



Kvantifikovanie kauzálnych vzťahov v distribuovanom systéme

Úvod k téme diplomovej práce

Bc. Anton Vančo

vedúci: doc. Ing. Igor Farkaš, PhD.

obsah

- kauzalita v komplexných sústavách
- formy analýzy časových radov
- metóda Grangerovej kauzality
 - jednorozmerné dáta (univariate)
 - viacrozmerné dáta (multivariate)
- ukážka analýzy – GCCA toolbox

kauzalita

- vplyv jedného prvku systému na iný
- (ne)činnosť jedného elementu priamo podmieňuje činnosť druhého
- *intra-level kauzalita*
- *inter-level kauzalita* - top-down, bottom-up

formy analýzy

- identifikácia *orientovanej* funkčnej konektivity
- analýza fMRI, EEG, MEG údajov
- 3 perspektívy:
 - efektívna konektivita
 - funkčná konektivita
 - kauzálna konektivita

kauzálna konektivita

- nutne nemodeluje fyziologické vlastnosti
- pokus o identifikáciu *dynamických vzorov* a vzt'ahov
- 3 dôvody:
 - *same brain, different task*
 - *don't tell me everything ... just the important stuff*
 - *they keep messing up my neural connections!*

meranie zložitosti

- kvantifikovanie správania sa distribuovaného systému
- 3 miery:
 - *neurálna komplexnosť* – segregácia vs. integrácia
 - *integrácia informácií* – podobná NK, sleduje orientované kauzálne interakcie – *effective information*
 - *kauzálna hustota* – zachytáva kauzálne vzťahy naprieč celým systémom

Grangerova kauzalita

- premenná Y je kauzálna (*Granger-causes*) na premennú X , ak sa predpoveď hodnôt X (pomocou jej minulých hodnôt) zlepší zakomponovaním minulých hodnôt Y .
- zlepšenie = štatisticky signifikantné informácie v Y
- autoregresné modely – OLS, Yule-Walker

- pôvodný model

$$X_t = A \cdot \mathbf{X}_{t-1}^{(m)} + \varepsilon_t$$

- rozšírený model

$$X_t = A' \cdot (\mathbf{X}_{t-1}^{(m)} \oplus \mathbf{Y}_{t-1}^{(m)}) + \varepsilon'_t$$

- zlepšenie, ak rozptyl ε' je signifikantne menší ako ε

$$\mathcal{F}_{Y \rightarrow X} = \ln \frac{\text{var}(\varepsilon_t)}{\text{var}(\varepsilon'_t)}$$

Grangerova kauzalita

- *podmienená kauzalita* – prítomnosť tretej premennej

- $$X_t = A \cdot \left(X_{t-1}^{(m)} \oplus Z_{t-1}^{(m)} \right) + \varepsilon_t$$

$$X_t = A' \cdot \left(X_{t-1}^{(m)} \oplus Y_{t-1}^{(m)} \oplus Z_{t-1}^{(m)} \right) + \varepsilon'_t$$

- opäť porovnanie rozptylu – **Geweke (1982)**

$$\mathcal{F}_{Y \rightarrow X|Z} = \ln \frac{\text{var}(\varepsilon_t)}{\text{var}(\varepsilon'_t)}$$

- potenciálne *top-down* kauzalita

Grangerova kauzalita

- **jednorozmerné dáta**
 - pomer rozptylov reziduálnych hodnôt
- **viacrozmerné dáta**
 - *trace* (stopa) kovariačnej matice residuálov
 - determinant kovariačnej matice residuálov, Gewekeho metóda
 - *bottom-up* kauzalita

kauzálna hustota

- miera kauzálne signifikantných vzťahov v systéme
- *normalizovaná* – hodnoty v $[0, 1]$

$$C_d(X) = \frac{\alpha}{N(N-1)}$$

- *nenormalizovaná (váhovaná)* – hodnoty v celom R

$$C_{dw}(X) = \frac{1}{N(N-1)} \sum_{i=1}^N \sum_{j=1}^N \mathcal{F}_{j \rightarrow i}$$


- vysoké hodnoty znamenajú globálnu koordinovanosť prvkov a zároveň ich dynamickú odlišnosť

d'alsie pojmy

- *causal flow* – rozdiel medzi počtom vstupných a výstupných interakcií na danom prvku
 - causal source – zdroj, vysoký *flow*
 - causal sink – záporný *flow*
- *causal hub* – prvok s veľkou kauzálnou hustotou

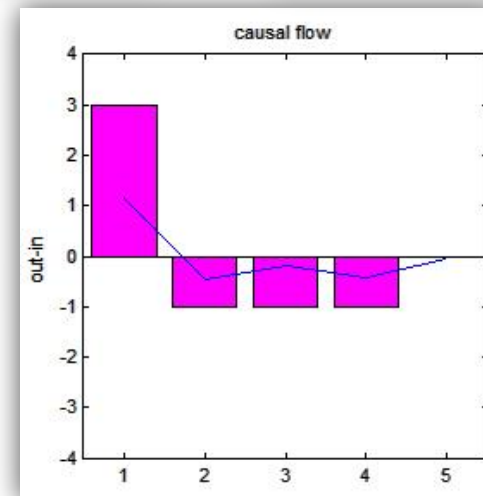
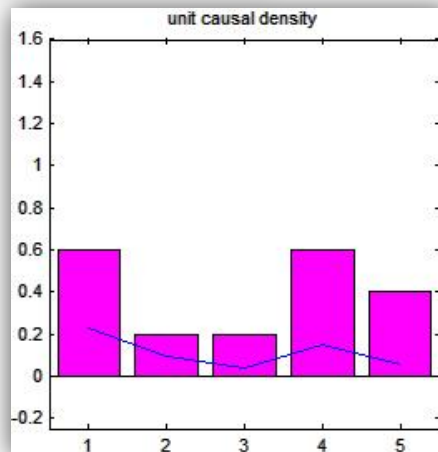

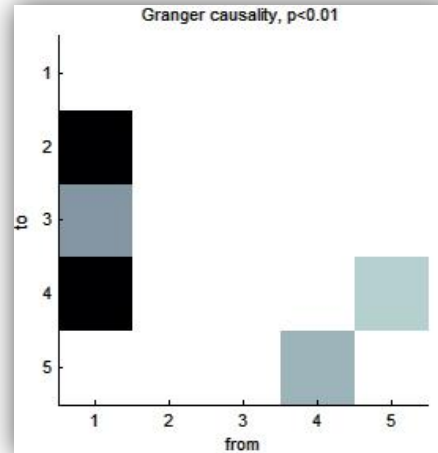

ukážka analýzy

- 5 premenných (**Baccala & Sameshima, 2001**)
- $x_1(n) = 0.95\sqrt{2}x_1(n-1) - 0.9025x_1(n-2) + w_1(n)$
 $x_2(n) = 0.5x_1(n-2) + w_2(n)$
 $x_3(n) = -0.4x_1(n-3) + w_3(n)$
 $x_4(n) = -0.5x_1(n-2) + 0.25\sqrt{2}x_4(n-1) + 0.25\sqrt{2}x_5(n-1) + w_4(n)$
 $x_5(n) = -0.25\sqrt{2}x_4(n-1) + 0.25\sqrt{2}x_5(n-1) + w_5(n)$
- graf



ukážka analýzy

- GCCA toolbox pre MATLAB (**Seth, 2005 – dnes**)





Ďakujem za pozornosť