

Odhady a modelování závislostní struktury aktivity v biologických neuronových sítích aneb

Přelet nad neurálním hnízdem

Jaroslav Hlinka

Ústav informatiky, Akademie věd ČR
Skupina nelineární dynamiky
<http://ndw.cs.cas.cz/>

Seminář strojového učení a modelování
Praha: 1. března 2012

Plán

Úvod

Mozek a jeho studium

Funkční konektivita

Motivation

Strategie

Výsledky

Efektivní konektivita

Grafové metody

Biologické neuronové sítě

Závěr

Úvod

Mozek a jeho studium

Funkční konektivita

Motivation

Strategie

Výsledky

Efektivní konektivita

Grafové metody

Biologické
neuronové sítě

Závěr

Reference

Úvod

Mozek a jeho studium

Funkční
konektivita

Motivation

Strategie

Výsledky

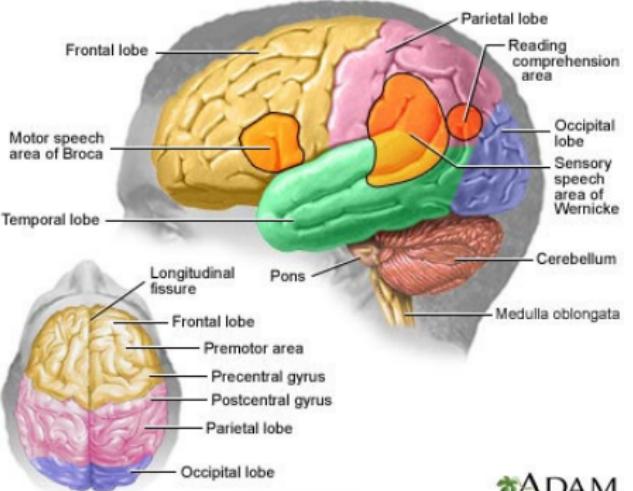
Efektivní
konektivita

Grafové metody

Biologické
neuronové sítě

Závěr

Reference



Metody v rukou neurovědce

Přelet nad
neurálním
hnízdem

Jaroslav Hlinka

Úvod

Mozek a jeho studium

Funkční
konektivita

Motivation

Strategie

Výsledky

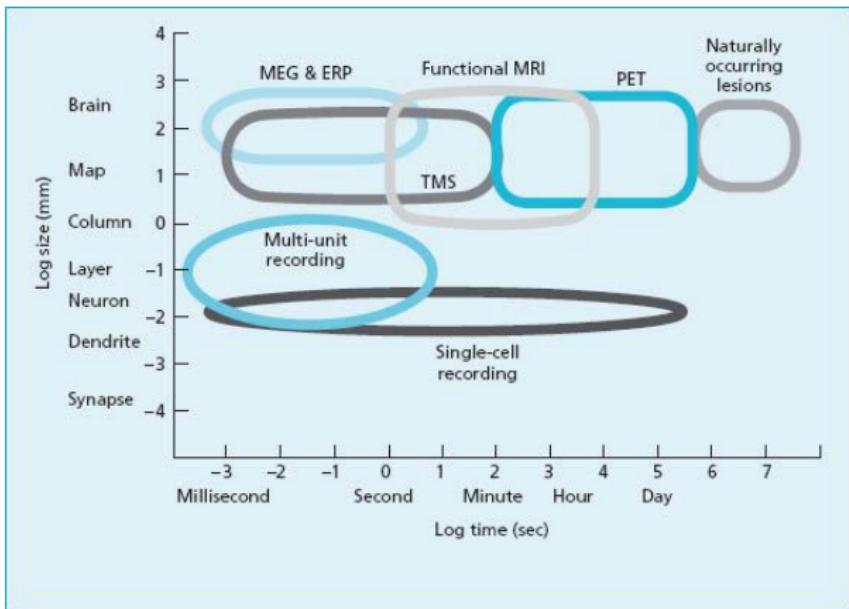
Efektivní
konektivita

Grafové metody

Biologické
neuronové sítě

Závěr

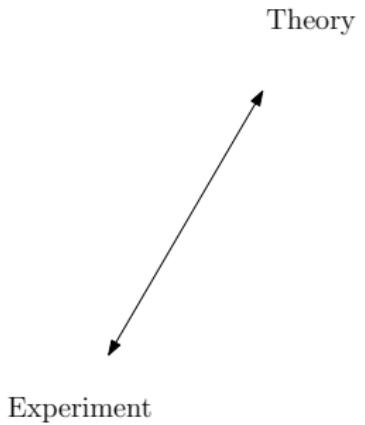
Reference



Děláme vědu takto?

Přelet nad
neurálním
hnízdem

Jaroslav Hlinka



Úvod
Mozek a jeho studium

Funkční
konektivita

Motivation
Strategie
Výsledky

Efektivní
konektivita

Grafové metody

Biologické
neuronové sítě

Závěr

Reference

Nebo spíše takto?

Přelet nad
neurálním
hnízdem

Jaroslav Hlinka

Úvod
Mozek a jeho studium

Funkční
konektivita

Motivation
Strategie
Výsledky

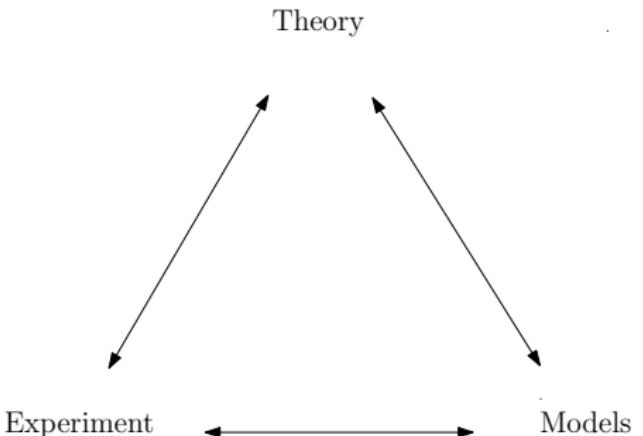
Efektivní
konektivita

Grafové metody

Biologické
neuronové sítě

Závěr

Reference



Osy výzkumu funkce mozku

Přelet nad
neurálním
hnízdem

Jaroslav Hlinka

Úvod

Mozek a jeho studium

Funkční
konektivita

Motivation

Strategie

Výsledky

Efektivní
konektivita

Grafové metody

Biologické
neuronové sítě

Závěr

Reference

- ▶ Lokalizace vs. integrace
- ▶ Exogenní vs. endogenní

Co je funkční konektivita?

Přelet nad
neurálním
hnízdem

Jaroslav Hlinka

Úvod

Mozek a jeho studium

Funkční
konektivita

Motivation

Strategie

Výsledky

Efektivní
konektivita

Grafové metody

Biologické
neuronové sítě

Závěr

Reference

Úvod

Mozek a jeho studium

Funkční
konektivita

Motivation

Strategie

Výsledky

Efektivní
konektivita

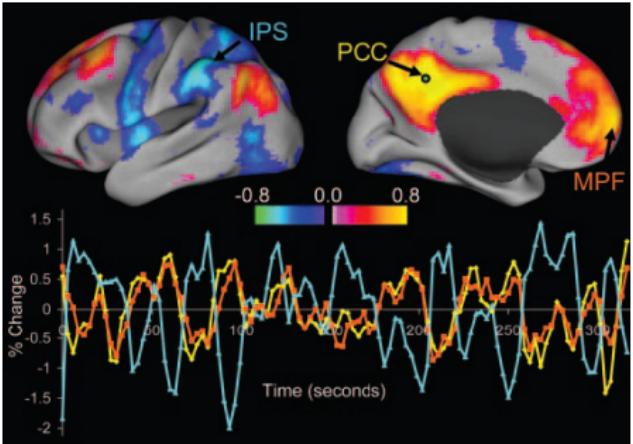
Grafové metody

Biologické
neuronové sítě

Závěr

Reference

Co je funkční konektivita?



Obrázek: Funkční konektivita organizovaná do velkých sítí.
(Fox et al, 2005, PNAS)

- ▶ Funkční konektivita: statistická souvislost mezi aktivitou různých mozkových oblastí
- ▶ Typicky měřená korelací mezi aktivitou oblastí v čase
- ▶ Lze měřit během úkolu, ale i během klidového stavu
- ▶ U fMRI je odvislá od pomalých fluktuací signálu

Co je na tom ‘funkční’?

Přelet nad
neurálním
hnízdem

Jaroslav Hlinka

Úvod

Mozek a jeho studium

Funkční
konektivita

Motivation

Strategie

Výsledky

Efektivní
konektivita

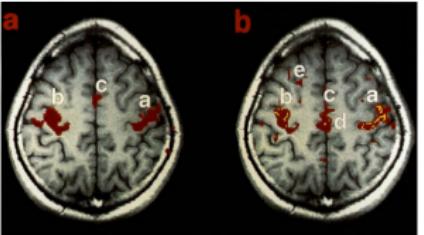
Grafové metody

Biologické
neuronové sítě

Závěr

Reference

Co je na tom ‘funkční’?



Obrázek: Biswal, 1995, MRM

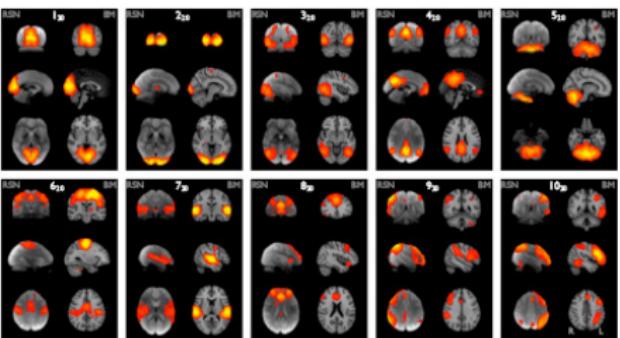


Fig. 1. Ten well-matched pairs of networks from the 20-component analysis of the 29,671-subject BrainMap activation database and (a) completely separate analysis of the 26-subject resting fMRI dataset. This figure contains 20 informative orthogonal slices for each pair. Scale bar (mm) of each pair. Resting fMRI data were obtained from the 26-subject fMRI dataset. (Right) RSNs 1s through 10s. Corresponding slices from the 20-component analysis based on the MN152 standard space template image. The networks were paired automatically by using spatial cross-correlation, with $r_{max} = 0.53$ ($0.26, 0.70$; the weakest of these correlations that has a significance of $P < 10^{-4}$ (corrected). All ICA spatial maps were converted to Z statistic images via a normalized mixture-model fit, and then thresholded at $Z = 3$.

Obrázek: Smith, 2009, PNAS

Jak vylepšit metody kvantifikace funkční konektivity?

- ▶ konektivita “all-to-all”?

Přelet nad
neurálním
hnízdem

Jaroslav Hlinka

Úvod

Mozek a jeho studium

Funkční
konektivita

Motivation

Strategie

Výsledky

Efektivní
konektivita

Grafové metody

Biologické
neuronové sítě

Závěr

Reference

Jak vylepšit metody kvantifikace funkční konektivity?

- ▶ konektivita “all-to-all”?
 - ▶ příliš mnoho signálů
 - ▶ nutno redukovat dimenzionalitu (anatomické oblasti zájmu, shlukovací metody, analýza nezávislých komponent)

Přelet nad
neurálním
hnízdem

Jaroslav Hlinka

Úvod

Mozek a jeho studium

Funkční
konektivita

Motivation

Strategie

Výsledky

Efektivní
konektivita

Grafové metody

Biologické
neuronové sítě

Závěr

Reference

Jak vylepšit metody kvantifikace funkční konektivity?

Přelet nad
neurálním
hnízdem

Jaroslav Hlinka

- ▶ konektivita “all-to-all”?
 - ▶ příliš mnoho signálů
 - ▶ nutno redukovat dimenzionalitu (anatomické oblasti zájmu, shlukovací metody, analýza nezávislých komponent)
- ▶ různé míry závislosti

Úvod

Mozek a jeho studium

Funkční
konektivita

Motivation

Strategie

Výsledky

Efektivní
konektivita

Grafové metody

Biologické
neuronové sítě

Závěr

Reference

Jak vylepšit metody kvantifikace funkční konektivity?

- ▶ konektivita “all-to-all”?
 - ▶ příliš mnoho signálů
 - ▶ nutno redukovat dimenzionalitu (anatomické oblasti zájmu, shlukovací metody, analýza nezávislých komponent)
- ▶ různé míry závislosti
 - ▶ korelační koeficient $\rho_{X,Y} = \frac{\text{cov}(X,Y)}{\sigma_X\sigma_Y} = \frac{E[(X-\mu_X)(Y-\mu_Y)]}{\sigma_X\sigma_Y}$
 - ▶ pořadové korelační míry (Spearman, Kendalovo tau,...)
 - ▶ informačně-teoretické míry:

Úvod

Mozek a jeho studium

Funkční
konektivita

Motivation

Strategie

Výsledky

Efektivní
konektivita

Grafové metody

Biologické
neuronové sítě

Závěr

Reference

Jak vylepšit metody kvantifikace funkční konektivity?

Přelet nad
neurálním
hnízdem

Jaroslav Hlinka

- ▶ konektivita “all-to-all”?
 - ▶ příliš mnoho signálů
 - ▶ nutno redukovat dimenzionalitu (anatomické oblasti zájmu, shlukovací metody, analýza nezávislých komponent)
- ▶ různé míry závislosti
 - ▶ korelační koeficient $\rho_{X,Y} = \frac{\text{cov}(X,Y)}{\sigma_X\sigma_Y} = \frac{E[(X-\mu_X)(Y-\mu_Y)]}{\sigma_X\sigma_Y}$
 - ▶ pořadové korelační míry (Spearman, Kendalovo tau,...)
 - ▶ informačně-teoretické míry: vzájemná informace

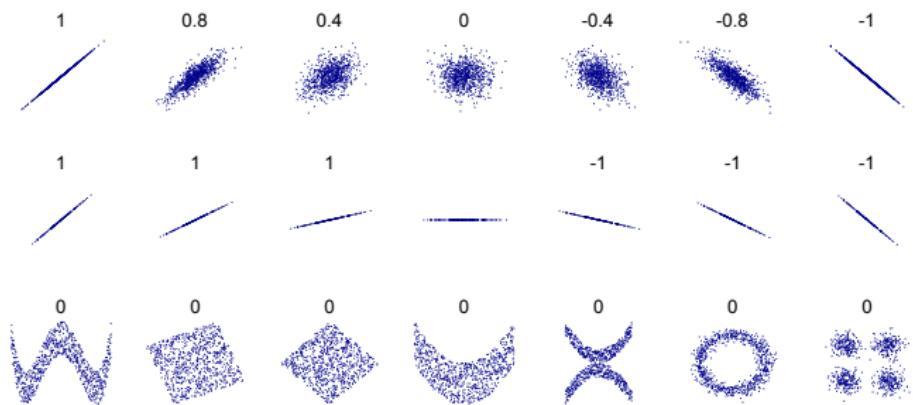
$$I(X; Y) = \sum_{y \in Y} \sum_{x \in X} p(x, y) \log \left(\frac{p(x, y)}{p(x)p(y)} \right)$$

Úvod
Mozek a jeho studium
Funkční
konektivita
Motivation
Strategie
Výsledky
Efektivní
konektivita
Grafové metody
Biologické
neuronové sítě
Závěr
Reference

Proč nemusí být lineární korelace vhodná?

Přelet nad neurálním hnízdem

Jaroslav Hlinka



Vzájemná informace

$$I(X; Y) = \sum_{y \in Y} \sum_{x \in X} p(x, y) \log \left(\frac{p(x, y)}{p(x) p(y)} \right)$$

Úvod

Mozek a jeho studium

Funkční
konektivita

Motivation

Strategie

Výsledky

Efektivní
konektivita

Grafové metody

Biologické
neuronové sítě

Závěr

Reference

Úvod

Mozek a jeho studium

Funkční
konektivita

Motivation

Strategie

Výsledky

Efektivní
konektivita

Grafové metody

Biologické
neuronové sítě

Závěr

Reference

Vzájemná informace

$$I(X; Y) = \sum_{y \in Y} \sum_{x \in X} p(x, y) \log \left(\frac{p(x, y)}{p(x) p(y)} \right)$$

souvisí s entropií: $H(X) = - \sum_{x \in X} p(x) \log p(x)$

Vzájemná informace

$$I(X; Y) = \sum_{y \in Y} \sum_{x \in X} p(x, y) \log \left(\frac{p(x, y)}{p(x)p(y)} \right)$$

souvisí s entropií: $H(X) = - \sum_{x \in X} p(x) \log p(x)$

$$I(X; Y) = H(X) + H(Y) - H(X, Y)$$

$$H(X|Y) = H(X, Y) - H(Y) \quad I(X; Y) = H(X) - H(X|Y)$$

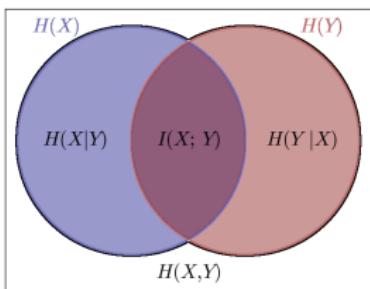
Vzájemná informace

$$I(X; Y) = \sum_{y \in Y} \sum_{x \in X} p(x, y) \log \left(\frac{p(x, y)}{p(x)p(y)} \right)$$

souvisí s entropií: $H(X) = - \sum_{x \in X} p(x) \log p(x)$

$$I(X; Y) = H(X) + H(Y) - H(X, Y)$$

$$H(X|Y) = H(X, Y) - H(Y) \quad I(X; Y) = H(X) - H(X|Y)$$



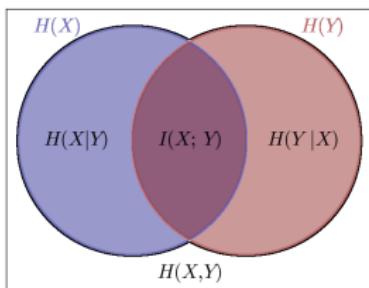
Vzájemná informace

$$I(X; Y) = \sum_{y \in Y} \sum_{x \in X} p(x, y) \log \left(\frac{p(x, y)}{p(x)p(y)} \right)$$

souvisí s entropií: $H(X) = - \sum_{x \in X} p(x) \log p(x)$

$$I(X; Y) = H(X) + H(Y) - H(X, Y)$$

$$H(X|Y) = H(X, Y) - H(Y) \quad I(X; Y) = H(X) - H(X|Y)$$



omezení: $0 \leq I(X; Y) \leq \max(H(X), H(Y))$; jednotky;

invariance vůči bijekcím: $I(X; Y) = I(f(X); g(Y))$;

$$I(X; Y) = D_{\text{KL}}(p(x, y) \| p(x)p(y))$$

Praktický problém

Přelet nad
neurálním
hnízdem

Jaroslav Hlinka

- ▶ lineární korelace
 - ▶ široce používaná, jednoduchý koncept
 - ▶ obecně efektivní

Úvod
Mozek a jeho studium

Funkční
konektivita
Motivation
Strategie
Výsledky

Efektivní
konektivita

Grafové metody

Biologické
neuronové sítě

Závěr

Reference

Praktický problém

Přelet nad
neurálním
hnízdem

Jaroslav Hlinka

- ▶ lineární korelace
 - ▶ široce používaná, jednoduchý koncept
 - ▶ obecně efektivní
- ▶ ALE ... neuronální i hemodynamické procesy jsou nelineární!
 - ⇒ nelineární metody navrženy pro fMRI funkční konektivitu

Úvod

Mozek a jeho studium

Funkční
konektivita

Motivation

Strategie

Výsledky

Efektivní
konektivita

Grafové metody

Biologické
neuronové sítě

Závěr

Reference

- ▶ lineární korelace
 - ▶ široce používaná, jednoduchý koncept
 - ▶ obecně efektivní
 - ▶ ALE ... neuronální i hemodynamické procesy jsou nelineární!
 - ⇒ nelineární metody navrženy pro fMRI funkční konektivitu
 - ▶ JENŽE ... nelineární metody mají také své problémy:
 - ▶ robustnost
 - ▶ implementace
 - ▶ interpretace
- ⇒ **Je lineární korelace dostatečná pro fMRI FC?**
- [1]

Úvod

Mozek a jeho studium

Funkční
konektivita

Motivation

Strategie

Výsledky

Efektivní
konektivita

Grafové metody

Biologické
neuronové sítě

Závěr

Reference

Strategie

Přelet nad
neurálním
hnízdem

Jaroslav Hlinka

Úvod

Mozek a jeho studium

Funkční
konektivita

Motivation

Strategie

Výsledky

Efektivní
konektivita

Grafové metody

Biologické
neuronové sítě

Závěr

Reference

- ▶ pro bivariátní normální rozdělení (“lineární závislost”):
 - ▶ lineární korelace $\rho_{X,Y}$ plně vystihuje závislost
 - ▶ vzájemná informace:
 $I(X; Y) = I_{Gauss}(\rho_{X,Y}) = -\frac{1}{2} \log(1 - \rho_{X,Y}^2)$

Úvod
Mozek a jeho studium
Funkční
konektivita
Motivation
Strategie
Výsledky
Efektivní
konektivita
Grafové metody
Biologické
neuronové sítě
Závěr
Reference

- ▶ pro bivariátní normální rozdělení (“lineární závislost”):
 - ▶ lineární korelace $\rho_{X,Y}$ plně vystihuje závislost
 - ▶ vzájemná informace:
 $I(X; Y) = I_{Gauss}(\rho_{X,Y}) = -\frac{1}{2} \log(1 - \rho_{X,Y}^2)$
- ▶ pro obecné bivariátní rozdělení:
 - ▶ lineární korelace nemusí být dostatečná
 - ▶ vzájemná informace: (při normalitě marginálů):
 $I(X; Y) \geq I_{Gauss}(\rho_{X,Y})$

Úvod

Mozek a jeho studium

Funkční
konektivita

Motivation

Strategie

Výsledky

Efektivní
konektivita

Grafové metody

Biologické
neuronové sítě

Závěr

Reference

- ▶ pro bivariátní normální rozdělení (“lineární závislost”):
 - ▶ lineární korelace $\rho_{X,Y}$ plně vystihuje závislost
 - ▶ vzájemná informace:
 $I(X; Y) = I_{Gauss}(\rho_{X,Y}) = -\frac{1}{2} \log(1 - \rho_{X,Y}^2)$
- ▶ pro obecné bivariátní rozdělení:
 - ▶ lineární korelace nemusí být dostatečná
 - ▶ vzájemná informace: (při normalitě marginálů):
 $I(X; Y) \geq I_{Gauss}(\rho_{X,Y})$
- ▶ ⇒ extra informace nezachycená korelačním koeficientem: $I_{neglected} = I(X; Y) - I_{Gauss}(\rho_{X,Y})$

Úvod

Mozek a jeho studium

Funkční
konektivita

Motivation

Strategie

Výsledky

Efektivní
konektivita

Grafové metody

Biologické
neuronové sítě

Závěr

Reference

Vizualizace strategie

Přelet nad neurálním hnízdem

Jaroslav Hlinka

Úvod

Funkční konektivita

Strategie

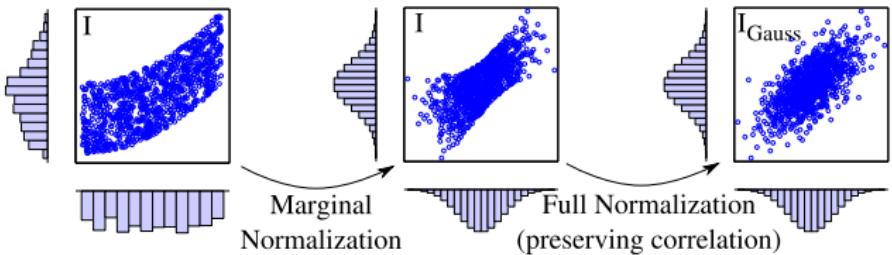
Efektivní konektivita

Grafové metody

Biologické neuronové sítě

Závěr

Reference



Úvod

Mozek a jeho studium

Funkční
konektivita

Motivation

Strategie

Výsledky

Efektivní
konektivita

Grafové metody

Biologické
neuronové sítě

Závěr

Reference

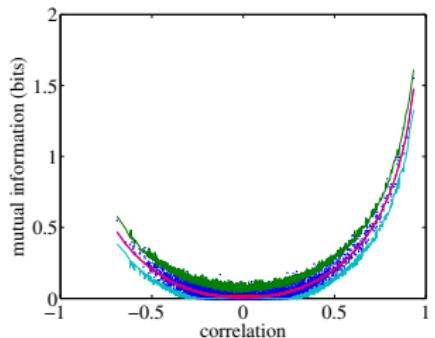
Implementation details

- ▶ **24 fMRI sessions** (3T, TR=2000 ms, $3 \times 3 \times 3.5$ mm³, 300 volumes), standard data processing
- ▶ AAL based parcellation to 90 regions
- ▶ each region represented by average activity time series
- ▶ **90-by-90 matrices of linear and nonlinear connectivity**
- ▶ **difference between linear and nonlinear connectivity**
 - ▶ **quantified**
 - ▶ **tested**
- ▶ mutual information estimated using the equiquantal method
- ▶ $I_{Gauss}(\rho_X, Y)$ is estimated by computing mutual information on linearized version of the data (Fast Fourier Transform surrogates) as finite sample estimates of linear correlation and mutual information have different properties (such as bias and variance)

Výsledky

Přelet nad neurálním hnízdem

Jaroslav Hlinka



Úvod

Mozek a jeho studium

Funkční konektivita

Výsledky

Efektivní konektivita

Grafové metody

Biologické neuronové sítě

Závěr

Reference

Úvod

Mozek a jeho studium

Funkční
konektivita

Motivation

Strategie

Výsledky

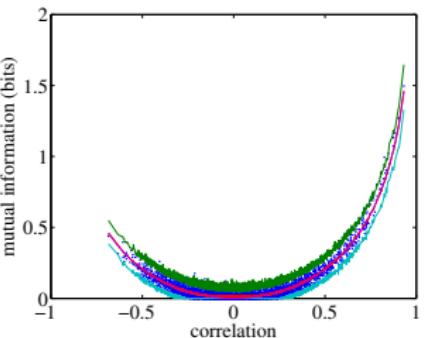
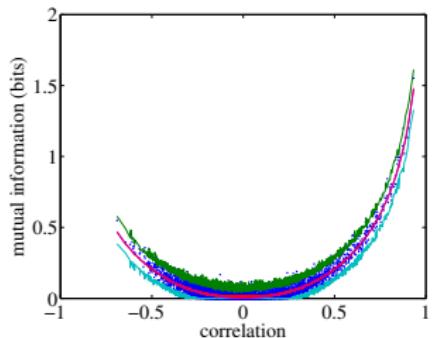
Efektivní
konektivita

Grafové metody

Biologické
neuronové sítě

Závěr

Reference



Úvod

Mozek a jeho studium

Funkční
konektivita

Motivation

Strategie

Výsledky

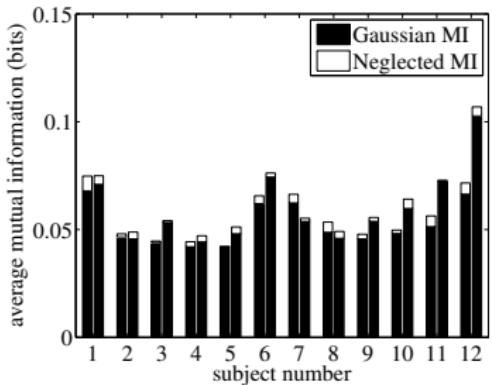
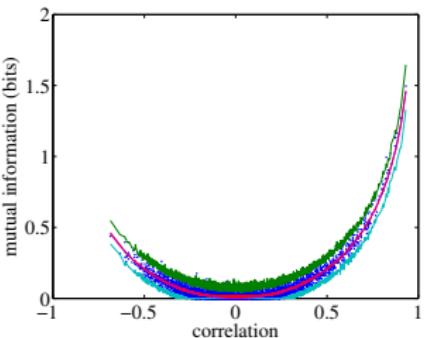
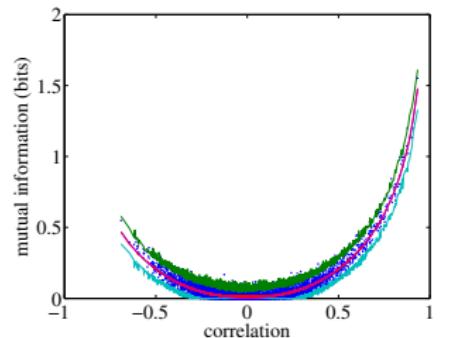
Efektivní
konektivita

Grafové metody

Biologické
neuronové sítě

Závěr

Reference



Úvod

Mozek a jeho studium

Funkční
konektivita

Motivation

Strategie

Výsledky

Efektivní
konektivita

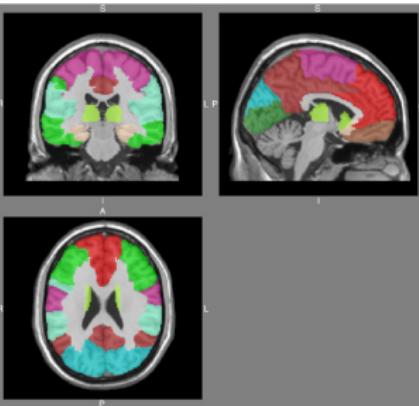
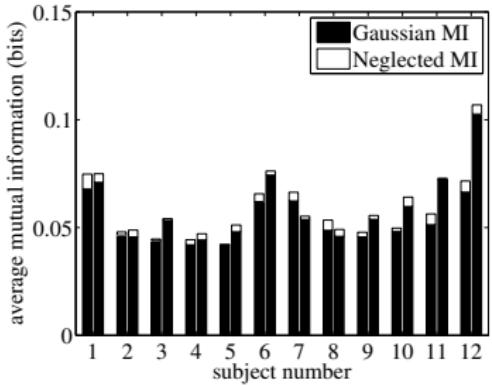
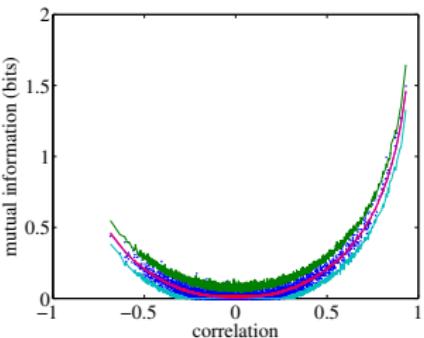
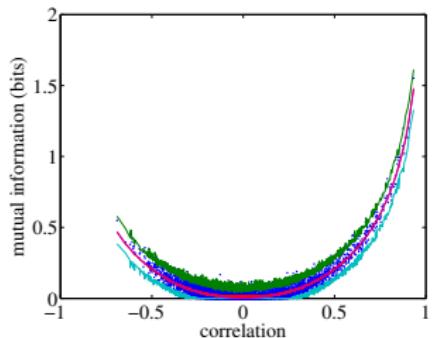
Grafové metody

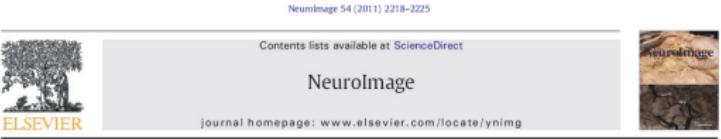
Biologické
neuronové sítě

Závěr

Reference

Výsledky





NeuroImage 54 (2011) 2218–2225

Contents lists available at ScienceDirect

NeuroImage

journal homepage: www.elsevier.com/locate/ynim

Functional connectivity in resting-state fMRI: Is linear correlation sufficient?

Jaroslav Hlinka ^{a,*}, Milan Paluš ^a, Martin Vejmelka ^a, Dante Mantini ^{b,c}, Maurizio Corbetta ^{c,d,e}

^a Institute of Computer Science, Academy of Sciences of the Czech Republic, Pod vodárenskou věží 2, 18207 Prague, Czech Republic

^b Laboratory for Neuro- and Psychophysiology, Katholieke Universiteit Leuven, 3000 Leuven, Belgium

^c Institute for Advanced Biomedical Technologies, G. D'Annunzio University Foundation, G. D'Annunzio University, 66013 Chieti, Italy

^d Department of Radiology, Washington University, St Louis, MO, USA

^e Department of Neurology, Washington University, St Louis, MO, USA

ARTICLE INFO

Article history:
Received 20 June 2010
Revised 9 August 2010
Accepted 10 August 2010
Available online 25 August 2010

Keywords:
fMRI
Functional connectivity
Gaussianity
Nonlinearity
Correlation
Mutual information

ABSTRACT

Functional connectivity (FC) analysis is a prominent approach to analyzing fMRI data, especially acquired under the resting state condition. The commonly used linear correlation FC measure bears an implicit assumption of Gaussianity of the dependence structure. If only the marginals, but not all the bivariate distributions are Gaussian, linear correlation consistently underestimates the strength of the dependence. To assess the suitability of linear correlation and its generality potential of other FC measures, we present a framework to test and estimate the deviation from Gaussianity by means of comparing mutual information in the data and its Gaussianized counterpart. We apply this method to 24 sessions of human resting state fMRI. For each session, matrix of connectivities between 90 anatomical parcel time series is computed using mutual information and compared to results from its multivariate Gaussian surrogate that conserves the correlations but cancels any nonlinearity. While the group-level tests confirmed non-Gaussianity in the FC, the quantitative assessment revealed that the portion of mutual information neglected by linear correlation is relatively minor—on average only about 5% of the mutual information already captured by the linear correlation. The marginality of the non-Gaussianity was confirmed in comparisons using clustering of the parcels—the disagreement between clustering obtained from mutual information and linear correlation was attributable to random error. We conclude that for this type of data, practical relevance of nonlinear methods trying to improve over linear correlation might be limited by the fact that the data are indeed almost Gaussian.

© 2010 Elsevier Inc. All rights reserved.

Úvod

Mozek a jeho studium

Funkční konektivita

Motivation

Strategie

Výsledky

Efektivní konektivita

Grafové metody

Biologické neuronové sítě

Závěr

Reference

Strategie - připomenutí

Přelet nad
neurálním
hnízdem

Jaroslav Hlinka

Úvod

Mozek a jeho studium

Funkční
konektivita

Motivation

Strategie

Výsledky

Efektivní
konektivita

Grafové metody

Biologické
neuronové sítě

Závěr

Reference

Strategie - připomenutí

Přelet nad
neurálním
hnízdem

Jaroslav Hlinka

- ▶ pro bivariátní normální rozdělení (“lineární závislost”):
 - ▶ lineární korelace $\rho_{X,Y}$ plně vystihuje závislost
 - ▶ vzájemná informace:
 $I(X; Y) = I_{Gauss}(\rho_{X,Y}) = -\frac{1}{2} \log(1 - \rho_{X,Y}^2)$

Úvod

Mozek a jeho studium

Funkční
konektivita

Motivation

Strategie

Výsledky

Efektivní
konektivita

Grafové metody

Biologické
neuronové sítě

Závěr

Reference

Strategie - připomenutí

Přelet nad
neurálním
hnízdem

Jaroslav Hlinka

Úvod

Mozek a jeho studium

Funkční
konektivita

Motivation

Strategie

Výsledky

Efektivní
konektivita

Grafové metody

Biologické
neuronové sítě

Závěr

Reference

- ▶ pro bivariátní normální rozdělení (“lineární závislost”):
 - ▶ lineární korelace $\rho_{X,Y}$ plně vystihuje závislost
 - ▶ vzájemná informace:
 $I(X; Y) = I_{Gauss}(\rho_{X,Y}) = -\frac{1}{2} \log(1 - \rho_{X,Y}^2)$
- ▶ pro obecné bivariátní rozdělení:
 - ▶ lineární korelace nemusí být dostatečná
 - ▶ vzájemná informace: (při normalitě marginálů):
 $I(X; Y) \geq I_{Gauss}(\rho_{X,Y})$

Strategie - připomenutí

Přelet nad
neurálním
hnízdem

Jaroslav Hlinka

- ▶ pro bivariátní normální rozdělení (“lineární závislost”):
 - ▶ lineární korelace $\rho_{X,Y}$ plně vystihuje závislost
 - ▶ vzájemná informace:
 $I(X; Y) = I_{Gauss}(\rho_{X,Y}) = -\frac{1}{2} \log(1 - \rho_{X,Y}^2)$
- ▶ pro obecné bivariátní rozdělení:
 - ▶ lineární korelace nemusí být dostatečná
 - ▶ vzájemná informace: (při normalitě marginálů):
 $I(X; Y) \geq I_{Gauss}(\rho_{X,Y})$
- ▶ ⇒ extra informace nezachycená korelačním koeficientem: $I_{neglected} = I(X; Y) - I_{Gauss}(\rho_{X,Y})$

Úvod

Mozek a jeho studium

Funkční
konektivita

Motivation

Strategie

Výsledky

Efektivní
konektivita

Grafové metody

Biologické
neuronové sítě

Závěr

Reference

Proč $I(X, Y) \geq -\frac{1}{2} \log(1 - \rho_{X,Y}^2)$?

Přelet nad
neurálním
hnízdem

Jaroslav Hlinka

Rozdělení s **maximální entropií**:

- ▶ $(0, 1)$: rovnoměrné rozdělení
- ▶ $\mathbb{R}, \sigma(X) = c$: $\mathcal{N}(\mu, \sigma^2)$
- ▶ $\mathbb{R}^2, \text{Cov}(X) = \Sigma$: $\mathcal{N}(\mu, \Sigma)$

Úvod

Mozek a jeho studium

Funkční
konektivita

Motivation

Strategie

Výsledky

Efektivní
konektivita

Grafové metody

Biologické
neuronové sítě

Závěr

Reference

Proč $I(X, Y) \geq -\frac{1}{2} \log(1 - \rho_{X,Y}^2)$?

Přelet nad
neurálním
hnízdem

Jaroslav Hlinka

Rozdělení s **maximální entropií**:

- ▶ $(0, 1)$: rovnoměrné rozdělení
- ▶ $\mathbb{R}, \sigma(X) = c$: $\mathcal{N}(\mu, \sigma^2)$
- ▶ $\mathbb{R}^2, \text{Cov}(X) = \Sigma$: $\mathcal{N}(\mu, \Sigma)$
- ▶ Co tedy rozdělení s **minimální informací**?

Úvod

Mozek a jeho studium

Funkční
konektivita

Motivation

Strategie

Výsledky

Efektivní
konektivita

Grafové metody

Biologické
neuronové sítě

Závěr

Reference

Proč $I(X, Y) \geq -\frac{1}{2} \log(1 - \rho_{X,Y}^2)$?

Přelet nad
neurálním
hnízdem

Jaroslav Hlinka

Rozdělení s **maximální entropií**:

- ▶ $(0, 1)$: rovnoměrné rozdělení
- ▶ $\mathbb{R}, \sigma(X) = c$: $\mathcal{N}(\mu, \sigma^2)$
- ▶ $\mathbb{R}^2, \text{Cov}(X) = \Sigma$: $\mathcal{N}(\mu, \Sigma)$
- ▶ Co tedy rozdělení s **minimální informací**?
 - ▶ $I(X; Y) = H(X) + H(Y) - H(X, Y)$
 - ▶ $\arg \min_X I(X) \stackrel{?}{=} \mathcal{N}(\mu, \Sigma)$

Úvod

Mozek a jeho studium

Funkční
konektivita

Motivation

Strategie

Výsledky

Efektivní
konektivita

Grafové metody

Biologické
neuronové sítě

Závěr

Reference

Proč $I(X, Y) \geq -\frac{1}{2} \log(1 - \rho_{X,Y}^2)$?

Přelet nad
neurálním
hnízdem

Jaroslav Hlinka

Rozdělení s **maximální entropií**:

- ▶ $(0, 1)$: rovnoměrné rozdělení
- ▶ $\mathbb{R}, \sigma(X) = c$: $\mathcal{N}(\mu, \sigma^2)$
- ▶ $\mathbb{R}^2, \text{Cov}(X) = \Sigma$: $\mathcal{N}(\mu, \Sigma)$
- ▶ Co tedy rozdělení s **minimální informací**?
 - ▶ $I(X; Y) = H(X) + H(Y) - H(X, Y)$
 - ▶ $\arg \min_X I(X) \stackrel{?}{=} \mathcal{N}(\mu, \Sigma)$
 - ▶ Ano, pokud zafixujeme $H(X)$ a $H(Y)$ marginální normalizací...
 - ▶ **Je to třeba?**

Úvod

Mozek a jeho studium

Funkční
konektivita

Motivation

Strategie

Výsledky

Efektivní
konektivita

Grafové metody

Biologické
neuronové sítě

Závěr

Reference

Rozdělení s minimální informací a danou kovariancí

It is well known that Gaussian distributions maximize the Shannon entropy for given first and second moments. This implies that the Shannon entropy of any distribution is bounded from above by $(1/2) \log \det \mathbf{C}$ where \mathbf{C} is the covariance matrix. For MI one can prove a similar result: For any multivariate distribution with joint covariance matrix \mathbf{C} and variances $\sigma_i = C_{ii}$ for the individual (scalar) random variables X_i , the redundancy is bounded from below,

$$I(X_1, \dots, X_m) \geq \frac{1}{2} \log \frac{\det \mathbf{C}}{\sigma_1 \dots \sigma_m}. \quad (48)$$

Obrázek: Kraskov, 2004 [2].

Úvod

Mozek a jeho studium

Funkční
konektivita

Motivation

Strategie

Výsledky

Efektivní
konektivita

Grafové metody

Biologické
neuronové sítě

Závěr

Reference

Rozdělení s minimální informací a danou kovariancí

It is well known that Gaussian distributions maximize the Shannon entropy for given first and second moments. This implies that the Shannon entropy of any distribution is bounded from above by $(1/2) \log \det \mathbf{C}$ where \mathbf{C} is the covariance matrix. For MI one can prove a similar result: For any multivariate distribution with joint covariance matrix \mathbf{C} and variances $\sigma_i = C_{ii}$ for the individual (scalar) random variables X_i , the redundancy is bounded from below,

$$I(X_1, \dots, X_m) \geq \frac{1}{2} \log \frac{\det \mathbf{C}}{\sigma_1 \dots \sigma_m}. \quad (48)$$

Obrázek: Kraskov, 2004 [2].

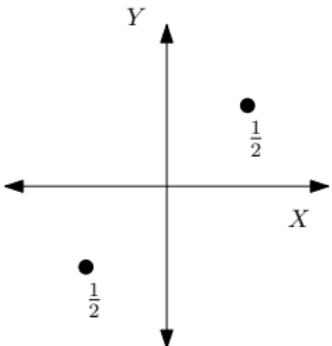
In the following we sketch only the proof for the case

- ▶ Takže: je marginalizace nutná?

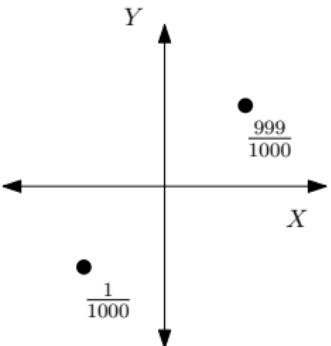
Protikpříklad

Přelet nad
neurálním
hnízdem

Jaroslav Hlinka



$$R(X, Y) = 1$$
$$I(X, Y) = H(X) = 1\text{bit}$$



$$R(X, Y) = 1$$
$$I(X, Y) = H(X) = 0.011$$

- $I(X, Y)$ lze stlačit k nule při zachování libovolně vysoké korelace
- Kraskov má v důkaze chybu, marginalizace nutná!

Úvod
Mozek a jeho studium

Funkční
konektivita
Motivation
Strategie
Výsledky

Efektivní
konektivita

Grafové metody

Biologické
neuronové sítě

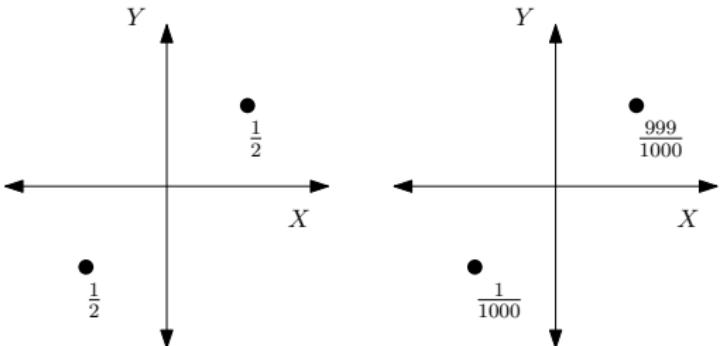
Závěr

Reference

Protikpříklad

Přelet nad
neurálním
hnízdem

Jaroslav Hlinka



$$R(X, Y) = 1$$
$$I(X, Y) = H(X) = 1\text{bit}$$

$$R(X, Y) = 1$$
$$I(X, Y) = H(X) = 0.011$$

- $I(X, Y)$ lze stlačit k nule při zachování libovolně vysoké korelace
- Kraskov má v důkaze chybu, marginalizace nutná!
- Každopádně, korelace pro fMRI stačí. Nebo ne?

Úvod

Mozek a jeho studium

Funkční
konektivita

Motivation

Strategie

Výsledky

Efektivní
konektivita

Grafové metody

Biologické
neuronové sítě

Závěr

Reference

Causality - linear and nonlinear

Přelet nad
neurálním
hnízdem

Jaroslav Hlinka

- ▶ Different approaches to causality detection from time series
- ▶ Granger causality: X ‘Granger causes’ Y iff including the past of Y in a (linear) model of X significantly improves the model fit

$$\mathcal{F}_{Y \rightarrow X|Z} = \ln\left(\frac{|\Sigma(\boldsymbol{\varepsilon}_t)|}{|\Sigma(\boldsymbol{\varepsilon}'_t)|}\right)$$

Úvod

Mozek a jeho studium

Funkční
konektivita

Motivation

Strategie

Výsledky

Efektivní
konektivita

Grafové metody

Biologické
neuronové sítě

Závěr

Reference

Causality - linear and nonlinear

Přelet nad
neurálním
hnízdem

Jaroslav Hlinka

- ▶ Different approaches to causality detection from time series
- ▶ Granger causality: X ‘Granger causes’ Y iff including the past of Y in a (linear) model of X significantly improves the model fit

$$\mathcal{F}_{Y \rightarrow X|Z} \equiv \ln\left(\frac{|\Sigma(\varepsilon_t)|}{|\Sigma(\varepsilon'_t)|}\right)$$

- ▶ Transfer entropy: the difference between entropies of the variable X conditioned (or not) on Y :

$$T'_{Y \rightarrow X|Z} \equiv H(X|X^- \oplus Z^-) - H(X|X^- \oplus Y^- \oplus Z^-),$$

- ▶ for stationary linear Gaussian processes linear GC index and TE **equivalent**

Úvod

Mozek a jeho studium

Funkční
konektivita

Motivation

Strategie

Výsledky

Efektivní
konektivita

Grafové metody

Biologické
neuronové sítě

Závěr

Reference

- ▶ for stationary linear Gaussian processes linear GC index and TE **equivalent**
- ▶ up to factor 2

$$\mathcal{F}_{Y \rightarrow X|Z} = 2\mathcal{T}_{Y \rightarrow X|Z}$$

- ▶ Recall $I(X, Y) \geq -\frac{1}{2} \log(1 - \rho_{X,Y}^2)$ for general distribution with normal marginals

- ▶ for stationary linear Gaussian processes linear GC index and TE **equivalent**
- ▶ up to factor 2

$$\mathcal{F}_{Y \rightarrow X|Z} = 2\mathcal{T}_{Y \rightarrow X|Z}$$

- ▶ Recall $I(X, Y) \geq -\frac{1}{2} \log(1 - \rho_{X,Y}^2)$ for general distribution with normal marginals
- ▶ **Is there a similar inequality for causality indices?**

Co když mne zajímá struktura interakcí mezi mnoha oblastmi?

Úvod

Mozek a jeho studium

Funkční
konektivita

Motivation

Strategie

Výsledky

Efektivní
konektivita

Grafové metody

Biologické
neuronové sítě

Závěr

Reference

Co když mne zajímá struktura interakcí mezi mnoha oblastmi?

grafově-teoretická analýza

- ▶ konektivity jsou převedeny na (ne)orientovaný graf
- ▶ zkoumáme vlastnosti grafu:
 - ▶ hustota
 - ▶ průměrná délka cest
 - ▶ shlukovitost
 - ▶ modularita
 - ▶ malosvětskost (small-world property)
 - ▶ existence centrálních uzlů
- ▶ interpretovány jsou získané hodnoty, nebo rozdíly v těchto vlastnostech mezi zkoumanými skupinami subjektů

Formalizace grafových vlastností

Přelet nad
neurálním
hnízdem

Jaroslav Hlinka

Úvod

Mozek a jeho studium

Funkční
konektivita

Motivation

Strategie

Výsledky

Efektivní
konektivita

Grafové metody

Biologické
neuronové sítě

Závěr

Reference

Formalizace grafových vlastností

Graf: $G = (V, E)$; V množina uzelů; bùno $V = 1, \dots, n$

$E \subset V^2$ množina hran. $d_{i,j}$ je délka nejkratší cesty mezi uzly i a j . Reprezentace (binární) maticí A:

$$A_{i,j} = 1 \Leftrightarrow (i, j) \in E.$$

$$L = \frac{1}{n \cdot (n - 1)} \cdot \sum_{i,j} d_{i,j}$$

$$C = \frac{1}{n} \sum_{i \in V} c_i; \quad c_i = \frac{\sum_{j,\ell} A_{i,j} A_{j,\ell} A_{\ell,i}}{k_i(k_i - 1)}$$

Malosvětskost (Small-world property)

Přelet nad
neurálním
hnízdem

Jaroslav Hlinka

Úvod

Mozek a jeho studium

Funkční
konektivita

Motivation

Strategie

Výsledky

Efektivní
konektivita

Grafové metody

Biologické
neuronové sítě

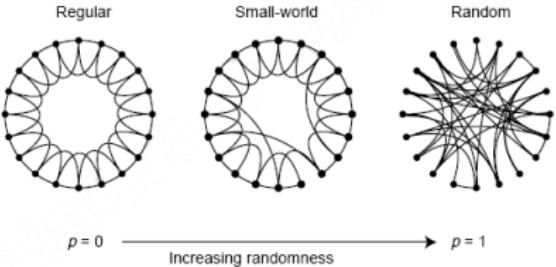
Závěr

Reference

Malosvětskost (Small-world property)

Přelet nad
neurálním
hnízdem

Jaroslav Hlinka



Úvod

Mozek a jeho studium

Funkční
konektivita

Motivation

Strategie

Výsledky

Efektivní
konektivita

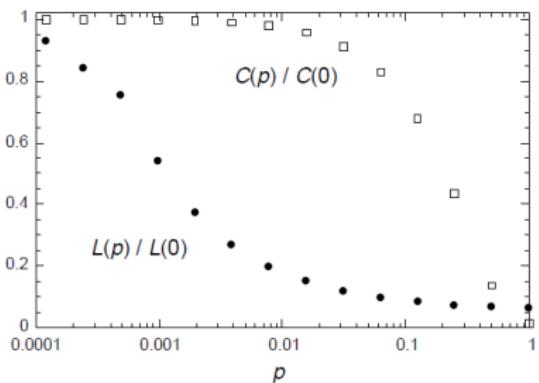
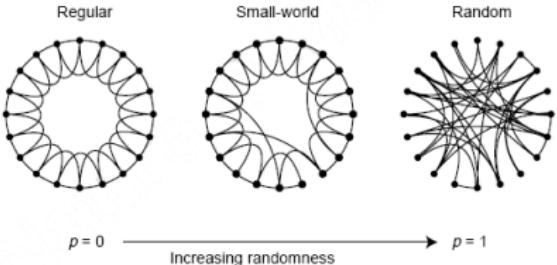
Grafové metody

Biologické
neuronové sítě

Závěr

Reference

Malosvětskost (Small-world property)



Úvod

Mozek a jeho studium

Funkční
konektivita

Motivation

Strategie

Výsledky

Efektivní
konektivita

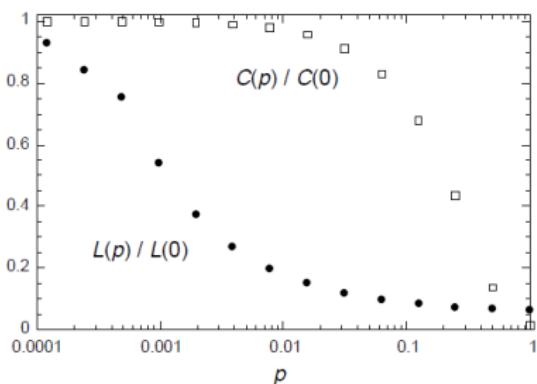
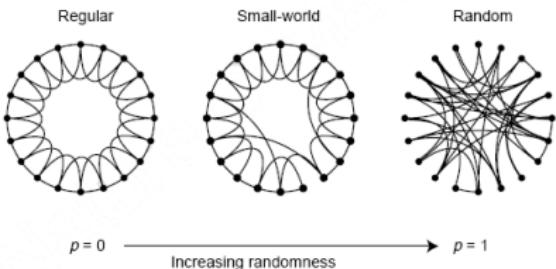
Grafové metody

Biologické
neuronové sítě

Závěr

Reference

Malosvětskost (Small-world property)



small-world index: $\sigma = \frac{\gamma}{\lambda} \gg 1$, $\lambda = \frac{L}{L_{rand}} \gtrsim 1$,
 $\gamma = \frac{C}{C_{rand}} \gg 1$

Mozek je malý svět

Přelet nad
neurálním
hnízdem

Jaroslav Hlinka

Úvod

Mozek a jeho studium

Funkční
konektivita

Motivation

Strategie

Výsledky

Efektivní
konektivita

Grafové metody

Biologické
neuronové sítě

Závěr

Reference

Mozek je malý svět

Přelet nad neurálním hnízdem

Jaroslav Hlinka

Úvod

Funkční konektivita

Efektivní konektivita

Grafové metody

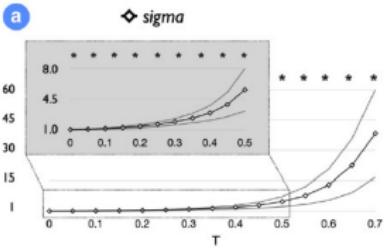
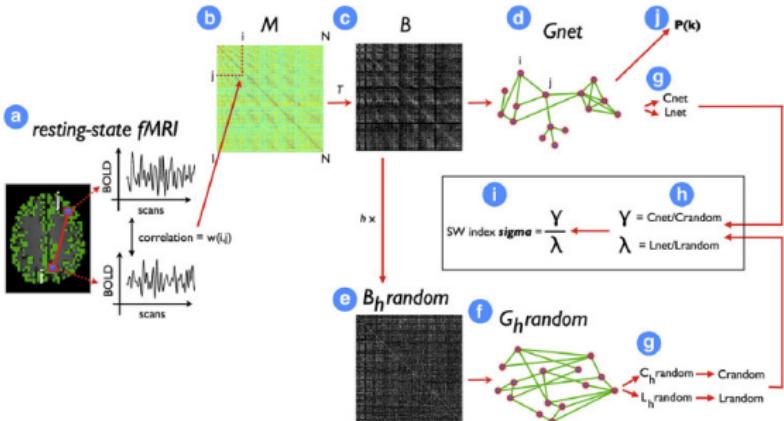
Biologické neuronové sítě

Závěr

Reference

M.P. van den Heuvel et al. / NeuroImage 43 (2008) 528–539

331



Proč je to zajímavé

Přelet nad
neurálním
hnízdem

Jaroslav Hlinka

Úvod

Mozek a jeho studium

Funkční
konektivita

Motivation

Strategie

Výsledky

Efektivní
konektivita

Grafové metody

Biologické
neuronové sítě

Závěr

Reference

Mozek je malý svět... a náhodně propojený AR proces taky...

Přelet nad
neurálním
hnízdem

Jaroslav Hlinka

Úvod

Mozek a jeho studium

Funkční konektivita

Motivation

Strategie

Výsledky

Efektivní konektivita

Grafové metody

Biologické neuronové sítě

Závěr

Reference

Mozek je malý svět... a náhodně propojený AR proces taky...

Přelet nad
neurálním
hnízdem

Jaroslav Hlinka

Úvod

Mozek a jeho studium

Funkční
konektivita

Motivation

Strategie

Výsledky

Efektivní
konektivita

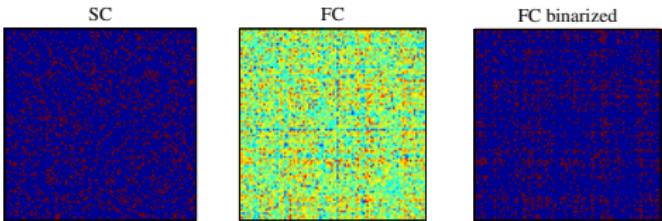
Grafové metody

Biologické
neuronové sítě

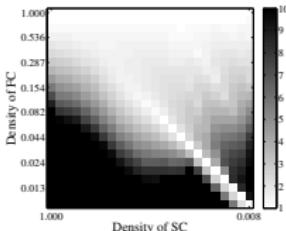
Závěr

Reference

$$X_t = AX_{t-1} + e_t$$



$$L_S = 2.157, L_F = 2.308, C_S = 0.1081, C_F = 0.2355, \lambda = 1.07, \gamma = 2.1778, \sigma = 2.0353.$$



Detailní výsledky

Přelet nad
neurálním
hnízdem

Jaroslav Hlinka

Úvod

Mozek a jeho studium

Funkční
konektivita

Motivation

Strategie

Výsledky

Efektivní
konektivita

Grafové metody

Biologické
neuronové sítě

Závěr

Reference

Úvod

Mozek a jeho studium

Funkční
konektivita

Motivation

Strategie

Výsledky

Efektivní
konektivita

Grafové metody

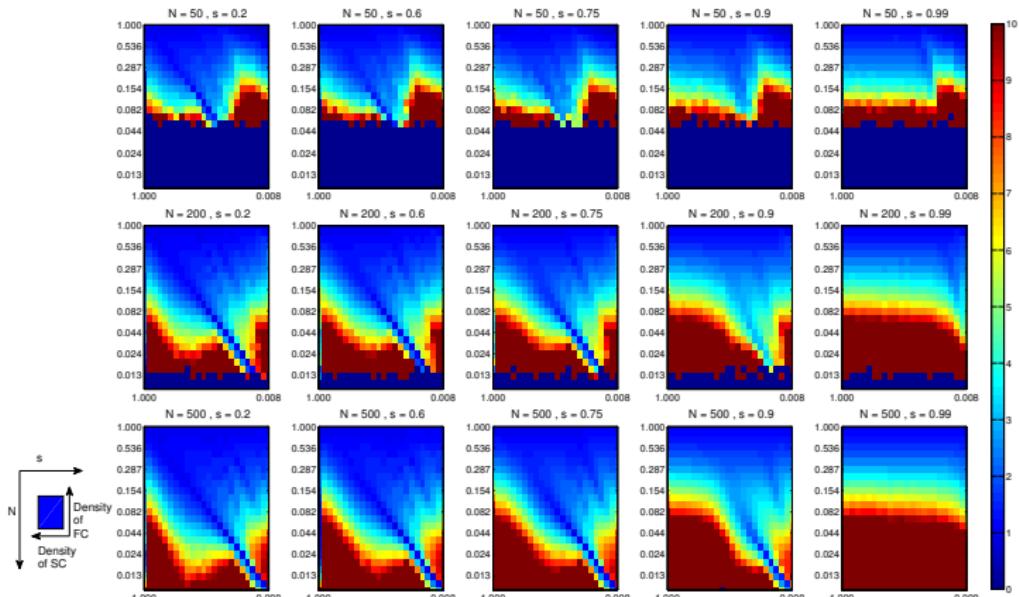
Biologické
neuronové sítě

Závěr

Reference

Detailní výsledky

$\sigma \gg 1$, ale závisí na mnoha parametrech:



Metody v rukou neurovědce

Přelet nad
neurálním
hnízdem

Jaroslav Hlinka

Úvod

Mozek a jeho studium

Funkční
konektivita

Motivation

Strategie

Výsledky

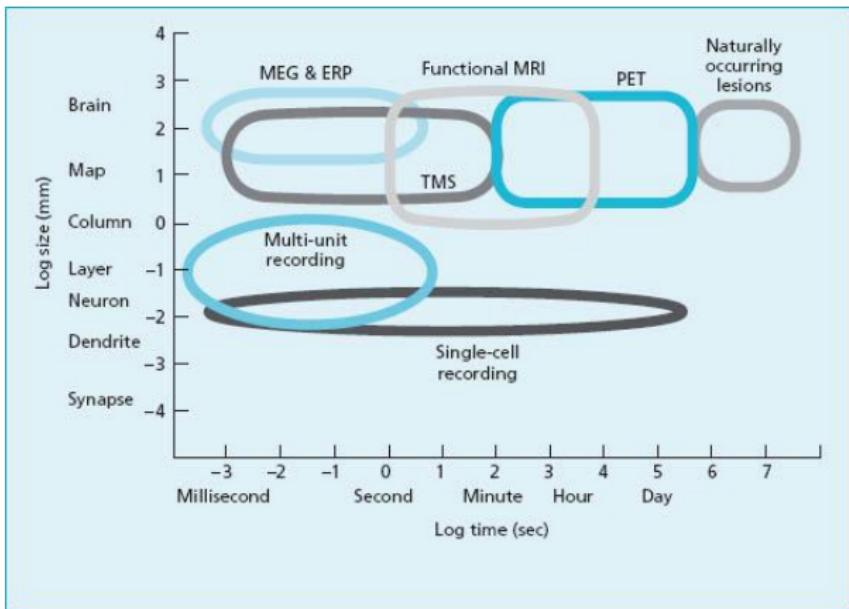
Efektivní
konektivita

Grafové metody

Biologické
neuronové sítě

Závěr

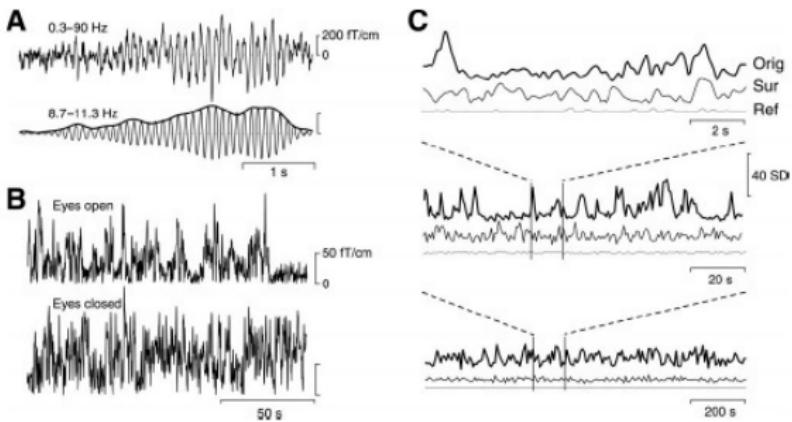
Reference



Hierarchie časových škál

Přelet nad neurálním hnízdem

Jaroslav Hlinka



Hierarchie časových škál

Přelet nad
neurálním
hnízdem

Jaroslav Hlinka

Úvod

Mozek a jeho studium

Funkční
konektivita

Motivation
Strategie
Výsledky

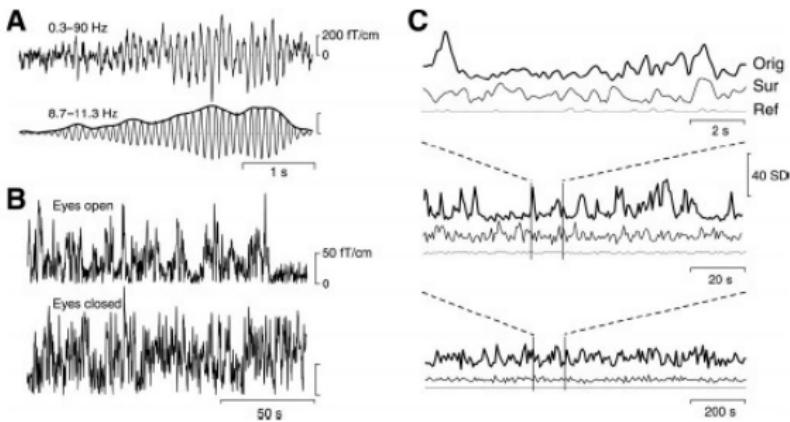
Efektivní
konektivita

Grafové metody

Biologické
neuronové sítě

Závěr

Reference

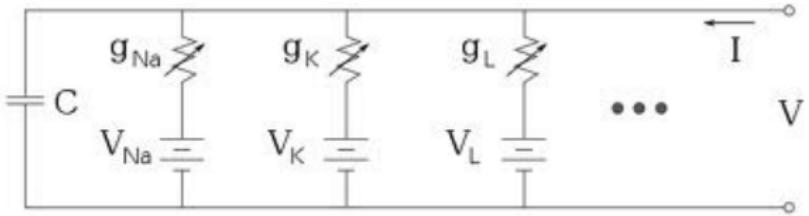


složitá dynamika

McCulloch-Pitts model (1943):

$$z(i, t + 1) = S \left(\sum_i w_{ij} z(j, t) - \epsilon_i \right),$$

Hodgkin-Huxley model (1952):



Úvod

Mozek a jeho studium

Funkční
konektivita

Motivation

Strategie

Výsledky

Efektivní
konektivita

Grafové metody

Biologické
neuronové sítě

Závěr

Reference

Hodgkin-Huxley model

$$C \frac{dV}{dt} = -F + I_s + I, \quad (1)$$

$$\begin{aligned} F(V, m, n, h) &= I_K + I_{Na} + I_L = \\ &= g_K n^4 (V - V_K) + g_{Na} m^3 h (V - V_{Na}) + g_L (V - V_L). \end{aligned} \quad (2)$$

$$\frac{dm}{dt} = \alpha_m(V)(1 - m) - \beta_m(V)m, \quad (3)$$

$$\frac{dn}{dt} = \alpha_n(V)(1 - n) - \beta_n(V)n, \quad (4)$$

$$\frac{dh}{dt} = \alpha_h(V)(1 - h) - \beta_h(V)h. \quad (5)$$

$C = 1 \mu F cm^{-2}$, $g_L = 0.3 mS cm^{-2}$, $g_K = 36 mS cm^{-2}$, $g_{Na} = 120 mS cm^{-2}$, $V_L = -54.402 mV$,
 $V_K = -77 mV$, $V_{Na} = 50 mV$

$$\alpha_m(V) = \frac{0.1(V + 40)}{1 - e^{-0.1(V+40)}} \qquad \beta_m(V) = 4.0e^{-0.0556(V+65)} \quad (6)$$

$$\alpha_n(V) = \frac{0.1(V + 55)}{1 - e^{-0.1(V+55)}} \qquad \beta_n(V) = 0.125e^{-0.0125(V+65)} \quad (7)$$

$$\alpha_h(V) = 0.07e^{-0.05(V+65)} \qquad \beta_h(V) = \frac{1}{1 + e^{-0.1(V+35)}}. \quad (8)$$

Behaviour of HH neuron

Přelet nad
neurálním
hnízdem

Jaroslav Hlinka

Úvod

Mozek a jeho studium

Funkční
konektivita

Motivation

Strategie

Výsledky

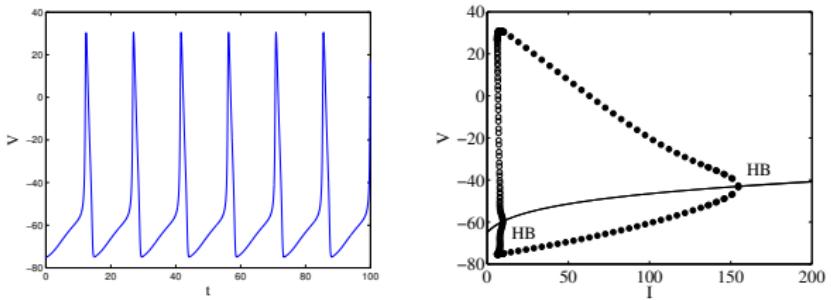
Efektivní
konektivita

Grafové metody

Biologické
neuronové sítě

Závěr

Reference



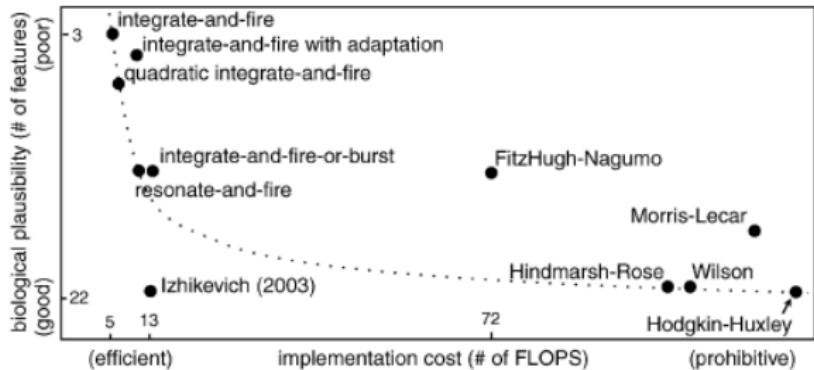
V závislosti na proudu I a jiných parametrech může mít stabilní pevný bod, oscilace, ale i třeba chaotický atraktor

Zoo modelů

modely neuronu:

Přelet nad
neurálním
hnízdem

Jaroslav Hlinka



Úvod

Mozek a jeho studium

Funkční
konektivita

Motivation

Strategie

Výsledky

Efektivní
konektivita

Grafové metody

Biologické
neuronové sítě

Závěr

Reference

Úvod

Mozek a jeho studium

Funkční
konektivita

Motivation

Strategie

Výsledky

Efektivní
konektivita

Grafové metody

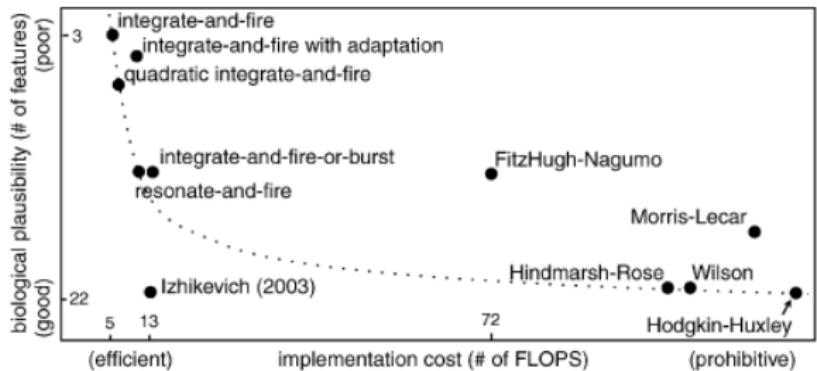
Biologické
neuronové sítě

Závěr

Reference

Zoo modelů

modely neuronu:



a vynásob modely synapse...

Úvod

Mozek a jeho studium

Funkční
konektivita

Motivation

Strategie

Výsledky

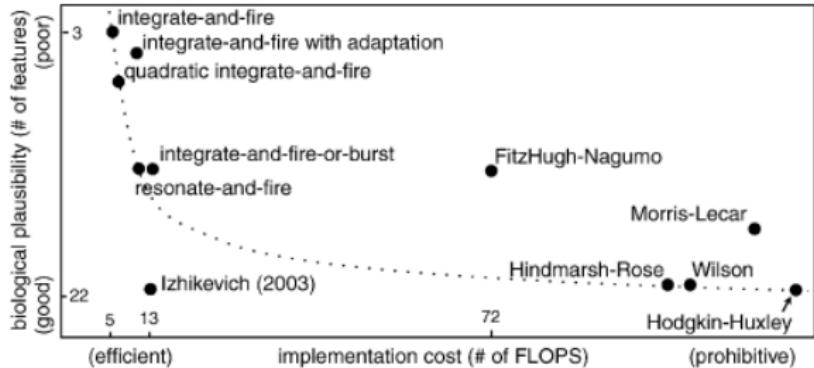
Efektivní
konektivita

Grafové metody

Biologické
neuronové sítě

Závěr

Reference



a vynásob modely synapse...

Podobně se schematicky modelují celé neuronální populace:

Wilson-Cowan model (1972)

$$\tau_e \frac{\partial E}{\partial t} = -E + (k_e - \rho_e E) S_e (c_1 E - c_2 I + P), \quad (9)$$

$$\tau_i \frac{\partial I}{\partial t} = -I + (k_i - \rho_i I) S_i (c_3 E - c_4 I + Q). \quad (10)$$

Dynamika Wilsonova-Cowanova modelu

Přelet nad
neurálním
hnízdem

Jaroslav Hlinka

Úvod

Mozek a jeho studium

Funkční
konektivita

Motivation

Strategie

Výsledky

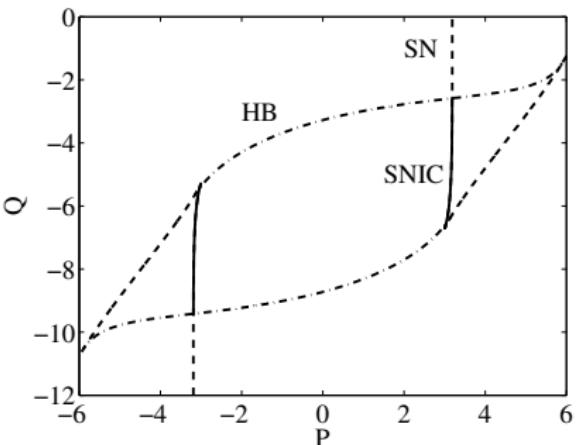
Efektivní
konektivita

Grafové metody

Biologické
neuronové sítě

Závěr

Reference



Velká otázka ohledně $\dot{X}_i = f_i(X_i) + g_i(X)$

Přelet nad
neurálním
hnízdem

Jaroslav Hlinka

Úvod

Mozek a jeho studium

Funkční
konektivita

Motivation

Strategie

Výsledky

Efektivní
konektivita

Grafové metody

Biologické
neuronové sítě

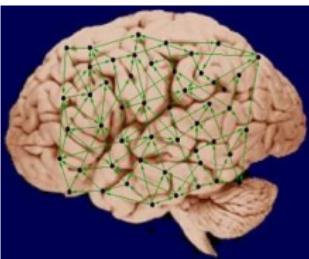
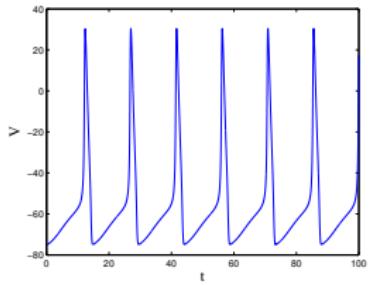
Závěr

Reference

Velká otázka ohledně $\dot{X}_i = f_i(X_i) + g_i(X)$

Přelet nad
neurálním
hnízdem

Jaroslav Hlinka



Úvod

Mozek a jeho studium

Funkční
konektivita

Motivation

Strategie

Výsledky

Efektivní
konektivita

Grafové metody

Biologické
neuronové sítě

Závěr

Reference

Velká otázka ohledně $\dot{X}_i = f_i(X_i) + g_i(X)$

Přelet nad
neurálním
hnízdem

Jaroslav Hlinka

Úvod

Mozek a jeho studium

Funkční
konektivita

Motivation

Strategie

Výsledky

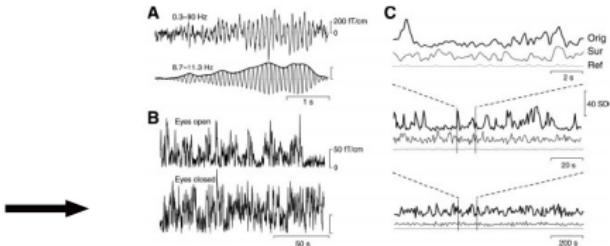
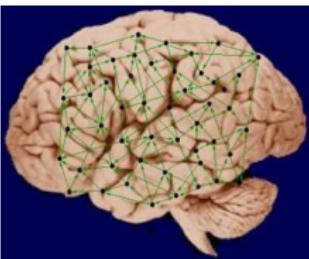
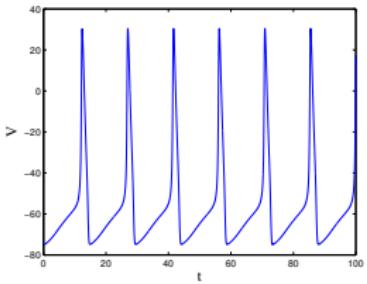
Efektivní
konektivita

Grafové metody

Biologické
neuronové sítě

Závěr

Reference



Velká otázka ohledně $\dot{X}_i = f_i(X_i) + g_i(X)$

Přelet nad
neurálním
hnízdem

Jaroslav Hlinka

Úvod

Mozek a jeho studium

Funkční
konektivita

Motivation

Strategie

Výsledky

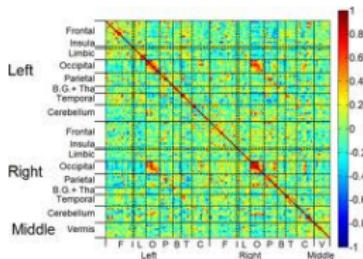
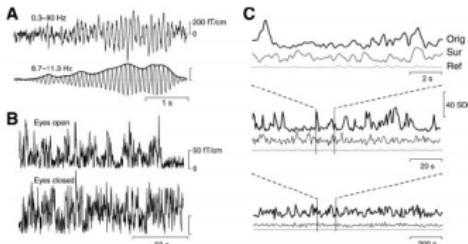
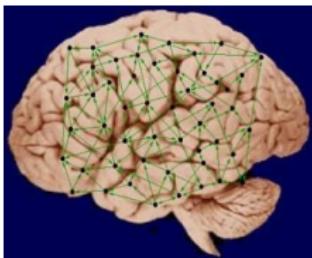
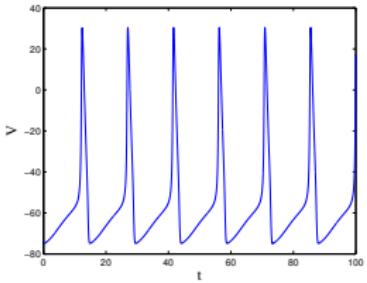
Efektivní
konektivita

Grafové metody

Biologické
neuronové sítě

Závěr

Reference



Fázová redukce modelu

Přelet nad
neurálním
hnízdem

Jaroslav Hlinka

Úvod

Mozek a jeho studium

Funkční
konektivita

Motivation

Strategie

Výsledky

Efektivní
konektivita

Grafové metody

Biologické
neuronové sítě

Závěr

Reference

$$\tau_e \frac{\partial E}{\partial t} = -E + (k_e - \rho_e E) S_e (c_1 E - c_2 I + P), \quad (11)$$

$$\tau_i \frac{\partial I}{\partial t} = -I + (k_i - \rho_i I) S_i (c_3 E - c_4 I + Q). \quad (12)$$

$$\dot{\theta}_i = \frac{1}{T} + \epsilon \sum_j w_{ij} H(\theta_j - \theta_i), \quad i = 1, \dots, N. \quad (13)$$

Stabilita synchronizovaného řešení závisí na $N \times N$ matici $\widehat{\mathcal{H}}$

$$\widehat{\mathcal{H}}_{ij} = H'(0) \left[w_{ij} - \delta_{i,j} \sum_k w_{ik} \right], \quad (14)$$

kde $H'(\theta) = dH(\theta)/d\theta$. Synchronizované řešení je stabilní pokud reálné části všech vlastních hodnot $\widehat{\mathcal{H}}$ jsou negativní.

Úvod

Mozek a jeho studium

Funkční
konektivita

Motivation

Strategie

Výsledky

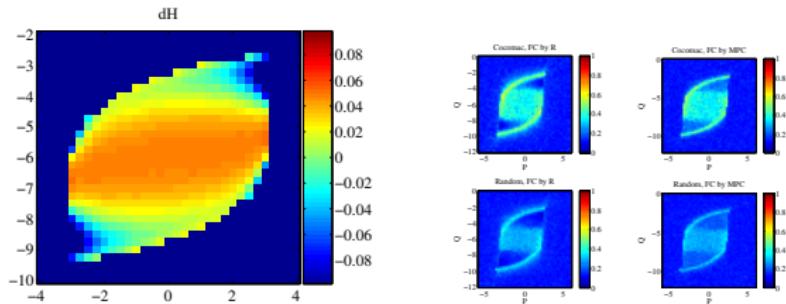
Efektivní
konektivita

Grafové metody

Biologické
neuronové sítě

Závěr

Reference



Úvod

Mozek a jeho studium

Funkční
konektivita

Motivation

Strategie

Výsledky

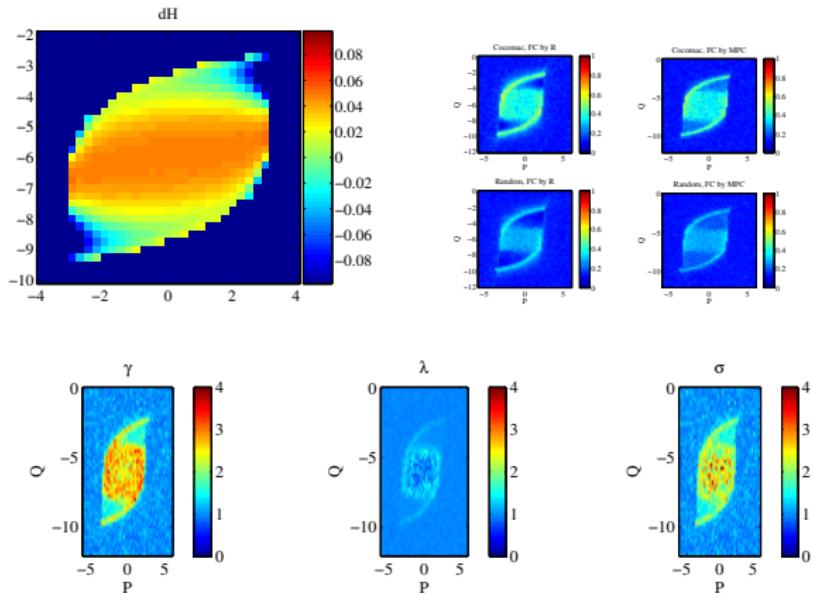
Efektivní
konektivita

Grafové metody

Biologické
neuronové sítě

Závěr

Reference



Úvod

Mozek a jeho studium

Funkční
konektivita

Motivation

Strategie

Výsledky

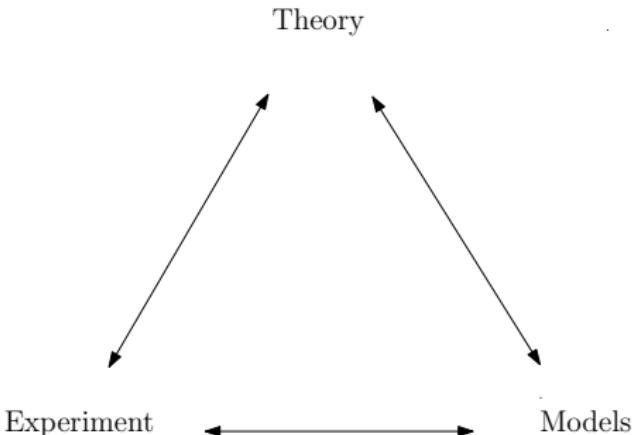
Efektivní
konektivita

Grafové metody

Biologické
neuronové sítě

Závěr

Reference



Stačí lineární korelace pro fMRI?

Přelet nad
neurálním
hnízdem

Jaroslav Hlinka

Úvod

Mozek a jeho studium

Funkční
konektivita

Motivation

Strategie

Výsledky

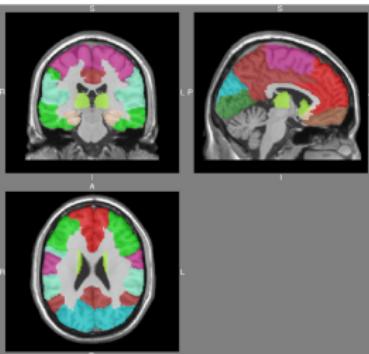
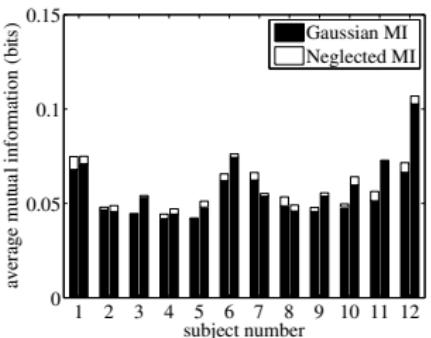
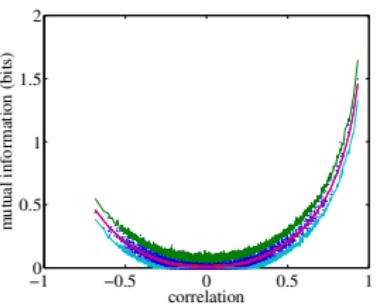
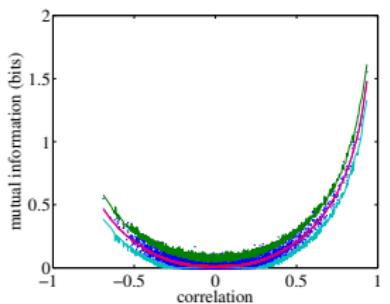
Efektivní
konektivita

Grafové metody

Biologické
neuronové sítě

Závěr

Reference



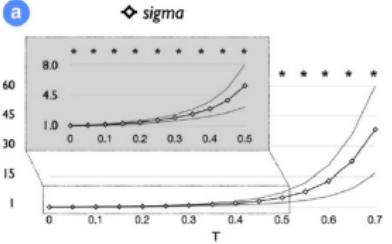
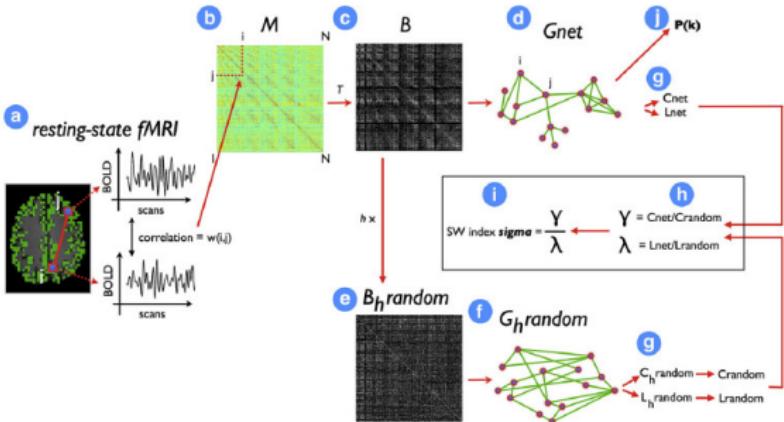
Mozek je malý svět

Přelet nad
neurálním
hnízdem

Jaroslav Hlinka

M.P. van den Heuvel et al. / NeuroImage 43 (2008) 528–539

531



Úvod

Mozek a jeho studium

Funkční
konektivita

Motivation
Strategie
Výsledky

Efektivní
konektivita

Grafové metody

Biologické
neuronové sítě

Závěr

Reference

Velká otázka ohledně $\dot{X}_i = f_i(X_i) + g_i(X)$

Přelet nad
neurálním
hnízdem

Jaroslav Hlinka

Úvod

Mozek a jeho studium

Funkční
konektivita

Motivation

Strategie

Výsledky

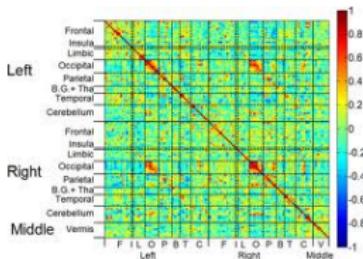
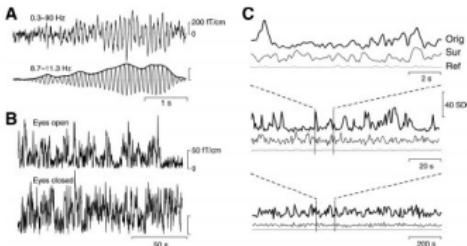
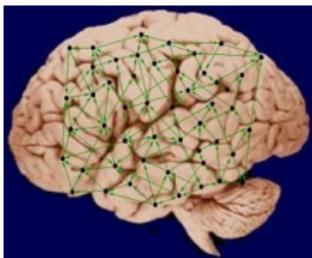
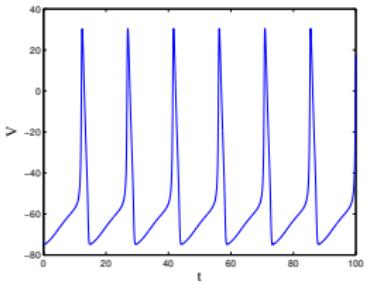
Efektivní
konektivita

Grafové metody

Biologické
neuronové sítě

Závěr

Reference



Úvod
Mozek a jeho studium

Funkční
konektivita
Motivation
Strategie
Výsledky

Efektivní
konektivita

Grafové metody

Biologické
neuronové sítě

Závěr

Reference

Děkuji za pozornost!

References



J. Hlinka, M. Palus, M. Vejmelka, D. Mantini, and M. Corbetta.

Functional connectivity in resting-state fMRI: Is linear correlation sufficient?
NeuroImage, 54:2218–2225, 2011.



A. Kraskov, H. Stogbauer, and P. Grassberger.

Estimating mutual information.

Physical Review E (Statistical, Nonlinear, and Soft Matter Physics), 2004.

<http://ndw.cs.cas.cz/~hlinka>