



ANALÝZA A KLASIFIKACE DAT



prof. Ing. Jiří Holčík, CSc.




INVESTICE DO ROZVOJE VZDĚLÁVÁNÍ



ANALÝZA NEZÁVISLÝCH KOMPONENT



ANALÝZA NEZÁVISLÝCH KOMPONENT PRINCIP METODY




$$x_1(t) = a_{11} \cdot s_1(t) + a_{12} \cdot s_2(t)$$

$$x_2(t) = a_{21} \cdot s_1(t) + a_{22} \cdot s_2(t)$$

Úloha spočívá v nalezení originálních neznámých signálů z jednotlivých zdrojů $s_1(t)$ a $s_2(t)$ máme-li k dispozici pouze zaznamenané signály $x_1(t)$ a $x_2(t)$.

ANALÝZA NEZÁVISLÝCH KOMPONENT PRINCIP METODY



ICA umožňuje určit koeficienty a_{ij} za předpokladu, že známé signály jsou dány lineárních kombinací zdrojových a za předpokladu statistické nezávislosti zdrojů v každém čase t .

ANALÝZA NEZÁVISLÝCH KOMPONENT

MODEL DAT

- ☑ necht' $\mathbf{x} = T(x_1, x_2, \dots, x_m)$ je m -rozměrný náhodný vektor (s nulovou střední hodnotou $E(\mathbf{x})=0$).

$$x_i = a_{i1}^{\text{orig}} \cdot s_1^{\text{orig}} + a_{i2}^{\text{orig}} \cdot s_2^{\text{orig}} + \dots + a_{im}^{\text{orig}} \cdot s_m^{\text{orig}} \\ i = 1, 2, \dots, m$$

nebo

$$\mathbf{x} = \mathbf{A}^{\text{orig}} \cdot \mathbf{s}^{\text{orig}}$$

\mathbf{s}^{orig} je vektor originálních skrytých nezávislých komponent a s_1^{orig} jsou nezávislé komponenty (předpoklad vzájemně statisticky nezávislosti);

\mathbf{A}^{orig} je transformační matice

ANALÝZA NEZÁVISLÝCH KOMPONENT MODEL DAT

☑ definice

$$\mathbf{s} = \mathbf{W} \cdot \mathbf{x},$$

☑ cíl:

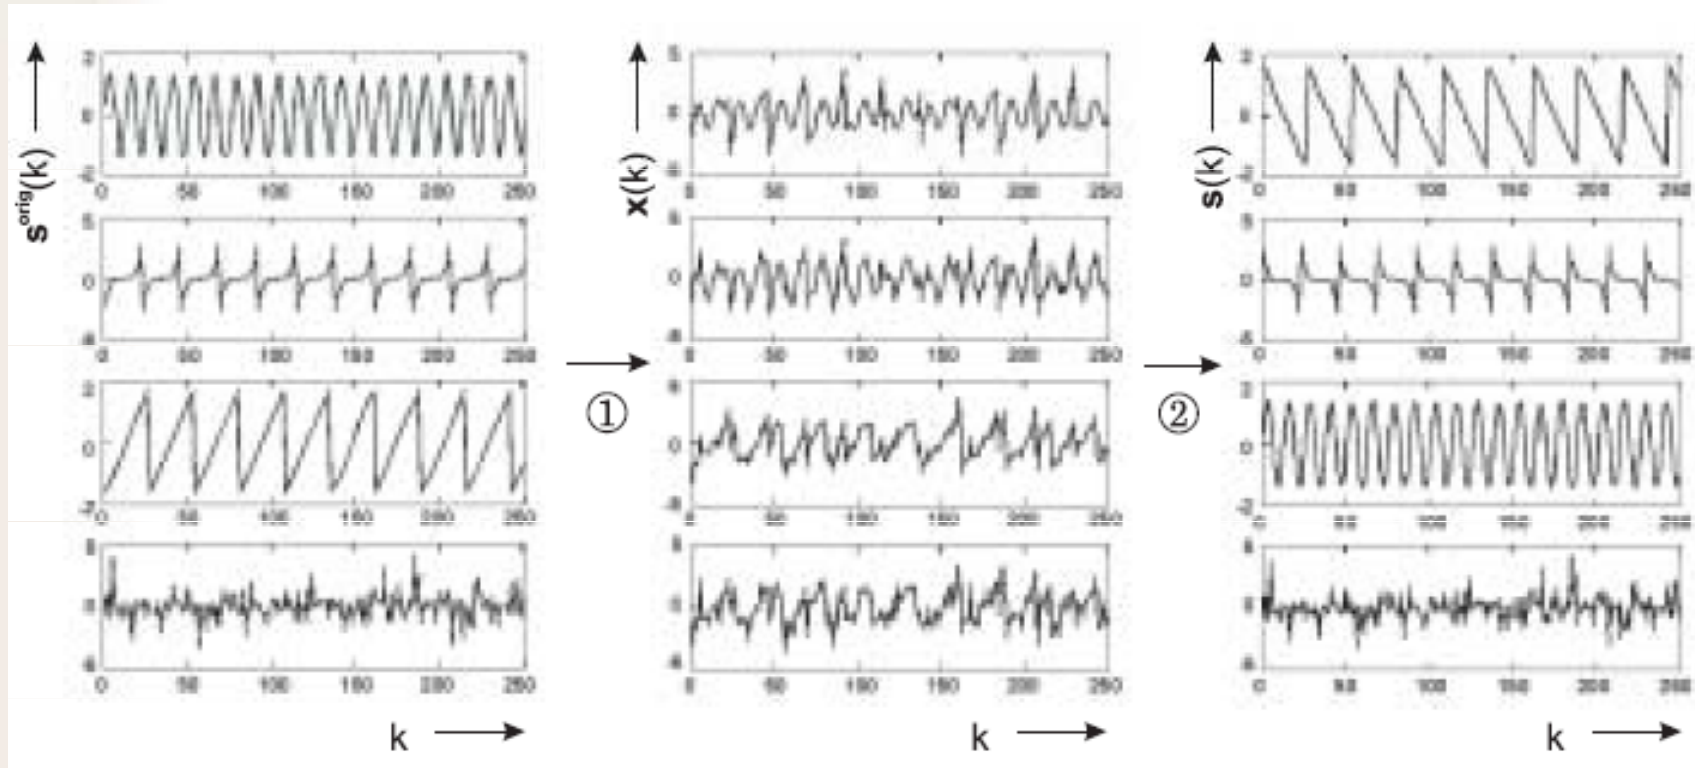
nalézt lineární transformaci (koeficienty transformační matice \mathbf{W} tak, aby vypočítané nezávislé komponenty s_i byly vzájemně statisticky nezávislé [$\mathbf{W} = \mathbf{A}^{-1}$]

$$[p(s_1, s_2, \dots, s_m) = p_1(s_1) \cdot p_2(s_2) \dots p_m(s_m)]$$

ANALÝZA NEZÁVISLÝCH KOMPONENT OMEZENÍ

- ☑ pouze jedna originální nezávislá komponenta může mít normální rozložení pravděpodobnosti (pokud má více zdrojů normální rozložení není ICA schopna tyto zdroje ze vstupních dat extrahovat);
- ☑ pro dané m -rozměrné obrazové vektory je ICA schopna najít pouze m nezávislých komponent;
- ☑ nelze obecně určit polaritu nezávislých komponent;
- ☑ nelze určit pořadí nezávislých komponent (?!)

ANALÝZA NEZÁVISLÝCH KOMPONENT OMEZENÍ



ODHAD NEZÁVISLÝCH KOMPONENT

- ☑ optimalizace pomocí zvolené optimalizační (účelové, kriteriální, objektové) funkce



a) nalézt kriteriální funkci

b) vybrat optimalizační algoritmus

ad a) možnost ovlivnit statistické vlastnosti metody;

ad b) spojená optimalizační úloha s „rozumnou“ kriteriální funkcí – gradientní metoda, Newtonova metoda – ovlivňujeme rychlost výpočtu (konvergenci), nároky na paměť,...

ODHAD NEZÁVISLÝCH KOMPONENT

ZÁKLADNÍ ÚVAHA

- ☑ nechť existuje m nezávislých náhodných veličin s určitými pravděpodobnostními rozděleními (jejich součet za dosti obecných podmínek konverguje s rostoucím počtem sčítanců k normálnímu rozdělení – **centrální limitní věta**);
- ☑ o vektoru \mathbf{x} (který máme k dispozici) předpokládáme, že vznikl součtem nezávislých komponent \mathbf{s}^{orig}



jednotlivé náhodné veličiny x_i mají pravděpodobnostní rozdělení, které je „bližší“ normálnímu než rozdělení jednotlivých komponent s_i^{orig}

ODHAD NEZÁVISLÝCH KOMPONENT

ZÁKLADNÍ ÚVAHA

- ☑ odhad nezávislých komponent si probíhá tak, že hledáme takové řádkové vektory \mathbf{w}_i transformační matice \mathbf{W} , aby pravděpodobnostní rozdělení součinu $\mathbf{w}_i \cdot \mathbf{x}$ bylo „co nejvíce **nenormální**“



tj. nalézt takovou transformační matici \mathbf{W} , aby proměnné $\mathbf{w}_i \cdot \mathbf{x}$ měly pravděpodobnostní rozdělení, které se co nejvíce liší od normálního



potřeba nalézt míru náhodné veličiny, která by mohla být použita pro kvantifikaci míry (podobnost, vzdálenost) nenormality

ODHAD NEZÁVISLÝCH KOMPONENT POUŽÍVANÉ MÍRY NENORMALITY

- ☑ koeficient špičatosti
- ☑ negativní normalizovaná entropie;
- ☑ aproximace negativní normalizované entropie;

ODHAD NEZÁVISLÝCH KOMPONENT KOEFCIENT ŠPIČATOSTI

$$\text{kurt}(s) = E\{s^4\} - 3(E\{s^2\})^2$$

Gaussovo rozložení má koeficient špičatosti roven nule, zatímco pro jiná rozložení (ne pro všechna) je koeficient nenulový.

Při hledání nezávislých komponent hledáme extrém, resp. kvadrát koeficientu špičatosti veličiny $\mathbf{s} = \mathbf{w}_i \cdot \mathbf{x}$

ODHAD NEZÁVISLÝCH KOMPONENT KOEFIČIENT ŠPIČATOSTI

výhody:

- ✓ rychlost a relativně jednoduchá implementace;

nevýhody:

- ✓ malá robustnost vůči odlehlým hodnotám (pokud v průběhu měření získáme několik hodnot, které se liší od skutečných, výrazně se změní KŠ a tím i nezávislé komponenty nebudou odhadnut korektně);
- ✓ existence náhodných veličin s nulovým KŠ, ale nenormálním rozdělením;

ODHAD NEZÁVISLÝCH KOMPONENT NEGATIVNÍ NORMALIZOVANÁ ENTROPIE

(NNE, negentropy)

Informační entropie - množství informace
náhodné veličiny

☑ pro diskrétní náhodnou veličinu s je

$$H(s) = -\sum_i P(s=a_i) \cdot \log_2 P(s=a_i),$$

kde $P(s=a_i)$ je pravděpodobnost, že náhodná veličina S je rovna hodnotě a_i .

☑ pro spojitou proměnnou platí

$$H(s) = - \int_{-\infty}^{\infty} p(s) \log_2 p(s) ds$$

ODHAD NEZÁVISLÝCH KOMPONENT NEGATIVNÍ NORMALIZOVANÁ ENTROPIE

- ☑ entropie je tím větší, čím jsou hodnoty náhodné veličiny méně predikovatelné;
- ☑ pro normální rozdělení má entropie největší hodnotu ve srovnání v dalšími rozděleními

NNE

$$J(s) = H(s_{\text{gauss}}) - H(s),$$

kde s_{gauss} je náhodná veličiny s normálním rozdělením

ODHAD NEZÁVISLÝCH KOMPONENT NEGATIVNÍ NORMALIZOVANÁ ENTROPIE

výhody:

- ☑ přesné vyjádření nenormality;
- ☑ dobrá robustnost vůči odlehlým hodnotám;

nevýhody:

- ☑ časově náročný výpočet \Rightarrow snaha o vhodnou aproximaci NNE aby byly zachovány její výhody a současně byl výpočet nenáročný

ODHAD NEZÁVISLÝCH KOMPONENT APROXIMACE NEGATIVNÍ NORMALIZOVANÉ ENTROPIE

- ☑ použití momentů vyšších řádů

$$J(s) \approx \frac{1}{12} E\{s^3\}^2 + \frac{1}{48} \text{kurt}(s)^2$$

kde s je náhodná veličina s nulovou střední hodnotou a jednotkovým rozptylem

nevýhoda:

- ☑ opět menší robustnost vůči odlehlým hodnotám

ODHAD NEZÁVISLÝCH KOMPONENT

APROXIMACE NEGATIVNÍ NORMALIZOVANÉ ENTROPIE

- ☑ Použití tzv. p-nekvadratických funkcí

$$J(\mathbf{s}) \approx \sum_{i=1}^p k_i \cdot [\mathcal{E}\{G_i(\mathbf{s})\} - \mathcal{E}\{G_i(\mathbf{s}_{\text{gauss}})\}]^2$$

kde $k_i > 0$ je konstanta, G_i jsou šikovně navržené nelineární funkce a $\mathbf{s}_{\text{gauss}}$ je normální náhodná proměnná, která spolu s \mathbf{s} má nulovou střední hodnotu a jednotkový rozptyl.

Je-li použita pouze jedna funkce G , pak je

$$J(\mathbf{s}) \approx [\mathcal{E}\{G(\mathbf{s})\} - \mathcal{E}\{G(\mathbf{s}_{\text{gauss}})\}]^2$$

ODHAD NEZÁVISLÝCH KOMPONENT

APROXIMACE NEGATIVNÍ NORMALIZOVANÉ ENTROPIE


☑ doporučujeme:

$$G_1(s) \approx \frac{1}{a_1} \log(\cosh a_1 s)$$


kde $a_1 \in \langle 1, 2 \rangle$ nebo

$$G_2(s) \approx -\exp(-s^2 / 2)$$

ODHAD NEZÁVISLÝCH KOMPONENT PŘÍKLAD POUŽITÍ




ODHAD NEZÁVISLÝCH KOMPONENT PŘÍKLAD POUŽITÍ

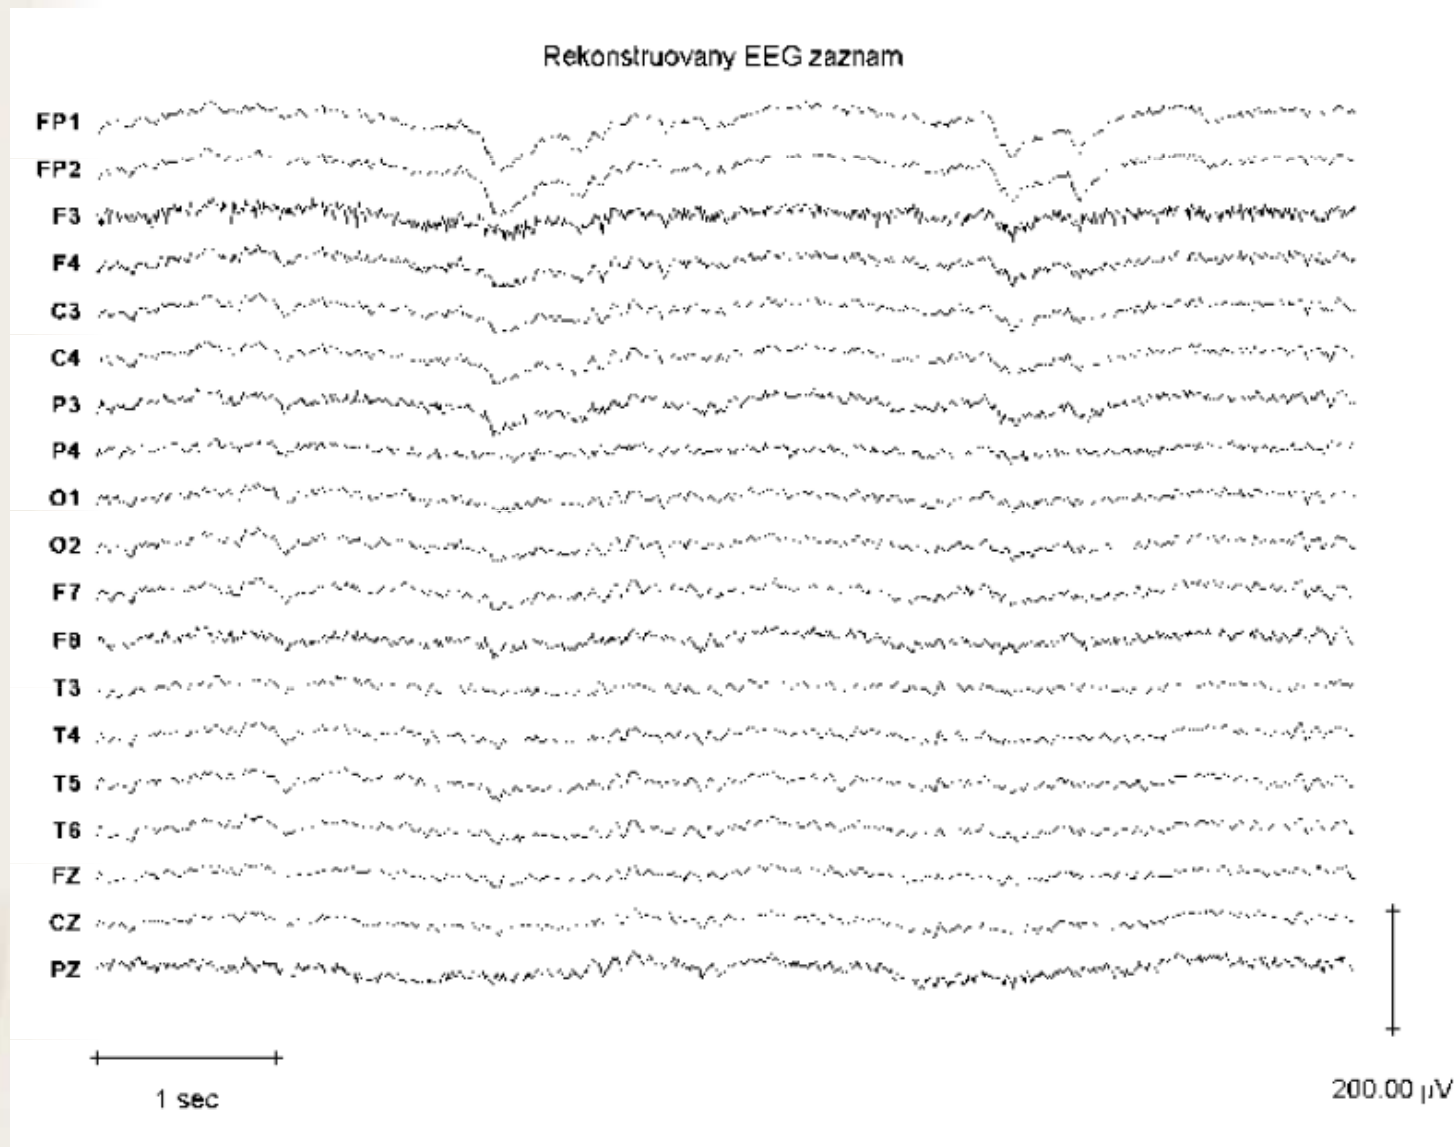


ODHAD NEZÁVISLÝCH KOMPONENT PŘÍKLAD POUŽITÍ

Nezávisle komponenty (IC4 a IC11 byly odstraněny)




ODHAD NEZÁVISLÝCH KOMPONENT PŘÍKLAD POUŽITÍ




ODHAD NEZÁVISLÝCH KOMPONENT PŘÍKLAD POUŽITÍ

Původní EEG záznam



Rekonstruovaný EEG záznam



Příprava nových učebních materiálů
oboru Matematická biologie

je podporována projektem ESF

č. CZ.1.07/2.2.00/07.0318

„VÍCEBOROVÁ INOVACE STUDIA MATEMATICKÉ BIOLOGIE“



INVESTICE DO ROZVOJE VZDĚLÁVÁNÍ