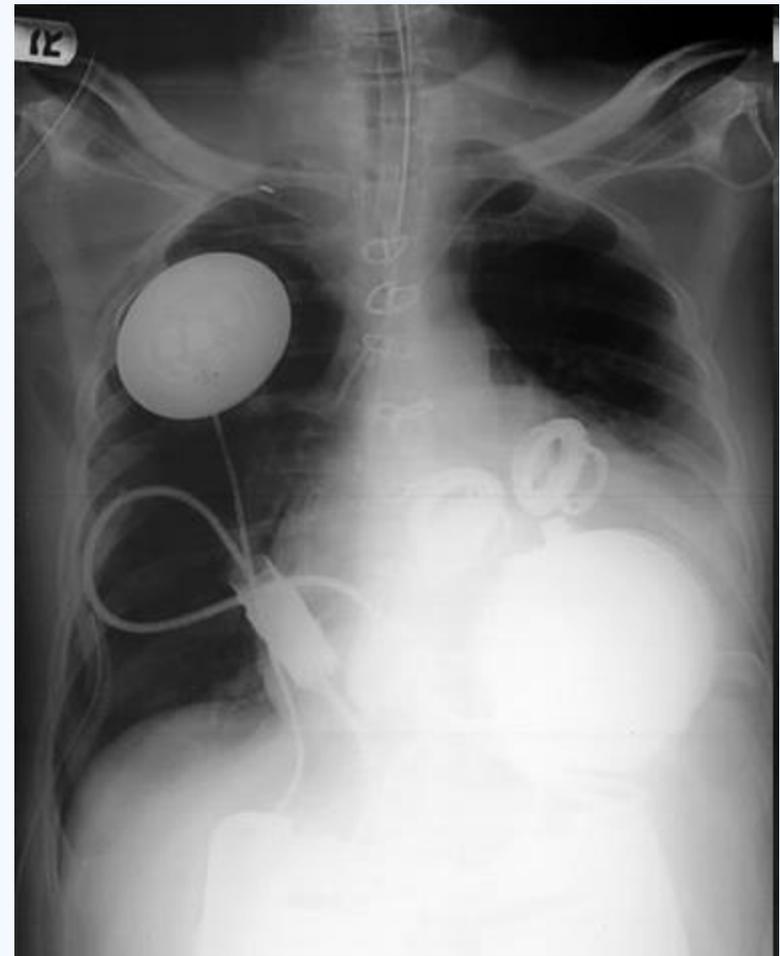
Umělé srdce (2)



Umělé srdce (3)



❖ Surgeons implanted the AbioCor heart during a seven-hour operation.



Umělé srdce – info od výrobce



❖ The AbioCor, developed by Abiomed, is a very sophisticated medical device, but the core mechanism of the device is the hydraulic pump that shuttles hydraulic fluid from side to side.

- ◆ Hydraulic pump - The basic idea with this device is similar to the hydraulic pumps used in heavy equipment. Force that is applied at one point is transmitted to another point using an incompressible fluid. A gear inside the pump spins at 10,000 revolutions per minute (rpm) to create pressure.
- ◆ Porting valve - This valve opens and closes to let the hydraulic fluid flow from one side of the artificial heart to the other. When the fluid moves to the right, blood gets pumped to the lungs through an artificial ventricle. When the fluid moves to the left, blood gets pumped to the rest of the body.
- ◆ Wireless energy-transfer system - Also called the Transcutaneous Energy Transfer (TET), this system consists of two coils, one internal and one external, that transmit power via magnetic force from an external battery across the skin without piercing the surface. The internal coil receives the power and sends it to the internal battery and controller device.
- ◆ Internal battery - A rechargeable battery is implanted inside the patient's abdomen. This gives a patient 30 to 40 minutes to perform certain activities, such as showering, while disconnected from the main battery pack.
- ◆ External battery - This battery is worn on a Velcro-belt pack around the patient's waist. Each rechargeable battery offers about four to five hours of power.
- ◆ Controller - This small electronic device is implanted in the patient's abdominal wall. It monitors and controls the pumping speed of the heart.

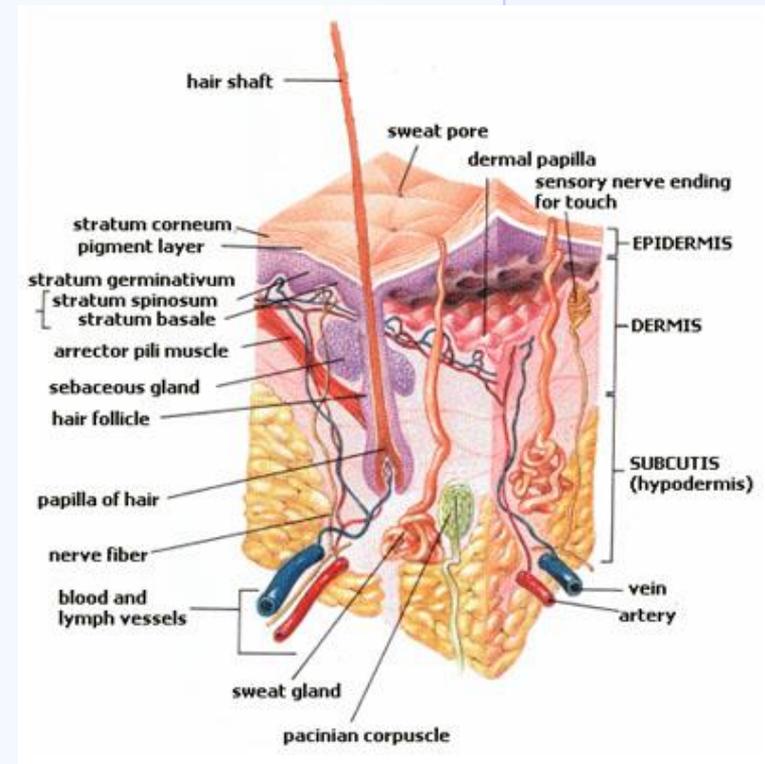


Photo-pletysmo-graphy (PPG)

Pulse Oximeters

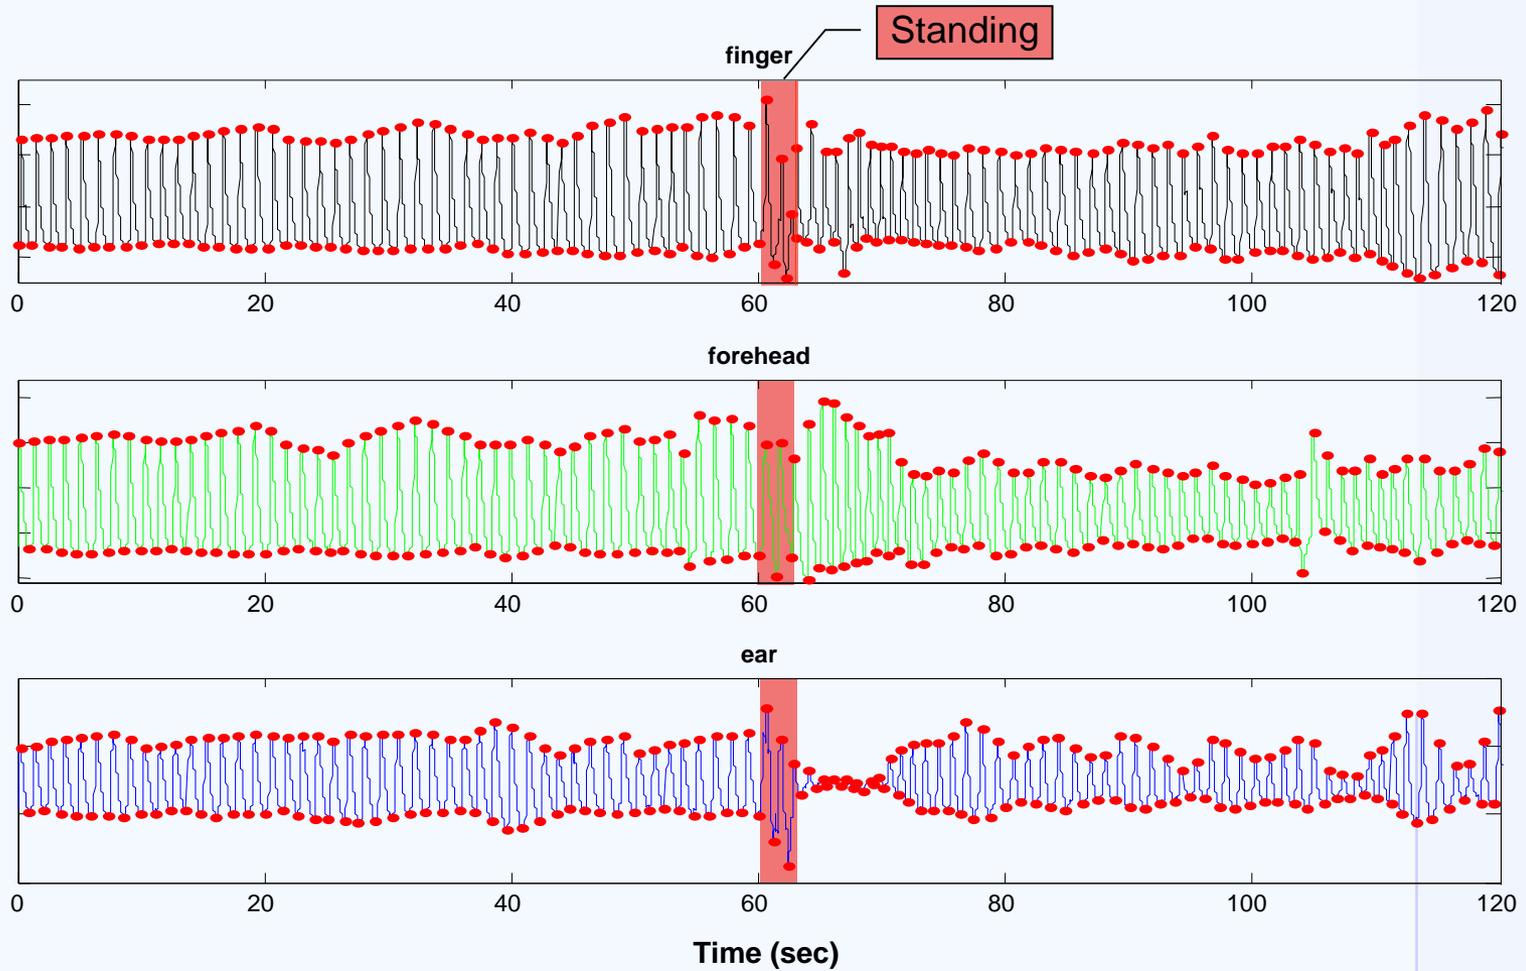


❖ The pulse oximeter uses changes in reflected or transmitted light to infer volumetric changes



- The resulting photoplethysmogram (PPG) gives the temporal variation in blood volume of peripheral tissue

Photoplethysmogram



Lower-body negative pressure (LBNP)

- ❖ Induces hypovolemia by sequestering blood in the hips and lower extremities
- ❖ Sequesters between 2 and 3 liters of blood at -90 mm Hg

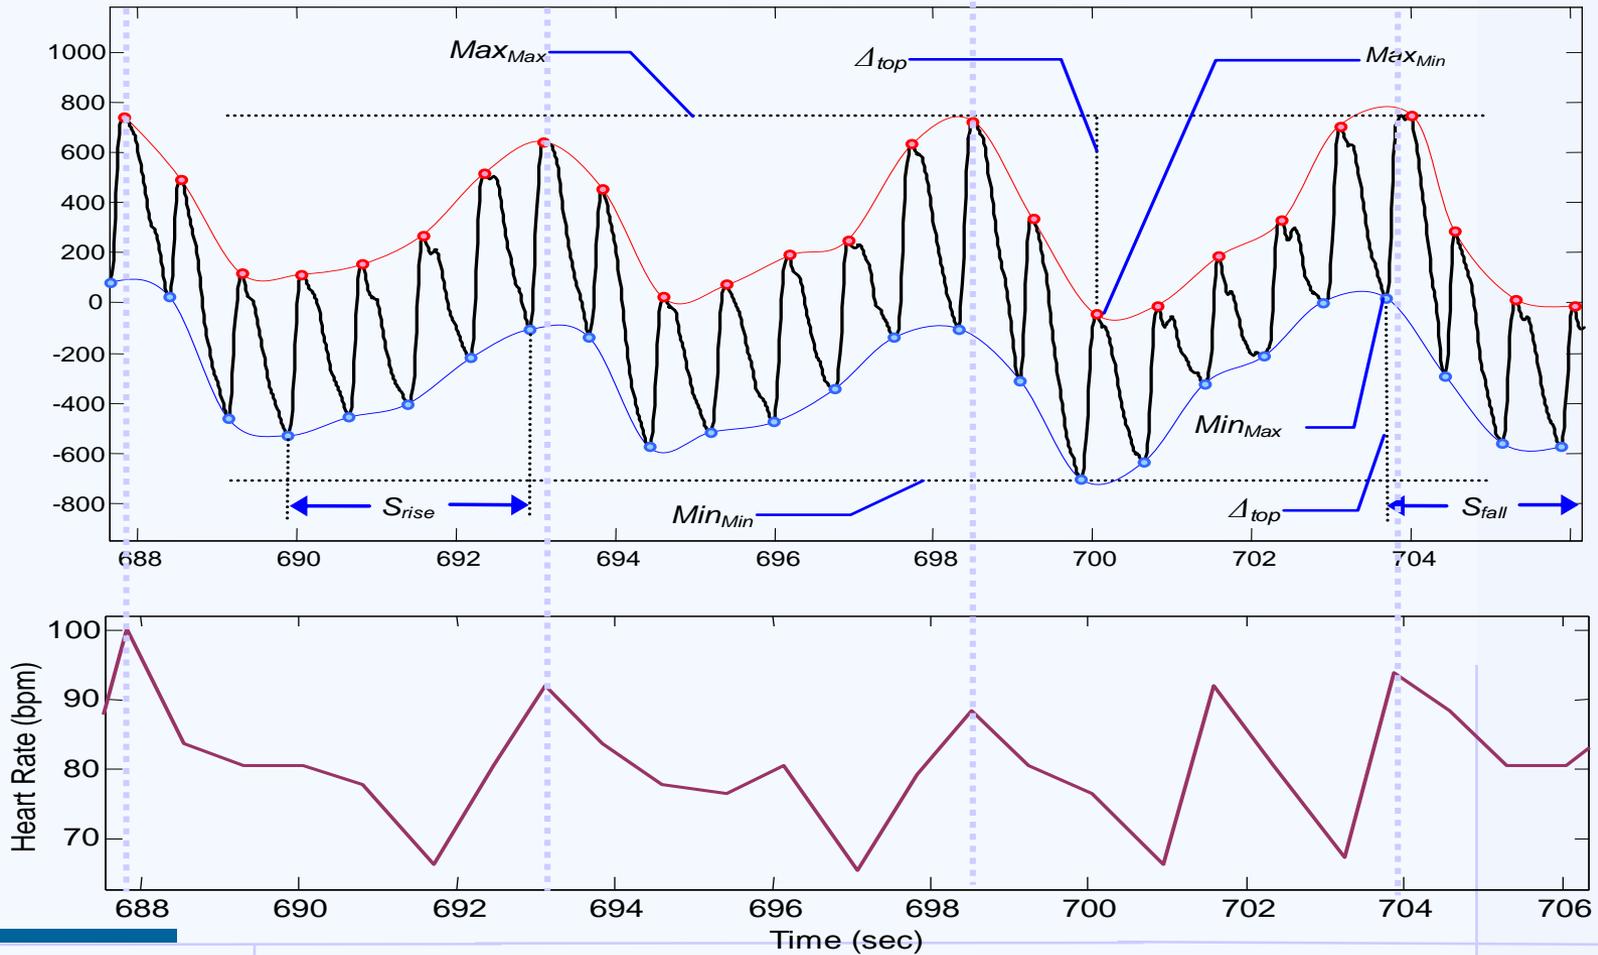


Work done with Victor Convertino and Gary Muniz at the Institute of Surgical Research, Brooks Army Medical Center

Respiratory-Induced Variation with LBNP of 80



mmHg





Děkuji za pozornost!