


Zpracování EEG signálů

CIIRC ČESKÝ INSTITUT INFORMATIKY,
ROBOTIKY A KYBERNETIKY

Václav Gerla

KOGNITIVNÍ SYSTÉMY A NEUROVĚDY


Český institut informatiky robotiky a kybernetiky




Elektroencefalografie (EEG)

CIIRC


- snímáme bioelektrické potenciály na povrchu hlavy související s činností mozku
- výsledný záznam nazýváme elektroencefalogram
- vhodná pro zjištění mozkových onemocnění jako epilepsie, poruchy spánku aj.















- **Elektrokortikografie (ECoG)** neboli intrakraniální elektroencefalografie (iEEG)



Obr. 34




Ostře časově omezené projevy výrazně se lišící od „pozadí“



Polysomnografie (PSG)

CIIRC




Simultánní dlouhodobý záznam více signálů současně v průběhu spánku (EEG, EMG, EOG, a další)

Používá se především při poruchách spánku:

- ❖ Insomnie
- ❖ Hypersomnie
- ❖ Narkolepsie
- ❖ Parasomnie
- ❖ Náměsíčnost
- ❖ Noční můry a děsy
- ❖ Syndrom neklidných nohou
- ❖ Syndrom spánkové apnoe

PSG záznam

CIIRC



WaveFinder –Brainscope (vývoj aplikace: doc. Ing. Vladimír Krajča, CSc.)

<http://www.brainscope.cz/o-systemu/komponenty-systemu/wave-finder/>



Zpracování EEG signálů - Motivace

CIIRC


Motivace - velké objemy EEG dat
(celodenní záznamy, 128/256 kanálové EEG).

Cíle – data vhodně předzpracovat,
k detailnímu posouzení předložit pouze
“zajímavé” části záznamu – **cílem není**
nahradit zkušené oko neurologa,
ale usnadnit mu práci.

Prostředky – výpočetní technika,
metody kvantitativního EEG,
zpracování signálů, rozpoznávání,
metody umělé inteligence.




- decimace




<http://mubeta06.github.io/python/sp/multirate.html>

- aproximace



http://home.etf.rs/~milic/Solution_Manual/Chapter_6_exercises/Chapter_6_exercises.html

- ostatní




např. segmentace + odhad
vybraného parametru pro
každý segment signálu



Odstranění rušení z rozvodné sítě (50/60Hz)

CIIRC


zobrazení filtrace v časové oblasti



a) EEG signál před filtrací





b) EEG signál po filtraci




Odstranění kolísání izolinie

CIIRC




Příklad detekce pohybových artefaktů

- pomocí histogramu je možné automaticky určit mez pro detekci artefaktů (červená přímka na obrázku).
- hodnoty v signálu přesahující tuto mez považujeme za artefakty.




Detekce svalových artefaktů v EEG

CIIRC



Detekce artefaktu způsobeným mrkáním

CIIRC



Segmentace = rozdělení signálu na úseky

Druhy segmentace

- konstantní segmentace
- adaptivní segmentace


Účel segmentace

- EEG signál nelze zpracovávat celý najednou
- EEG signál je obecně nestacionární – segmentací obdržíme po částech stacionární úseky signály, které lze lépe popsat metodami UI


Segmentace signálu (konstantní délka segmentů)

CIIRC


0.1 s




0.5 s




1 s



5 s




10 s



Jak volit délku segmentů pro segmentaci?

Adaptivní segmentace signálu

CIIRC




Příklad dvou různých nastavení segmentace





options.window_size = 0.5 s
options.window_shift = 0.01 s
options.segment_length_min = 0.1 s
options.segment_length_max = 10 s
options.adif = 0.6 %
options.fdif = 0.4 %
options.envelope_filtrconst = 1.2
options.envelope_filtrlength = 5 s
options.envelope_hysteresis = 0.03

options.window_size = 0.1 s



options.window_size = 1 s










Frekvenční příznaky


CIIRC

[iee.org/document/8477618](https://ieeexplore.ieee.org/document/8477618)

Waves	Frequency bands (Hz)	Behaviour Trait	Signal Waveform
Delta	0.3 – 4	Deep sleep	
Theta	4 – 8	Deep Meditation	
Alpha	8 – 13	Eyes closed, awake	
Beta	13 – 30	Eyes opened, thinking	
Gamma	30 and above	Unifying consciousness	

<https://ieeexplore.ieee.org/document/8477618>

Extrakce příznaků z novorozeneckého EEG



A: Sleep profile, as evaluated by an experienced physician.

B: Power Spectral Density computed for all EEG channels.


C: Blue color curve: the heart rate computed from the ECG signal. The red color curve represents the moving average, the window size is 5 minutes.

D: Blue color curve: regularity of respiration. We use autocorrelation analysis of the respiration signal for this. The red color curve represents the moving average, the window size is 5 minutes.


E: Blue color curve: standard deviation of EMG signal normalized to interval $<0,1>$. This feature corresponds to the movements artifact. The red color curve represents the filtered signal (see III.A.4).

F: Eye movements detection. Output signal of an FIR-median-hybrid filter applied to the EOG signal (see III.A.3).

A. Extrakce příznaků




B. Selekcce = výběr nejvhodnější kombinace příznaků




Klasifikace: matematická metoda, kdy vstupní objekty $X(i)$ jsou rozřazovány do tříd podle **podobnosti**

I. Metody klasifikace bez učitele: podoba (a často ani počet tříd) není známa.





II. Metody klasifikace s učitelem – nutným doplňkovým vstupem klasifikátoru je tzv. trénovací množina – množina ukázek objektů jednotlivých klasifikačních tříd.

1. krok - segmentace (rozdělení signálu na úseky konstatní délky)



2. krok - výpočet příznaků

(pro každý segment vypočítáme množinu příznaků)

segment	příznak 1	příznak 2
1 	0,43	7,51
2 	0,84	38,13

segment č. 1 => { 0,43 ; 7,51 }


segment č. 2 => { 0,84 ; 38,13 }

3. krok - vytvoření trénovací množiny


(trénovací množina = množina “ukázek” segmentů pro jednotlivé klasifikační třídy)

Pro náš problém pouze 2 třídy:

- normální aktivita – třída 1




- epileptická aktivita – třída 2



4. krok - klasifikace (nalézt pro každý segment původního signálu co nejpodobnější segment trénovací množiny a přiřadit mu tak třídu)

Zobrazení - normální EEG černě, epileptické červeně




Klasifikace spánkového EEG

CIIRC

1. Wake (bdělost)
2. REM (Rapid Eye Movements) // sny
3. NREM1 (usínání)
4. NREM2 (lehký spánek)
5. NREM3 (hluboký spánek)
6. NREM4 (nejhlubší spánek)

Hypnogram:




1. :

Beta rytmus: bdělý stav



Alfa rytmus: relaxovaný stav



Ospalost delta/theta



Usínání

Spánková vřetena




Spánek

delta




REM spánek

pilovité vlny




Spektrogram dlouhodobého EEG signálu

CIIRC



Analýza spektrogramu spánkového EEG

CIIRC




(Josef Rieger, 2006)

hodnoceno
lékařem

hodnoceno ručně dle
spektrogramu

Klasifikace hloubky kómatu

- signál délky 2 hodin, segmenty po 16 sekund
- trénovací množina – sestavena expertem (5 tříd, 319 segmentů)
- ukázka segmentů trénovací množiny:

segment	třída
	1
	2
	3
	4

- hrubý odhad dlouhodobých trendů:

Motivace, využití

- online monitorování -> odhad zralosti mozku novorozence

Data použitá v této studii:

- data nám poskytl Ústav pro péči o matku a dítě (www.upmd.cz)


Data jsou ohodnoceny do těchto tříd:

- 'quiet sleep'
- 'active sleep'
- 'wake'
- 'movement artefact'




Měření EEG, EOG, EKG a EMG u novorozenců

CIIRC




<https://www.youtube.com/watch?v=05D0YdA5cZY>

Metodika



Extrakce EEG příznaků









- klasifikace získána od lékaře
- délka záznamu = 85 minut

- příznaky založené na PSD
- počítáno pro každou EEG elektrodu
- zde je zobrazeno delta pásmo (0.5 to 3Hz)
- těchto 8 charakteristik používáme pro další zpracování

- příklad klasifikace do dvou tříd

Pravidelnost dýchání:

- charakteristiky pro několik novorozenců
- je problém určit přesný práh, který odděluje 2 různé třídy
- vhodné jako dodatečná informace pro lékaře









Analýza novorozeneckého EEG

CIIRC







EMG aktivita:

- zobrazena svalová aktivita pro několik novorozenců
- problém s detekcí svalové atonie v aktivním spánku



Srdeční tepová frekvence

- křivky srdeční tepové frekvence pro několik novorozenců
- zpravidla nižší tep v klidném spánku
- viditelná velká setrvačnost změny tepu



- cílem je nalézt podobné části EEG signálu
- učení bez učitele
- různé přístupy: k-means, hierarchické shlukování

Různé typy hierarchického shlukování:

- *Single linkage*, also called *nearest neighbor*, uses the smallest distance between objects in the two clusters:

$$d(r, s) = \min(\text{dist}(x_{ri}, x_{sj})), i \in (1, \dots, n_r), j \in (1, \dots, n_s)$$
- *Complete linkage*, also called *furthest neighbor*, uses the largest distance between objects in the two clusters:

$$d(r, s) = \max(\text{dist}(x_{ri}, x_{sj})), i \in (1, \dots, n_r), j \in (1, \dots, n_s)$$
- *Average linkage* uses the average distance between all pairs of objects in any two clusters:

$$d(r, s) = \frac{1}{n_r n_s} \sum_{i=1}^{n_r} \sum_{j=1}^{n_s} \text{dist}(x_{ri}, x_{sj})$$

- *Centroid linkage* uses the Euclidean distance between the centroids of the two clusters:

$$d(r, s) = \|\bar{x}_r - \bar{x}_s\|_2$$

where

$$\bar{x}_r = \frac{1}{n_r} \sum_{i=1}^{n_r} x_{ri}$$

- *Median linkage* uses the Euclidean distance between weighted centroids of the two clusters,


$$d(r, s) = \|\tilde{x}_r - \tilde{x}_s\|_2$$

where $\tilde{x}_r$ and $\tilde{x}_s$ are weighted centroids for the clusters r and s . If cluster r was created by combining clusters p and q , $\tilde{x}_r$ is defined recursively as

$$\tilde{x}_r = \frac{1}{2}(\tilde{x}_p + \tilde{x}_q)$$










- *Ward's linkage* uses the incremental sum of squares; that is, the increase in the total within-cluster sum of squares as a result of joining two clusters. The within-cluster sum of squares is defined as the sum of the squares of the distances between all objects in the cluster and the centroid of the cluster. The equivalent distance is:



$$d^2(r, s) = \frac{n_r n_s}{(n_r + n_s)} \|\bar{x}_r - \bar{x}_s\|_2^2$$



Shlukování – epileptická EEG data



CIIRC






Hierarchické shlukování - Dendrogram


CIIRC



CIIRC



1 bod v grafu = 1 segment PSG signálu




(N = celkový počet všech segmentů)

Jak určíme optimální počet shluků?

- experimentálně jej odhadneme
- provedeme prořezání dendrogramu (na základě vhodného kritéria)


- metody vizualizace umožňují nahlížet na signál diametrálně odlišným způsobem v porovnání s analýzou signálu v časové oblasti
- často jsou data transformována (např. pomocí integrálních transformací - FFT,..) do jiné oblasti, ve které je hledaná informace mnohem lépe viditelná.



Spektrogram dlouhodobého EEG signálu


CIIRC

- spektrogram spánkového EEG délky 8.5 hodiny
- patrná periodická struktura typická pro lidský spánek
- analýza spánkových stádií
- možná analýza poruch spánku apod.



2D a 3D spektrogram

CIIRC




frekvence

čas


čas

frekvence



2D spektrogram: audio-visuální stimulace

CIIRC




0:30-2:40	12Hz
2:40-6:00	8Hz
6:00-8:00	7Hz
8:00-10:00	6Hz
10:00-12:00	5Hz
12:00-14:00	4.5Hz
14:00-16:00	4Hz
16:00-18:00	3.5Hz
18:00-20:00	3Hz
20:00-21:00	2.5Hz
21:00-22:00	2Hz
22:00-23:00	4Hz
23:00-24:00	6Hz
24:00-25:00	7Hz
25:00-27:00	8Hz
27:00-31:58	od 8Hz do 1.5Hz
31:58-33:00	1.5Hz
33:00-34:00	4Hz
34:00-37:00	8Hz
37:00-37:20	pozvolna od 8Hz do 12Hz
37:20	probuzeni



2D spektrogram: více elektrod


CIIRC




2D mapování

CIIRC


00:00 - 00:09




00:10 - 00:19




00:20 - 00:29




00:30 - 00:39



00:40 - 00:49




00:50 - 00:59



01:00 - 01:09



01:10 - 01:19




01:20 - 01:29






01:30 - 01:38






Porovnání různých podmínek měření EEG




- výsledek analýzy zobrazíme barevnou modulací na modelu hlavy
- získáme topografickou představu o distribuci mapované veličiny (např. rozložení celkového výkonu v daném frekvenčním pásmu)







PAT > CON


PAT < CON






- klinický biofeedback
- léčení fobií
- omezení stresu
- sledování pozornosti






<http://openbci.com>



Vstup – rozložení 2D potenciálu na skalpu (EEG signál)


Výstup – 3D rozložení dipólů v objemu mozku



3D rozložení dipólů

DOPŘEDNÝ PROBLÉM

INVERZNÍ PROBLÉM



2D rozložení skalpového potenciálu = EEG


Inverzní problém NEMÁ jednoznačné řešení – nekonečně mnoho 3D konfigurací dipólů může vést ke stejnému EEG.





Hlubková mozková stimulace

CIIRC

Deep Brain Stimulation



Methods/Techniques of Deep Brain Stimulation



Implementace algoritmů pro analýzu EEG v prostředí programu Matlab

buffer

R2018b

Buffer signal vector into matrix of data frames

[collapse all in page](#)

Syntax

```
y = buffer(x,n)
y = buffer(x,n,p)
y = buffer(x,n,p,opt)
[y,z] = buffer(...)
[y,z,opt] = buffer(...)
```

Description

`y = buffer(x,n)` partitions a length- L signal vector x into nonoverlapping data segments (frames) of length n . Each data frame occupies one column of matrix output y , which has n rows and $\text{ceil}(L/n)$ columns. If L is not evenly divisible by n , the last column is zero-padded to length n .

`y = buffer(x,n,p)` overlaps or underlaps successive frames in the output matrix by p samples:

- For $0 < p < n$ (overlap), `buffer` repeats the final p samples of each frame at the beginning of the following frame. For example, if $x = 1:30$ and $n = 7$, an overlap of $p = 3$ looks like this.

$y =$

0	2	6	10	14	18	22	26
0	3	7	11	15	19	23	27
0	4	8	12	16	20	24	28
1	5	9	13	17	21	25	29
2	6	10	14	18	22	26	30
3	7	11	15	19	23	27	0
4	8	12	16	20	24	28	0

The first frame starts with p zeros (the default initial condition), and the number of columns in y is $\text{ceil}(L/(n-p))$.

- EEG signál x rozdělíme na segmenty délky n .

- Každý sloupec v matici y je jeden segment EEG signálu x .

- Takto můžeme celý signál zpracovávat najednou (v Matlabu výhodné, protože to je velmi rychlé).

Překrývající se segmenty

<https://se.mathworks.com/help/signal/ref/buffer.html>

Extrakce frekvenčních příznaků

CIIRC

Nutno spustit zvlášť pro každé EEG pásmo.

bandpower

R2018b

Band power

[collapse all in page](#)

Syntax

```
p = bandpower(x)
p = bandpower(x,fs,freqrange)

p = bandpower(pxx,f,'psd')
p = bandpower(pxx,f,freqrange,'psd')
```

Např. [4 8] pro pásmo 4-8Hz

Description

`p = bandpower(x)` returns the average power in the input signal, `x`. If `x` is a matrix, then `bandpower` computes the average power in each column independently. [example](#)

`p = bandpower(x,fs,freqrange)` returns the average power in the frequency range, `freqrange`, specified as a two-element vector. You must input the sample rate, `fs`, to return the power in a specified frequency range. `bandpower` uses a modified periodogram to determine the average power in `freqrange`. [example](#)

`p = bandpower(pxx,f,'psd')` returns the average power computed by integrating the power spectral density (PSD) estimate, `pxx`. The integral is approximated by the rectangle method. The input, `f`, is a vector of frequencies corresponding to the PSD estimates in `pxx`. The `'psd'` option indicates that the input is a PSD estimate and not time series data. [example](#)

`p = bandpower(pxx,f,freqrange,'psd')` returns the average power contained in the frequency interval, `freqrange`. If the frequencies in `freqrange` do not match values in `f`, the closest values are used. The average power is computed by integrating the power spectral density (PSD) estimate, `pxx`. The integral is approximated by the rectangle method. The `'psd'` option indicates the input is a PSD estimate and not time series data. [example](#)

<https://se.mathworks.com/help/signal/ref/bandpower.html>

Další příznaky

Základní příznaky

- `min(data_buffered)`
- `max(data_buffered)`
- `mean(data_buffered)`
- `std(data_buffered)`

Šikmost a špičatost signálu

- `skewness(data_buffered)`
- `kurtosis(data_buffered)`

Shannonova entropie

- `ent = wentropy(x, 'shannon')`

Další složitější příznaky

- Fraktální dimenze
- Korelace a autokorelace
- Koeficienty Waveletovy transformace
- EEG Koherence

Např. K-means algoritmus

kmeans

R2018b*k*-means clustering[collapse all in page](#)

Syntax

```
idx = kmeans(X,k)
idx = kmeans(X,k,Name,Value)
[idx,C] = kmeans(___)
[idx,C,sumd] = kmeans(___)
[idx,C,sumd,D] = kmeans(___)

```

X zde představuje matici s příznaky
(řádky jsou segmenty, sloupce jsou
jednotlivé příznaky)
k je počet shluků

Description

`idx = kmeans(X,k)` performs *k*-means clustering to partition the observations of the *n*-by-*p* data matrix *X* into *k* clusters, and returns an *n*-by-1 vector (*idx*) containing cluster indices of each observation. Rows of *X* correspond to points and columns correspond to variables.

[example](#)

By default, `kmeans` uses the squared Euclidean distance metric and the *k*-means++ algorithm for cluster center initialization.

`idx = kmeans(X,k,Name,Value)` returns the cluster indices with additional options specified by one or more *Name,Value* pair arguments.

[example](#)

For example, specify the cosine distance, the number of times to repeat the clustering using new initial values, or to use parallel computing.

`[idx,C] = kmeans(___)` returns the *k* cluster centroid locations in the *k*-by-*p* matrix *C*.

[example](#)

`[idx,C,sumd] = kmeans(___)` returns the within-cluster sums of point-to-centroid distances in the *k*-by-1 vector *sumd*.

[example](#)


`[idx,C,sumd,D] = kmeans(___)` returns distances from each point to every centroid in the *n*-by-*k* matrix *D*.

[example](#)

<https://se.mathworks.com/help/stats/kmeans.html>

Shluková analýza - ukázka

Počet příznaků = 2 (na obrázku osa x a y), hledáme 2 shluky



linkage

R2018b

Agglomerative hierarchical cluster tree

[collapse all in page](#)

Syntax

```
Z = linkage(X)
Z = linkage(X,method)
Z = linkage(X,method,metric)
Z = linkage(X,method,metric,'savememory',value)

Z = linkage(X,method,pdist_inputs)

Z = linkage(y)
Z = linkage(y,method)
```

X zde představuje matici s příznaky
(řádky jsou segmenty, sloupce jsou
jednotlivé příznaky)
// Segm. metoda např. 'ward'

Description

Z = `linkage(X)` returns a matrix **Z** that encodes a tree containing hierarchical clusters of the rows of the input data matrix **X**.

Z = `linkage(X,method)` creates the tree using the specified `method`, which describes how to measure the distance between clusters. For more information, see [Linkages](#).

[example](#)

Z = `linkage(X,method,metric)` performs clustering by passing `metric` to the `pdist` function, which computes the distance between the rows of **X**.

[example](#)

Z = `linkage(X,method,metric,'savememory',value)` uses a memory-saving algorithm when `value` is 'on', and uses the standard algorithm when `value` is 'off'.

[example](#)

Z = `linkage(X,method,pdist_inputs)` passes `pdist_inputs` to the `pdist` function, which computes the distance between the rows of **X**. The `pdist_inputs` argument consists of the 'seuclidean', 'minkowski', or 'mahalanobis' metric and an additional distance metric option.

[example](#)

Z = `linkage(y)` uses a vector representation **y** of a distance matrix. **y** is either computed by `pdist` or is a more general dissimilarity matrix conforming to the output format of `pdist`.

Z = `linkage(y,method)` creates the tree using the specified `method`, which describes how to measure the distance between clusters.

[example](#)

Shluková analýza - ukázka

CIIRC

Examples

[collapse all](#)

Cluster Data and Plot Result

Randomly generate sample data with 20,000 observations.

[Try This Example](#)


```
rng('default') % For reproducibility
X = rand(20000,3);
```

Create a hierarchical cluster tree using Ward's linkage. In this case, 'savememory' is set to 'on' by default. In general, choose the best value for 'savememory' based on the dimensions of X and the available memory.

```
Z = linkage(X,'ward');
```

Cluster data into four groups and plot the result.

```
c = cluster(Z,'Maxclust',4);
scatter3(X(:,1),X(:,2),X(:,3),10,c)
```



Shluková analýza - ukázka

CIIRC

Compare cluster assignments of flowers to their species classification.

Load the sample data.

[Try This Example](#)


```
load fisheriris
```

Compute three clusters of the Fisher iris data using the 'average' method and the 'chebychev' metric.

```
Z = linkage(meas,'average','chebychev');  
c = cluster(Z,'maxclust',3);
```

Create a dendrogram plot of Z. To see the three clusters, use 'ColorThreshold' with a cutoff halfway between the third-from-last and second-from-last linkages.

```
cutoff = median([Z(end-2,3) Z(end-1,3)]);  
dendrogram(Z,'ColorThreshold',cutoff)
```



Výpočet spektrogramu

spectrogram

R2018b

Spectrogram using short-time Fourier transform

[collapse all in page](#)

Syntax

```
s = spectrogram(x)
s = spectrogram(x,window)
s = spectrogram(x,window,noverlap)
s = spectrogram(x,window,noverlap,nfft)

[s,w,t] = spectrogram(___)
[s,f,t] = spectrogram(___,fs)

[s,w,t] = spectrogram(x,window,noverlap,w)
[s,f,t] = spectrogram(x,window,noverlap,f,fs)

[___,ps] = spectrogram(___)

[___] = spectrogram(___, 'reassigned')
[___,ps,fc,tc] = spectrogram(___)

[___] = spectrogram(___,freqrange)
[___] = spectrogram(___,spectrumtype)
[___] = spectrogram(___, 'MinThreshold',thresh)

spectrogram(___)
spectrogram(___,freqloc)
```

Poté vykreslit funkcí
imagesc(t, f, s)

<https://se.mathworks.com/help/signal/ref/spectrogram.html>

EEGLAB

Interactive Matlab toolbox for processing continuous and event-related EEG, MEG and other electrophysiological data incorporating independent component analysis (ICA), time/frequency analysis, artifact rejection, event-related statistics, and several useful modes of visualization of the averaged and single-trial data. EEGLAB runs under Linux, Unix, Windows, and Mac OS X.

<https://sccn.ucsd.edu/eeglab/index.php>

