

Předzpracování řeči, tvorba řeči, cepstrum

Jan Černocký cernocky@fit.vutbr.cz

FIT VUT Brno

Plán

- Parametrizace řeči
 - Předzpracování
 - základní parametry: krátkodobá energie, průchody nulou.
- Tvorba řeči a její signálový model.
- Spektrogram
- Oddělení buzení a modifikace – cepstrum
- Přiblížení cepstra lidskému slyšení – MFCC.

PARAMETRIZACE

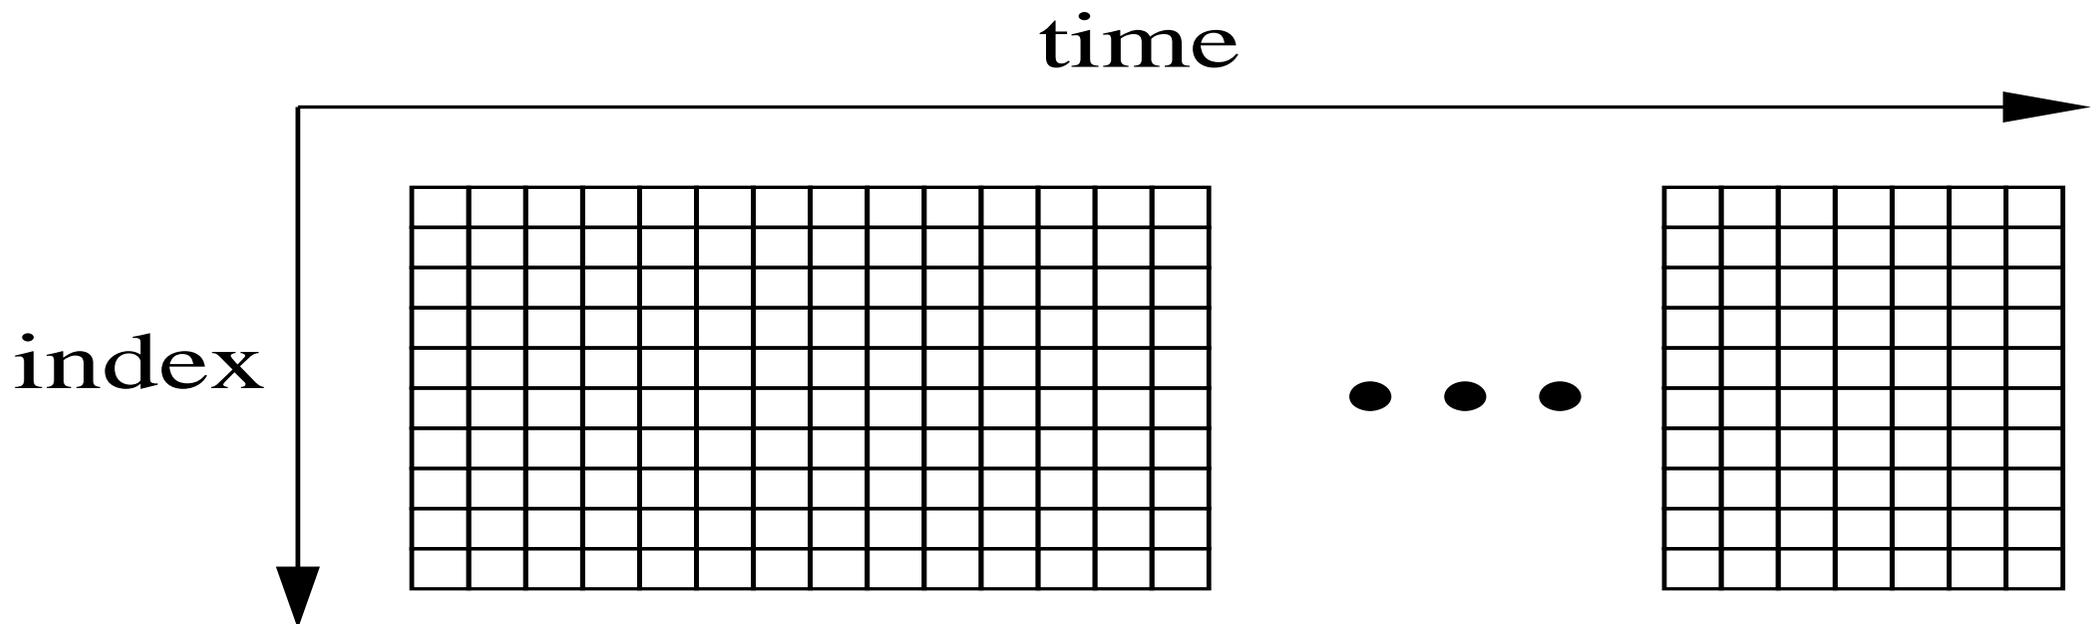
- Úkol: vyjádřit řečový signál omezeným množstvím hodnot – “parametrizace”, “feature extraction”.
- a) Popis založen pouze na poznacích o zpracování signálu (banky filtrů, Fourierova transformace, atd.) \Rightarrow *neparametrický popis*.
- b) Popis založen na poznacích o tvorbě řeči \Rightarrow *parametrický popis*.

ALE:

- b) používá mnoho technik neparametrického popisu, takže tyto dvě skupiny není snadné (a někdy ani žádoucí) oddělit.
- Vypočtené hodnoty stejně vždy nazýváme *parametry*.

Parametry

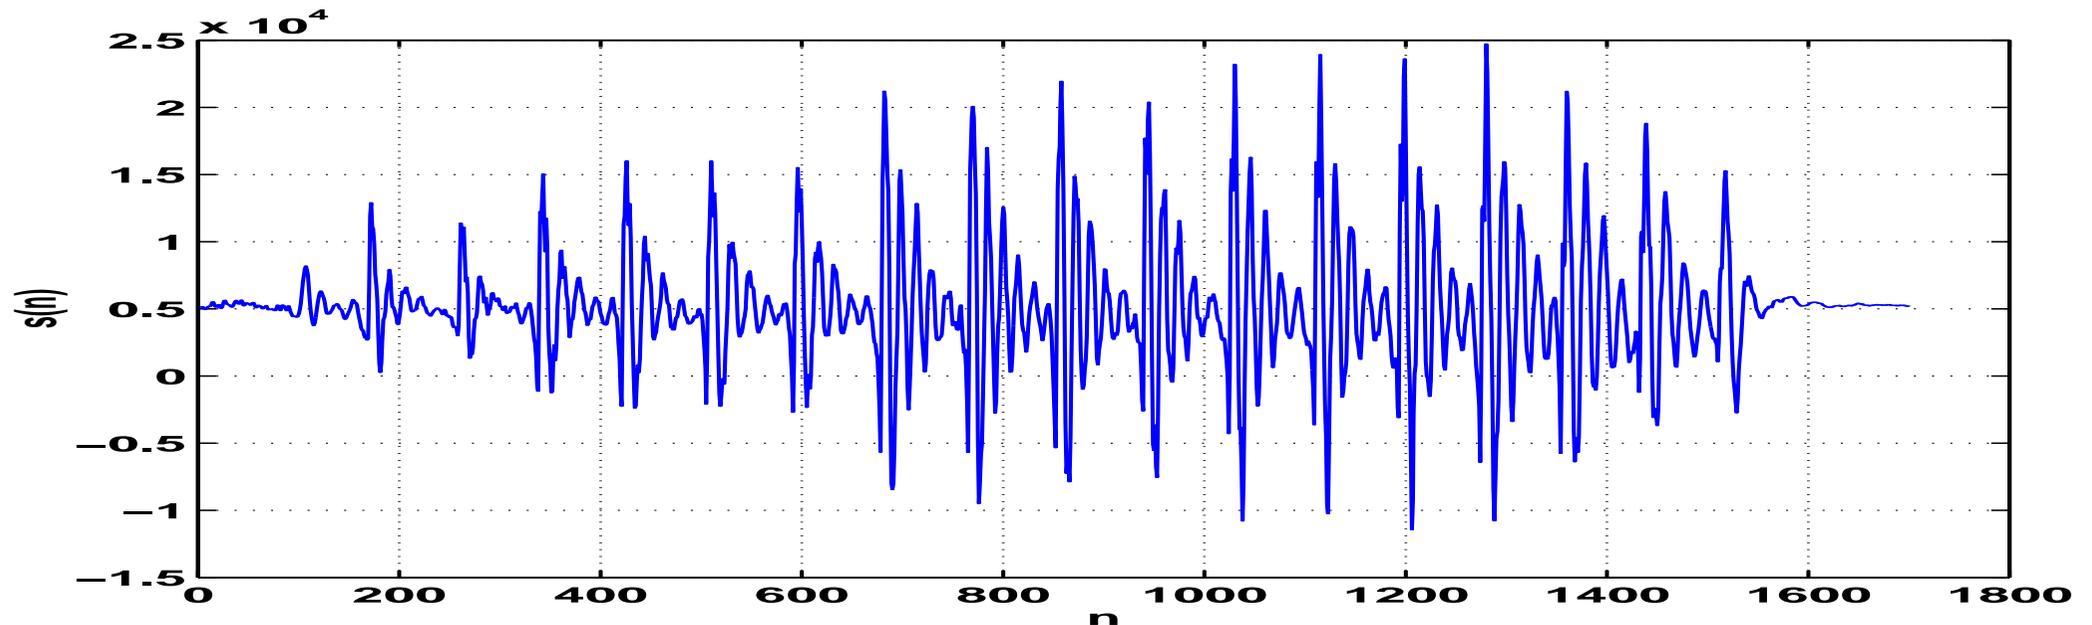
- **skalární** – jedno číslo na řečový úsek (krátkodobá energie nebo počet průchodů nulou).
- **vektorové** – sada čísel (vektor) na řečový úsek. Pokud více řečových úseků, řadíme vektorové hodnoty do *matic*.



PŘEDZPRACOVÁNÍ (pre-processing)

Ustřednění

Stejnosečná složka (dc-offset) – nese žádnou užitečnou informaci, naopak může být pro další zpracování rušivá (např. výpočet energie).



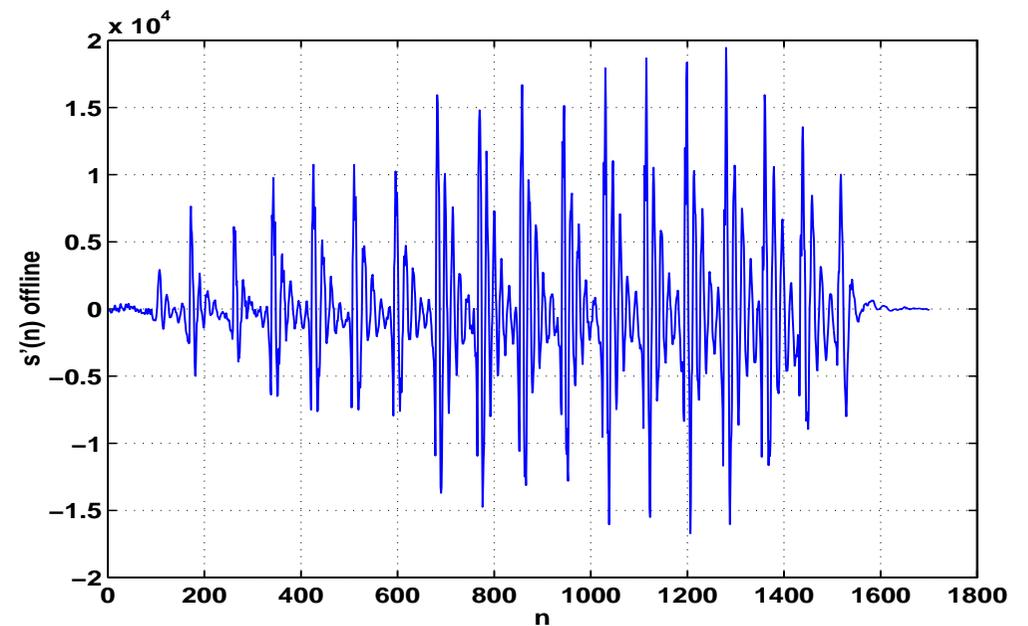
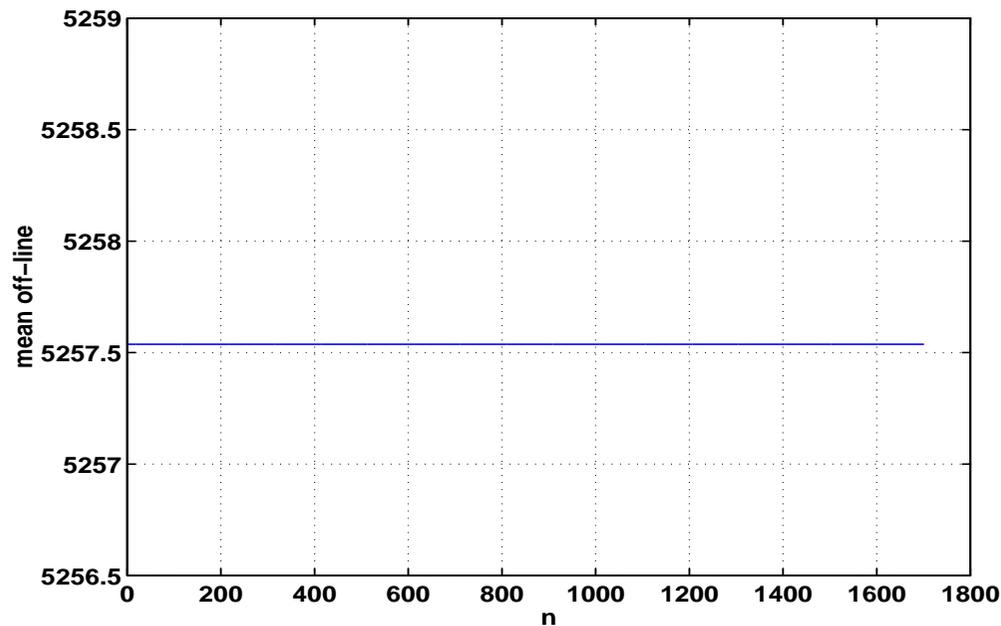
PRYČ S NÍ ! (dc-offset removal)

$$s'[n] = s[n] - \mu_s, \quad \mu_s \text{ musíme odhadnout.} \quad (1)$$

Střední hodnota off-line

v pohodě — každý umí spočítat průměr:

$$\bar{s} = \frac{1}{N} \sum_{n=1}^N s[n] \quad (2)$$



Střední hodnota on-line

Nemáme k dispozici celý signál: je příliš dlouhý, nebo neustále “přibývá”.

$$\bar{s}[n] = \gamma \bar{s}[n-1] + (1-\gamma)s[n], \quad (3)$$

kde $\gamma \rightarrow 1$. To je ekvivalentní filtraci signálu filtrem s impulsní odezvou:

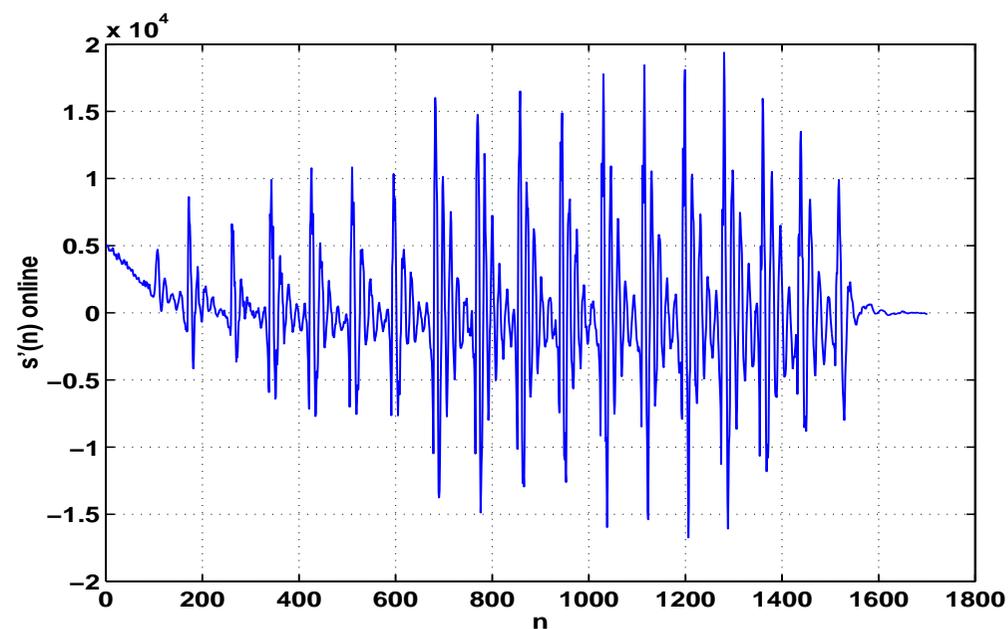
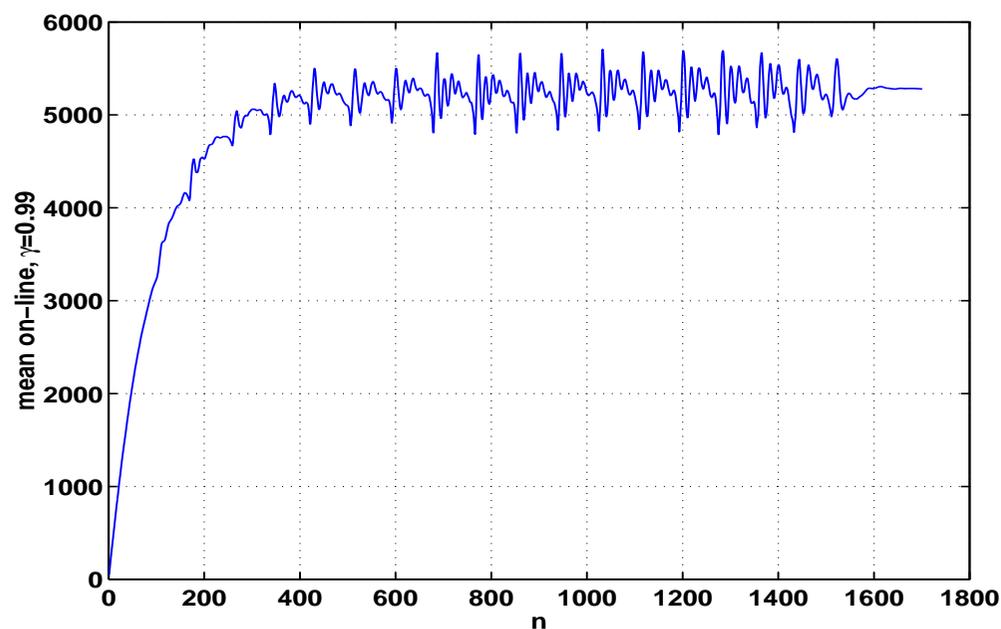
$$h = [(1-\gamma) \quad (1-\gamma)\gamma \quad (1-\gamma)\gamma^2 \quad \dots]. \quad (4)$$

Je to geometrická posloupnost: počáteční člen $a_0 = 1 - \gamma$ a kvocient $q = \gamma$. Její součet je tedy:

$$\sum_{n=0}^{\infty} h[n] = \frac{a_0}{1-q} = \frac{1-\gamma}{1-\gamma} = 1, \quad (5)$$

(to jsme u výrazu počítajícího střední hodnotu očekávali ☺).

Příklad pro $\gamma = 0.99$ (viz také první počítačová labina):



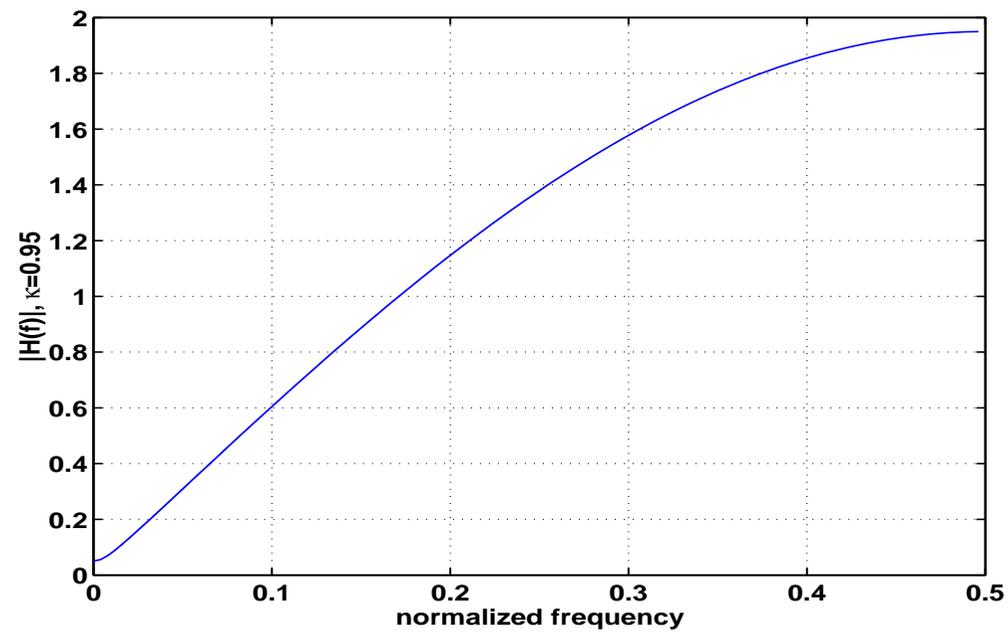
Preemfáze

Vyrovnnání kmitočtové charakteristiky řeči (energie klesá směrem k vyšším frekvencím).
Spíše historická operace.

Jednoduchý FIR filtr prvního řádu:

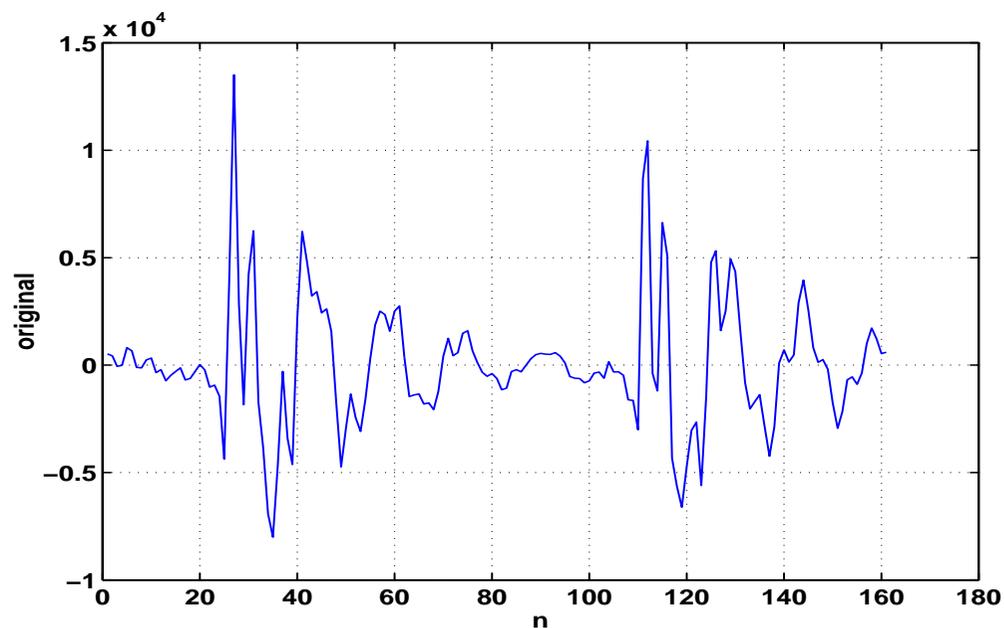
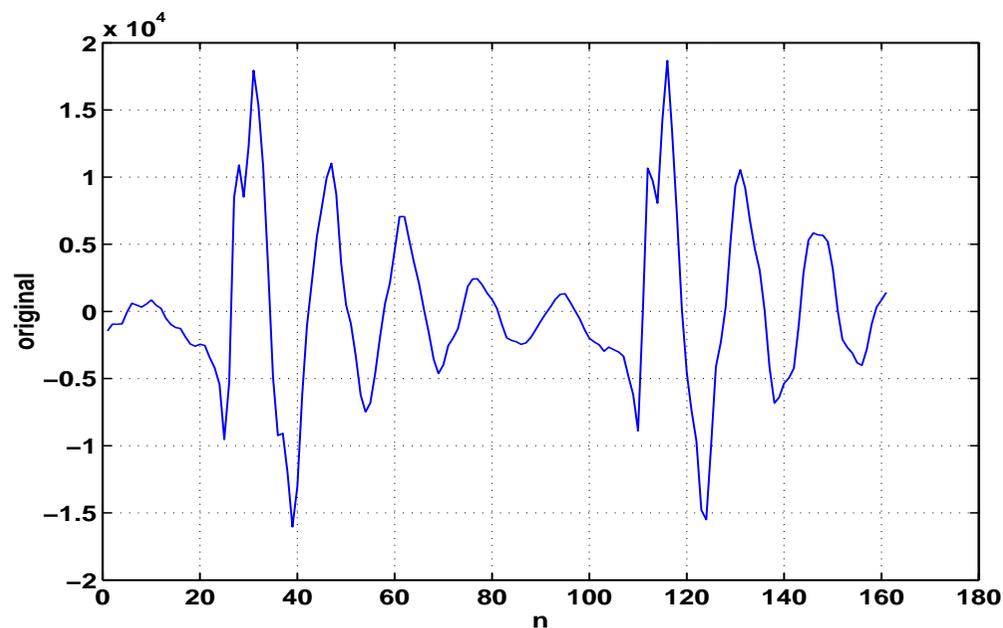
$$H(z) = 1 - \kappa z^{-1}, \quad (6)$$

kde $\kappa \in [0.9, 1]$. Tedy něco jako rozdíl dvou sousedních vzorků. Modulová frekvenční charakteristika pro $\kappa=0.95$:



Filtrace tímto filtrem:

$$s'[n] = s[n] - \kappa s[n - 1] \quad (7)$$



⇒ Preemfázovaný průběh je “kostrbatější” a má více “ostrých hran” – více vyšších frekvencí.

RÁMCE

- Proč ?
- Řečový signál považujeme za *náhodný*, pro metody odhadu parametrů by měl být *stacionární*.
- Jenže není \Rightarrow dělení na kratší úseky (segmenty, mikrosegmenty, frames). Tam stacionární bude nebo budeme doufat, že bude. . . .
- Parametry rámců: délka (length) l_{ram} , překrytí (overlap) p_{ram} , posun rámce (frame shift) $s_{ram} = l_{ram} - p_{ram}$.

Délka

1. dostatečně *malá*, aby bylo možné pokládat signál na daném úseku za stacionární.
2. ALE: dostatečně *velká*, aby bylo možné dostatečně přesně odhadnout požadované parametry.

\Rightarrow kompromis (setrvačnost hlasového ústrojí), typická délka 20–25 ms (160–200 vzorků pro $F_s = 8000$ Hz).

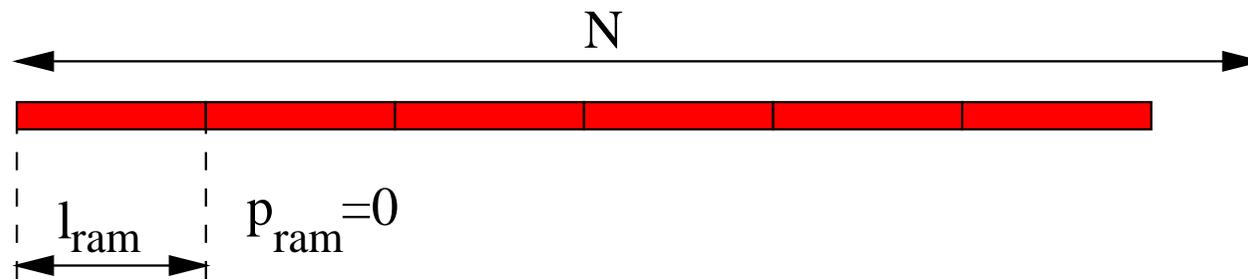
Překrytí

- **malé nebo žádné:** 😊 rychlý časový posun v signálu, malé nároky na paměť/procesor, 😞 hodnoty parametrů se od jednoho rámce ke druhému mohou hodně měnit.
- **velké:** 😊 pomalý časový posuv, “vyhlazené” průběhy parametrů, 😞 velké nároky na paměť/procesor, velmi podobné parametry (porušují požadavek nezávislosti!).

⇒ kompromis, typická délka 10 ms, tedy 100 rámců za vteřinu, centi-second vectors.

Kolik rámců pro řečový signál o délce N ?

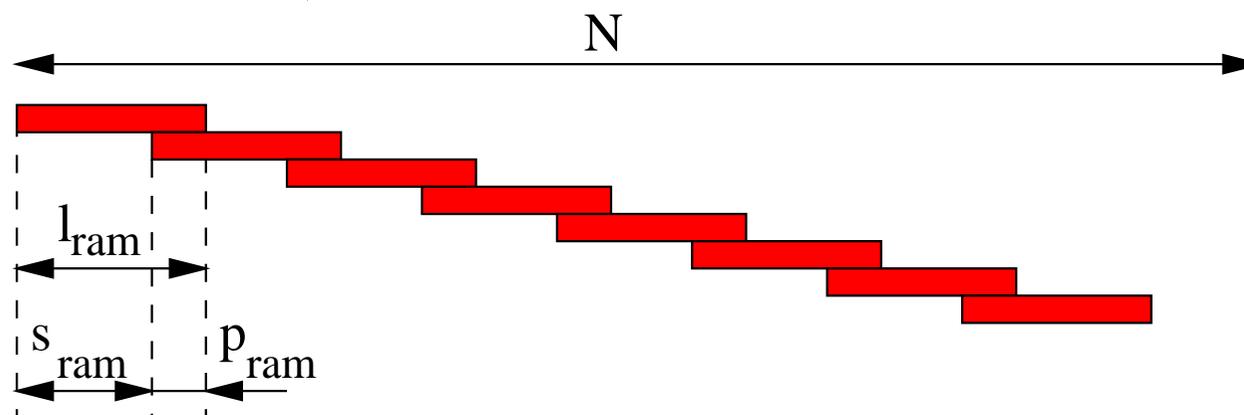
Rámce bez překrývání, $p_{ram} = 0$



$$N_{ram} = \left\lfloor \frac{N}{l_{ram}} \right\rfloor, \quad (8)$$

... operace $\lfloor \cdot \rfloor$ značí zaokrouhlování dolů (floor).

Rámce s překrýváním, $p_{ram} \neq 0$



$$N_{ram} = 1 + \left\lfloor \frac{N - l_{ram}}{s_{ram}} \right\rfloor \quad (9)$$

... pokud je signál alespoň jeden rámeček dlouhý.

Výběr signálu do rámců - okénkové funkce

Při “vykrojení” rámce je použito “okno” - window(ing) function:

Pravoúhlé (rectangular) – se signálem neudělá nic:

$$w[n] = \begin{cases} 1 & \text{pro } 0 \leq n \leq l_{ram} - 1 \\ 0 & \text{jinde} \end{cases} \quad (10)$$

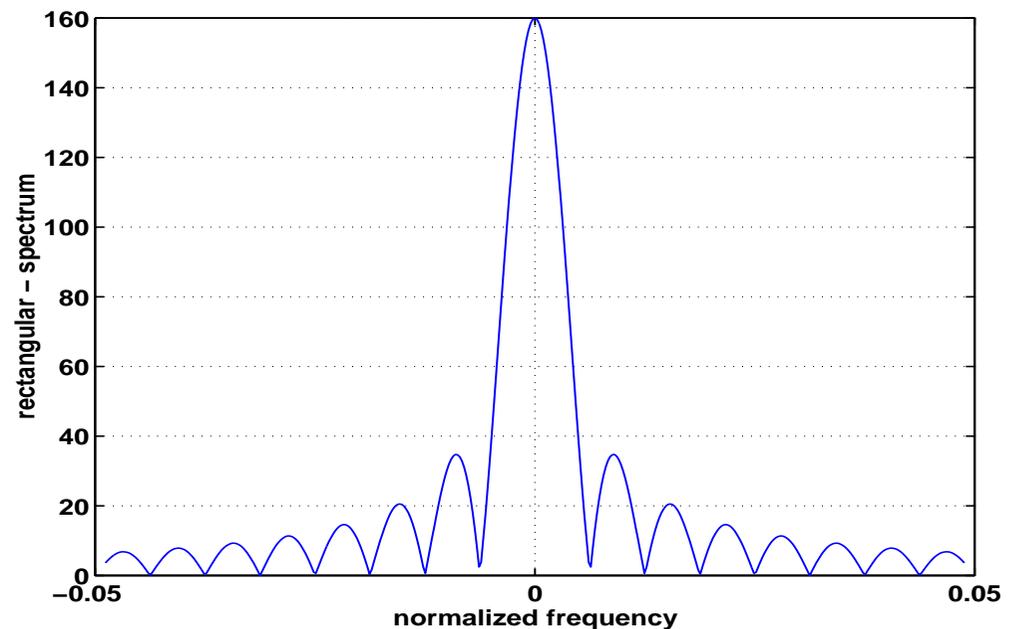
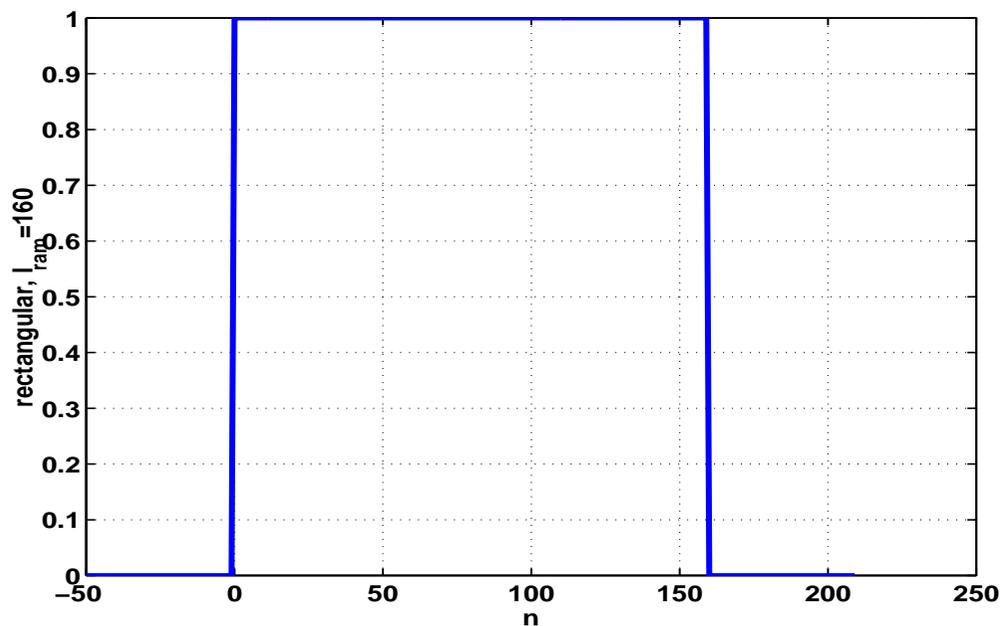
Hammingovo – utlumení signálu na okrajích:

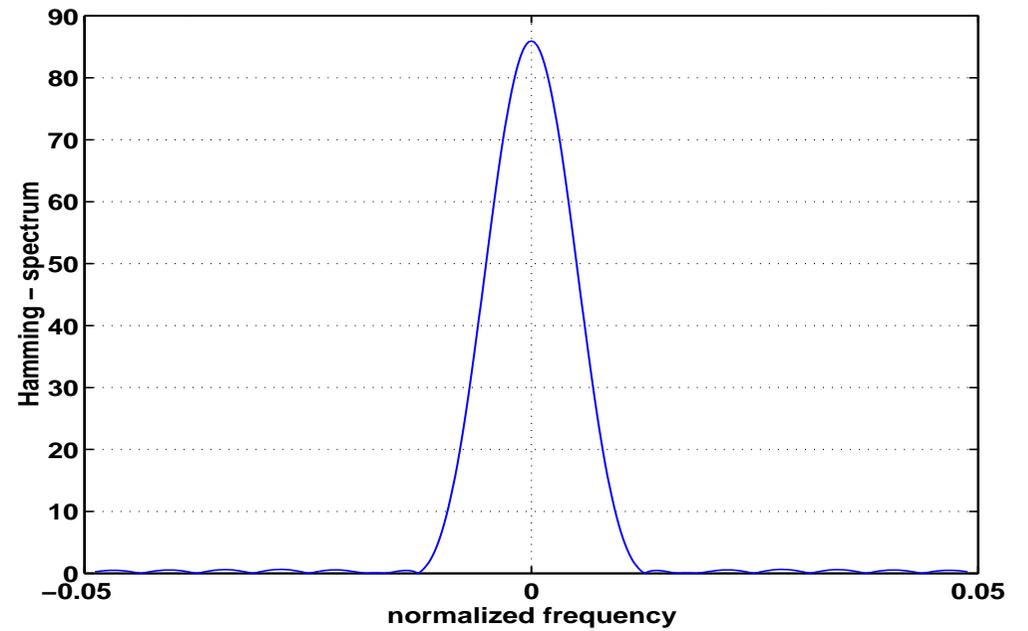
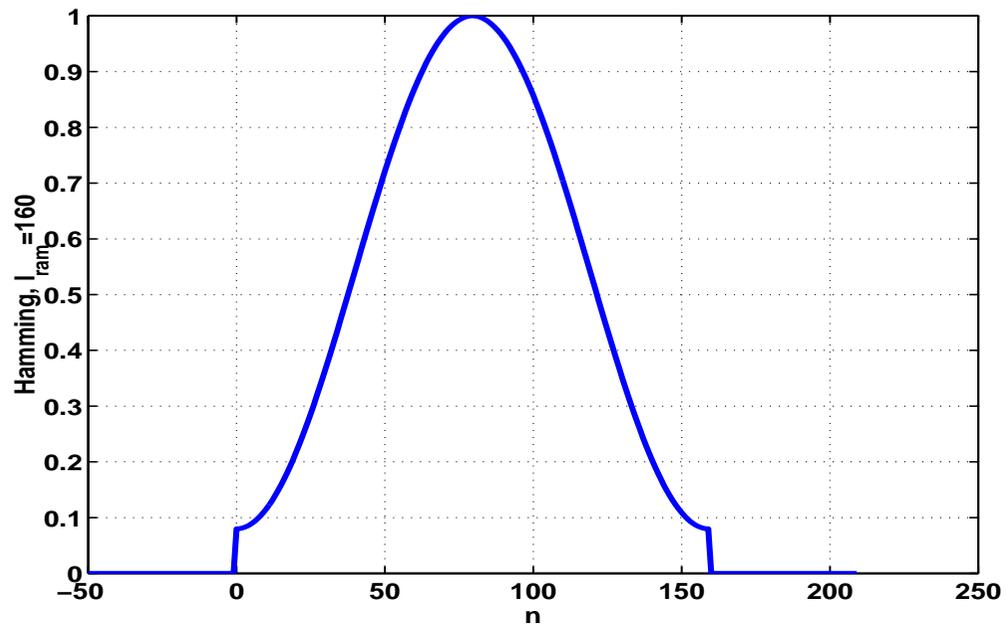
$$w[n] = \begin{cases} 0.54 - 0.46 \cos \frac{2\pi n}{l_{ram} - 1} & \text{pro } 0 \leq n \leq l_{ram} - 1 \\ 0 & \text{jinde} \end{cases} \quad (11)$$

Jak změní okno spektrum vykusovaného signálu ? Násobení signálu oknem v časové oblasti odpovídá *konvoluce* spektra řeči se spektrem okna:

$$X(f) = S(f) \star W(f) \quad (12)$$

Srovnání pravoúhlého a Hammingova:





ZÁKLADNÍ PARAMETRY ŘEČOVÉHO SIGNÁLU

všechny budeme odvozovat na jednotlivých rámcích. Pro všechny rámce:

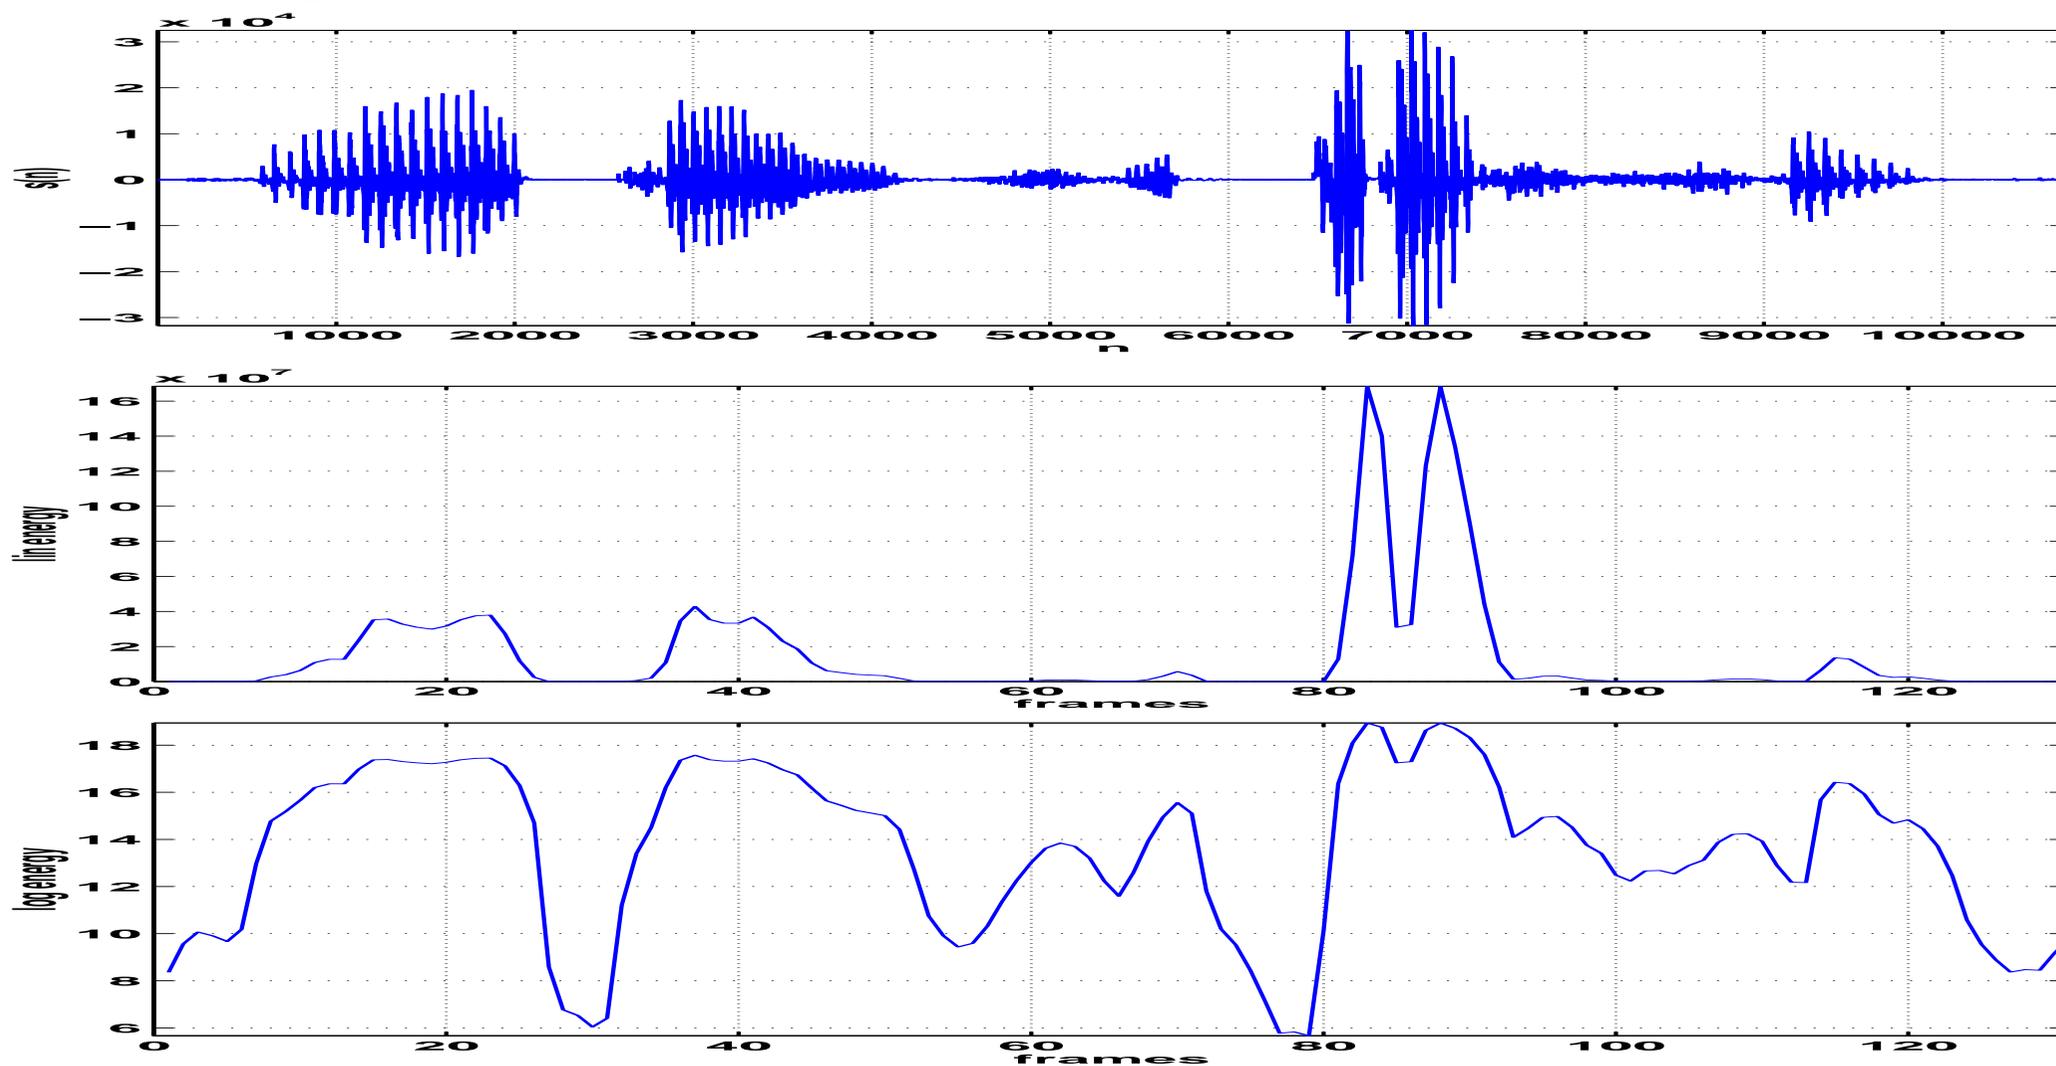
- skalární \Rightarrow jeden řádkový vektor.
- vektorové \Rightarrow matice, svisle index, vodorovně (hrubý) čas.

Střední krátkodobá energie

$$E = \frac{1}{l_{ram}} \sum_{n=0}^{l_{ram}-1} x^2[n] \quad (13)$$

- detektor řečové aktivity.
- rozlišení hlásek na znělé (vysoká energie) a neznělé (nízká).
- často log-energie.
- pozor na šum a na nízkoenergetické hlásky.

Příklad: “létající prase”



Počet průchodů nulou (zero-crossing rate)

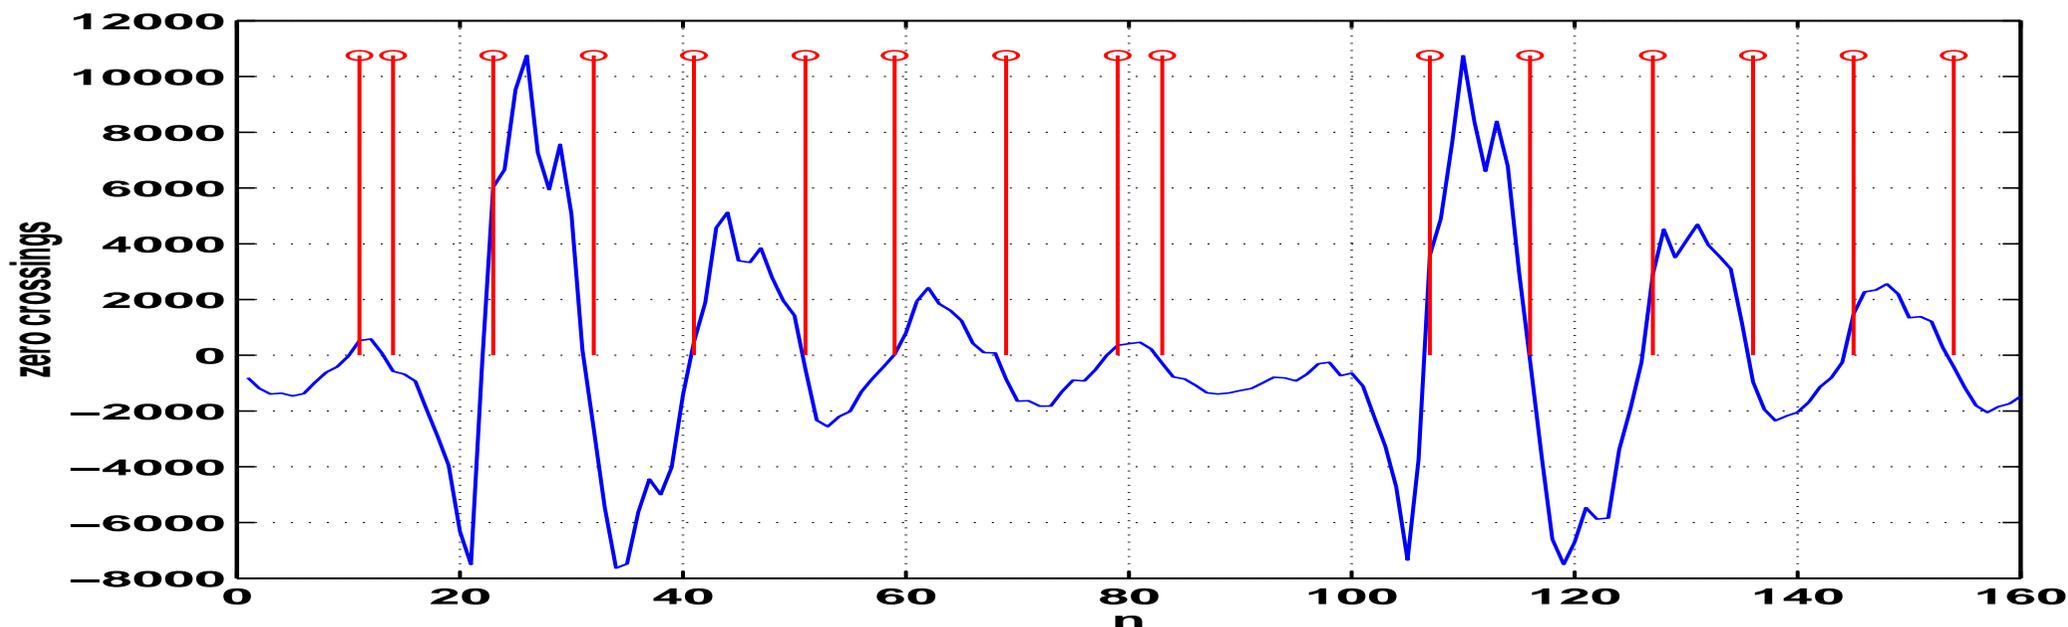
... kolikrát za rámeček proleze signál nulou.

$$Z = \frac{1}{2} \sum_{n=1}^{l_{ram}-1} |\text{sign } x[n] - \text{sign } x[n-1]|, \quad (14)$$

kde $\text{sign}(x)$ je zjednodušená znaménková funkce:

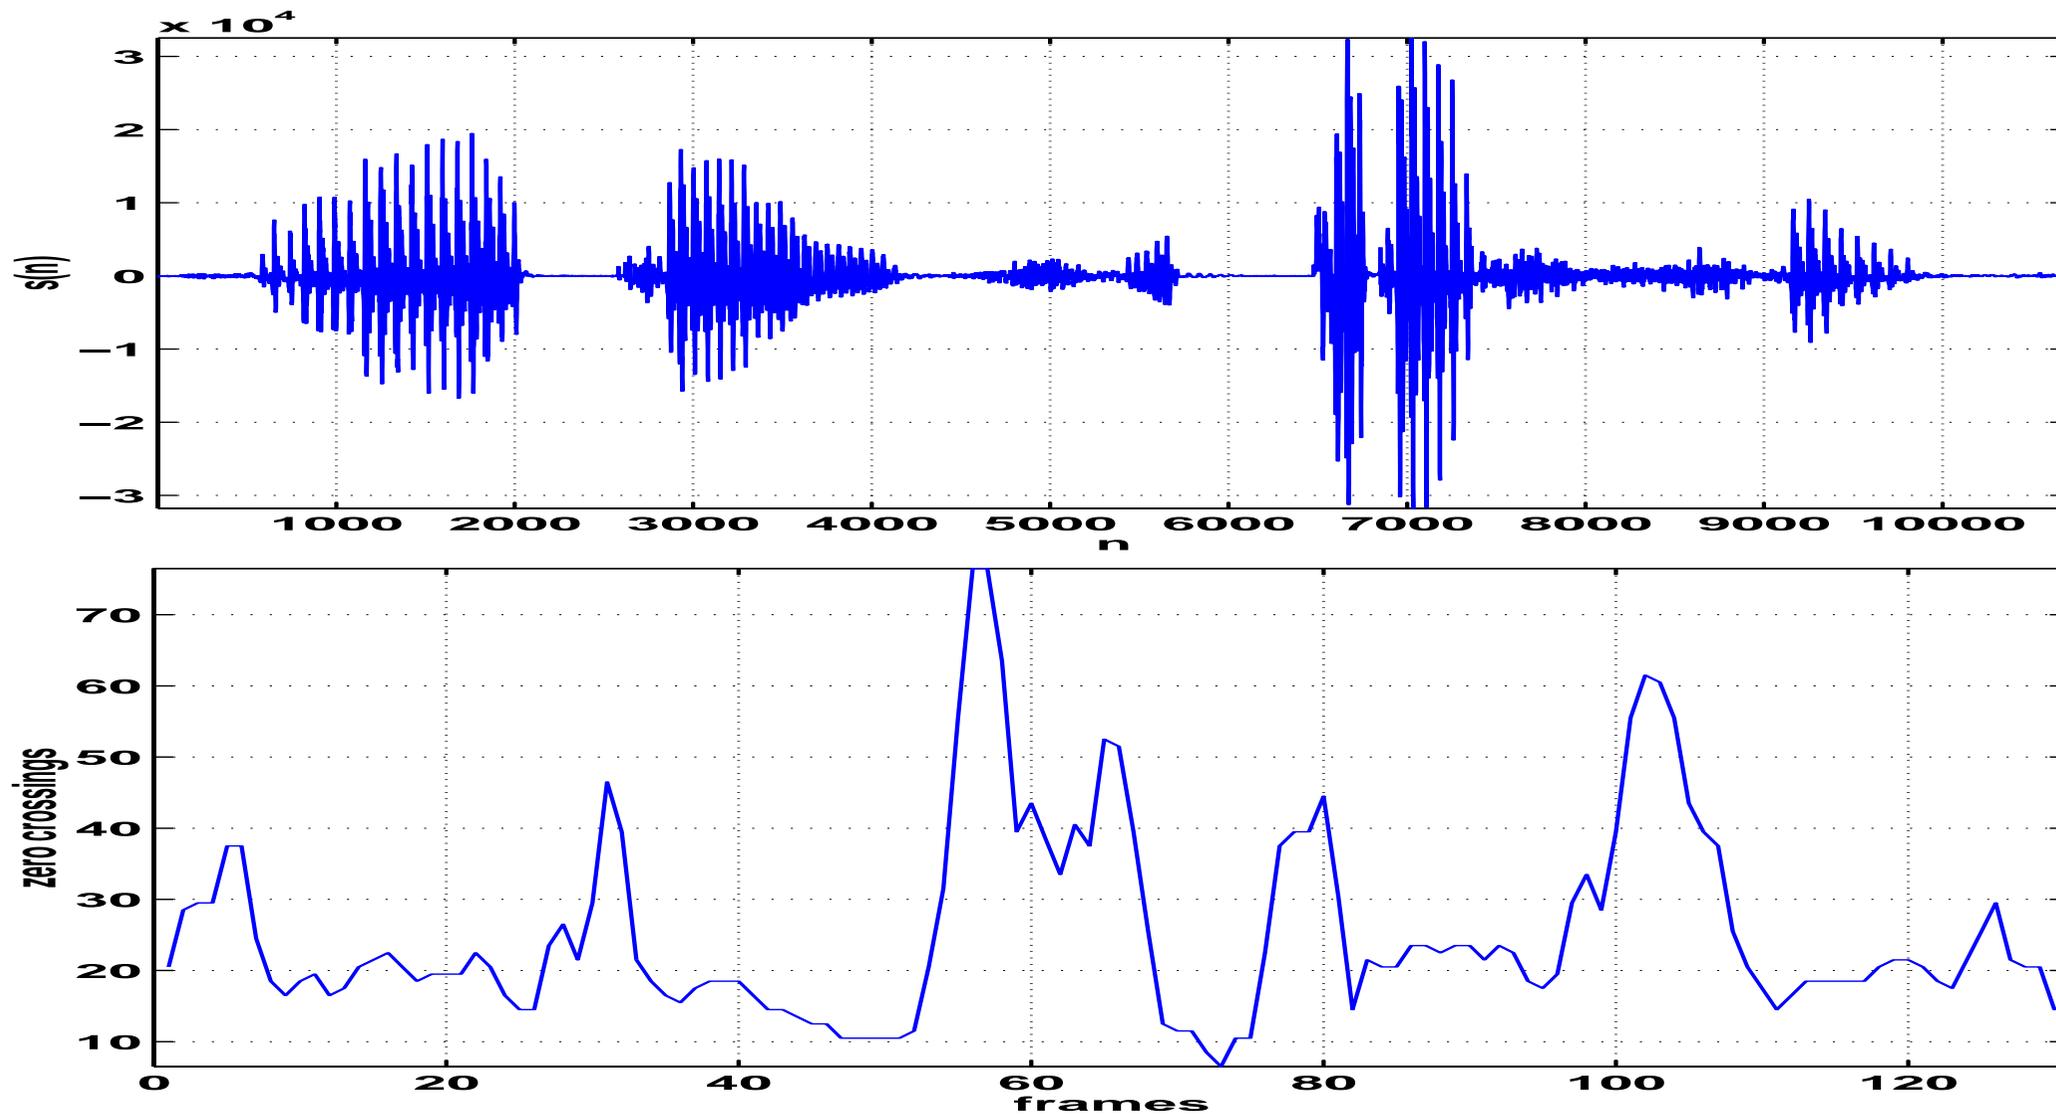
$$\text{sign } x[n] = \begin{cases} +1 & \text{pro } x[n] \geq 0 \\ -1 & \text{pro } x[n] < 0 \end{cases} \quad (15)$$

Jak to funguje? Funkce $|\text{sign } x[n] - \text{sign } x[n-1]|$ dává hodnotu 2 pro každý případ, že se od vzorku $x[n-1]$ ke vzorku $x[n]$ změní znaménko:



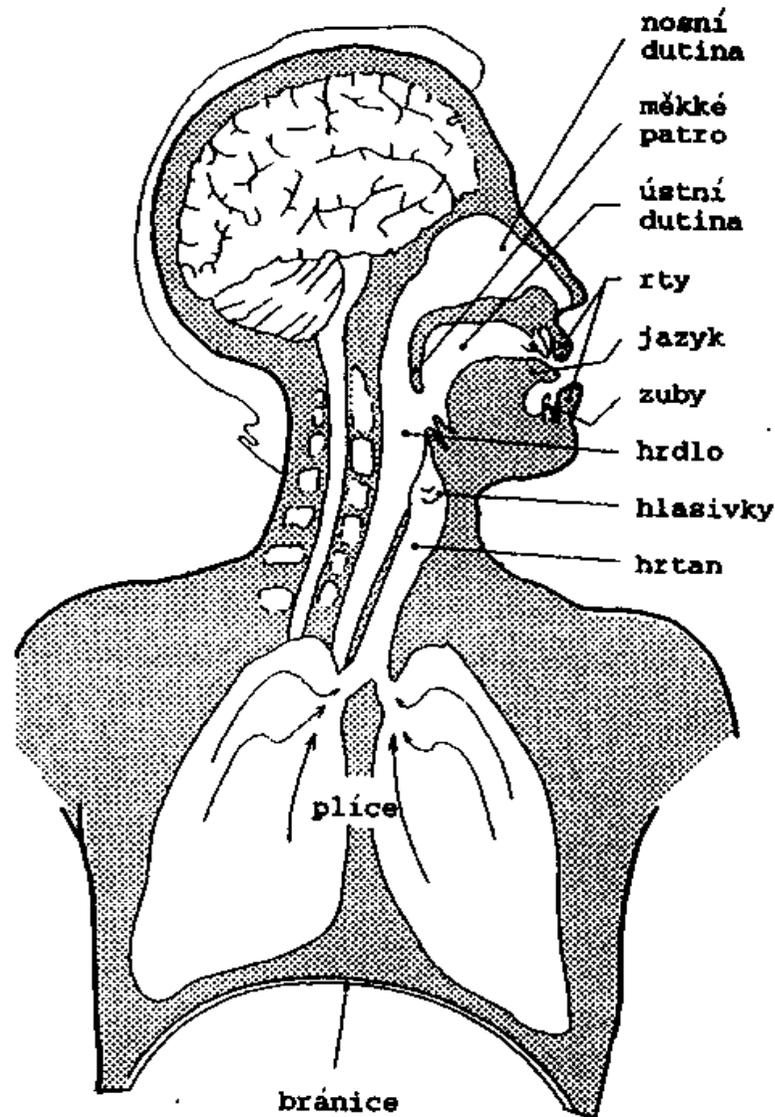
- rozlišení hlásek na znělé (málo průchodů) a neznělé (více jako šum – více průchodů).
- velmi citlivé na šum...

Příklad: “létající prase”



HLASOVÉ ÚSTROJÍ ČLOVĚKA A JEHO MODEL

S laskavým svolením autora převzato z J. Psutka: Komunikace s počítačem mluvenou řečí, Academia Praha 1995.



“Maso” a jeho modelování v číslicovém zpracování

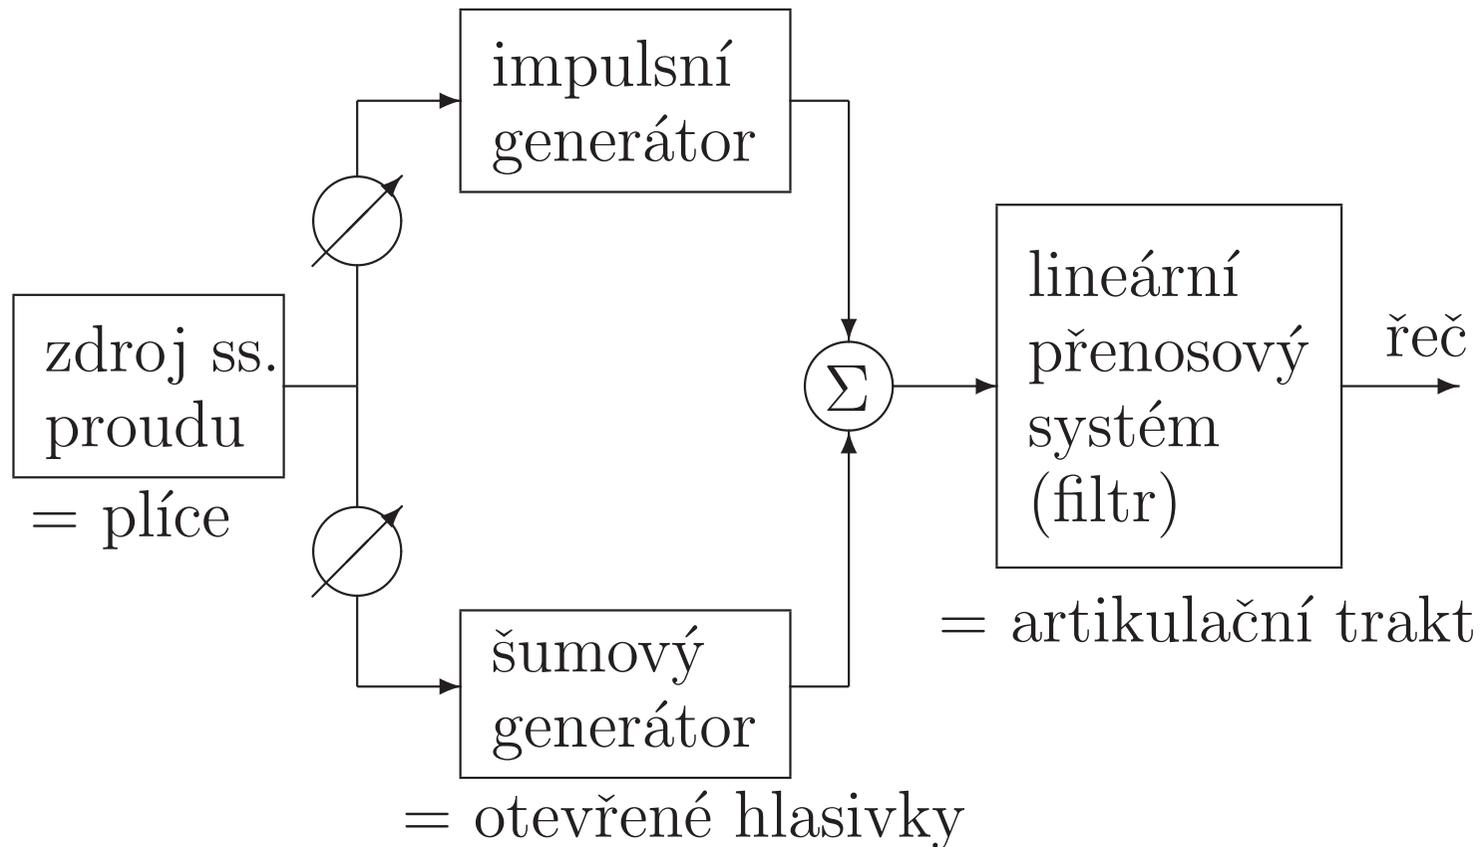
- **plíce** — zdroj energie — **signály: NIC**
- **hrtan** (larynx) — modulace energie – **signály: buzení (excitation)**.
 - otevřené hlasivky — šum.
 - kmitající hlasivky — periodický signál (tón). **základní tón řeči:**

muži	90–120 Hz
ženy	150–300 Hz
děti	350–400 Hz

- Buzení je většinou *smíšené* (moderní kodéry, GSM ...)
- **hlasový (artikulační) trakt** — modifikující ústrojí — **signály: filtrace**.
 - hltan (pharynx).
 - měkké patro (vélum).
 - jazyk.
 - ústní dutina.
 - nosní dutina.
 - zuby.
 - rty.

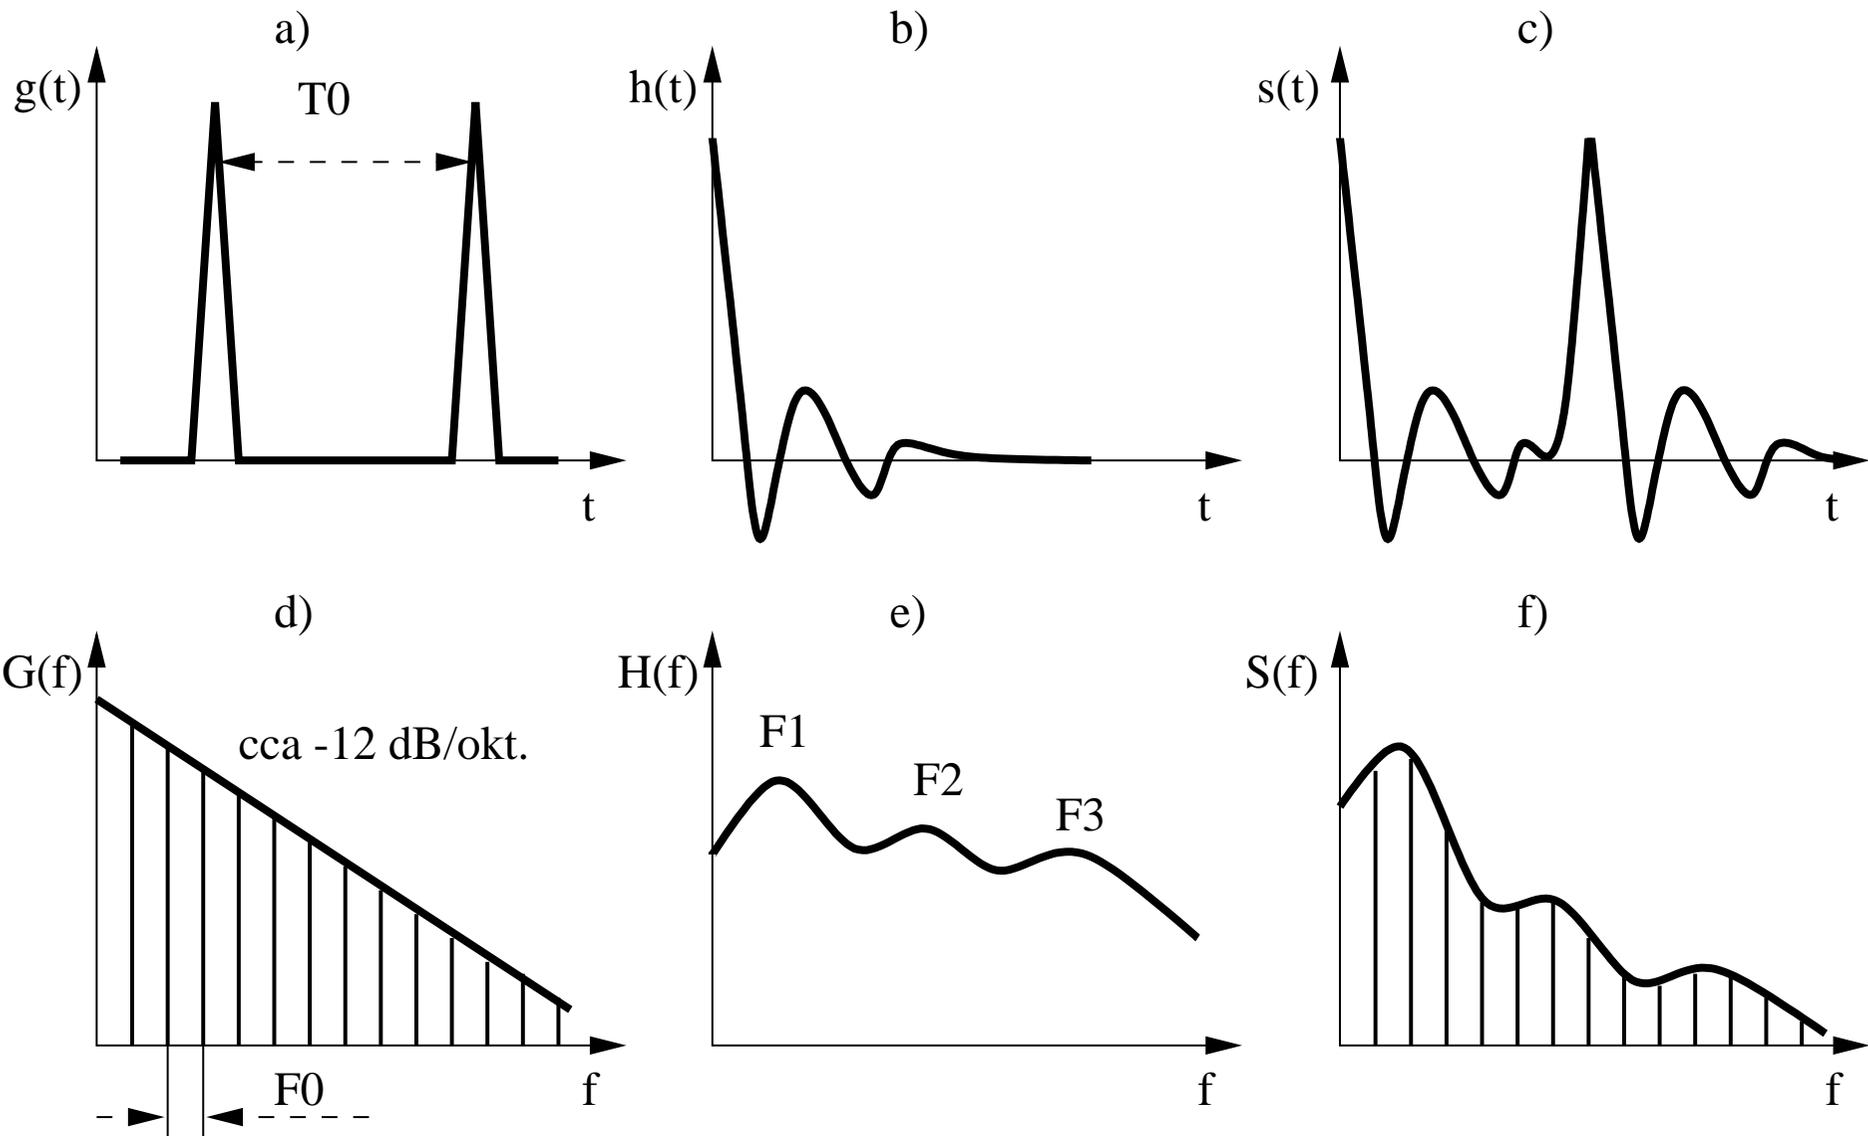
Model

= kmitající hlasivky



Přenosový systém: lineární filtr - nejčastěji IIR.

Model hlasového traktu v časové a frekvenční oblasti



Horní polovina – časové průběhy, spodní polovina – spektra.

- a) a d) buzení: T_0 je perioda, F_0 je frekvence základního tónu.
- b) a e) artikulační trakt: F_1 až F_3 jsou formanty (rezonanční frekvence hlasového traktu), dány jeho fyzickou konfigurací.
- c) a f) výsledný signál a jeho spektrum.

Výsledný signál je dán v časové oblasti *konvolucí*:

$$s(t) = g(t) \star h(t) = \int_{-\infty}^{+\infty} g(\tau)h(t - \tau)d\tau. \quad (16)$$

Do kmitočtové oblasti se tato konvoluce promítá jako *součin*:

$$S(f) = G(f)H(f). \quad (17)$$

Důležitý (a nelehký) úkol ve zpr. řeči je **dekonvoluce**, kdy se snažíme oddělit vliv buzení a artikulačního traktu.

SPEKTROGRAM

Jedno spektrum nestačí (řeč je nestacionární) \Rightarrow znázornění průběhu spektra řeči (přesněji spektrální hustoty výkonu – PSD) v čase:

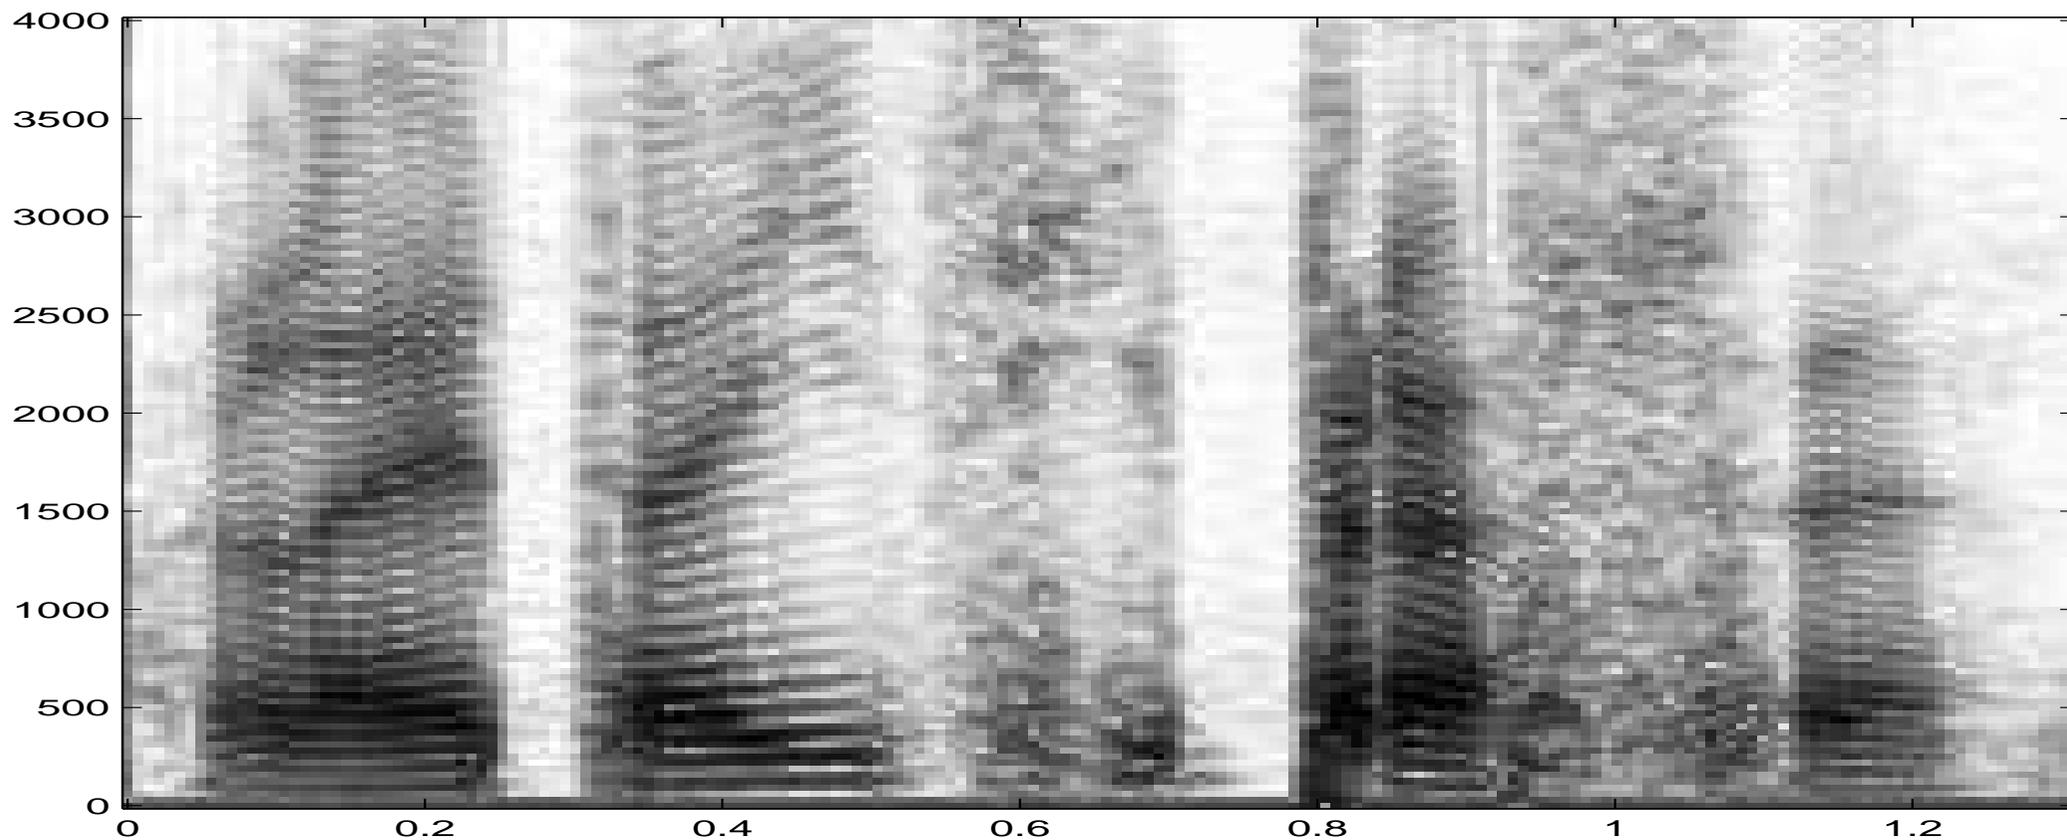
- řeč dělíme na rámce.
- v každém rámci odhadneme PSD, nejčastěji pomocí DFT.
- zobrazení:
 - vodorovná osa čas (“hrubý” čas v rámcích).
 - svislá osa frekvence.
 - stupně šedi nebo barvičky udávají energii.

Podle délky rámce dělíme na:

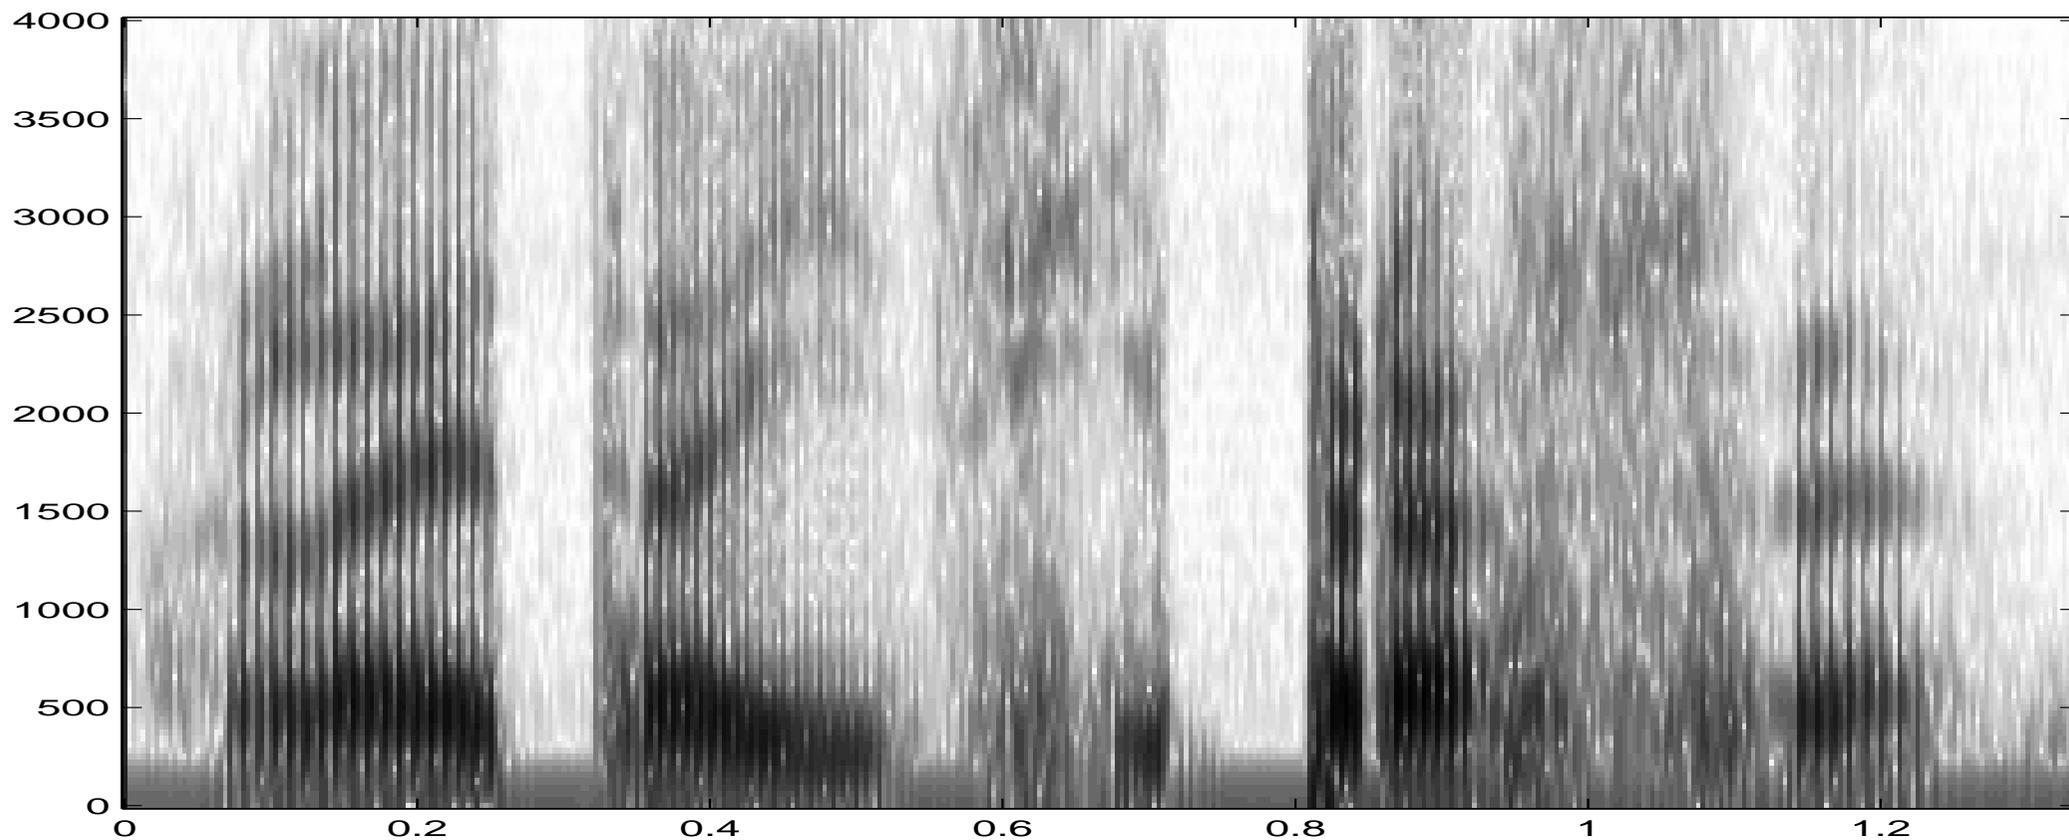
- long-term spectrogram.
- short-term spectrogram.

☹ Nevýhoda DFT: Přesnost ve frekvenci a v čase se nedá získat zároveň – wavelet analysis. . .

long-term: `specgram(s,256,8000,hamming(256),200);`



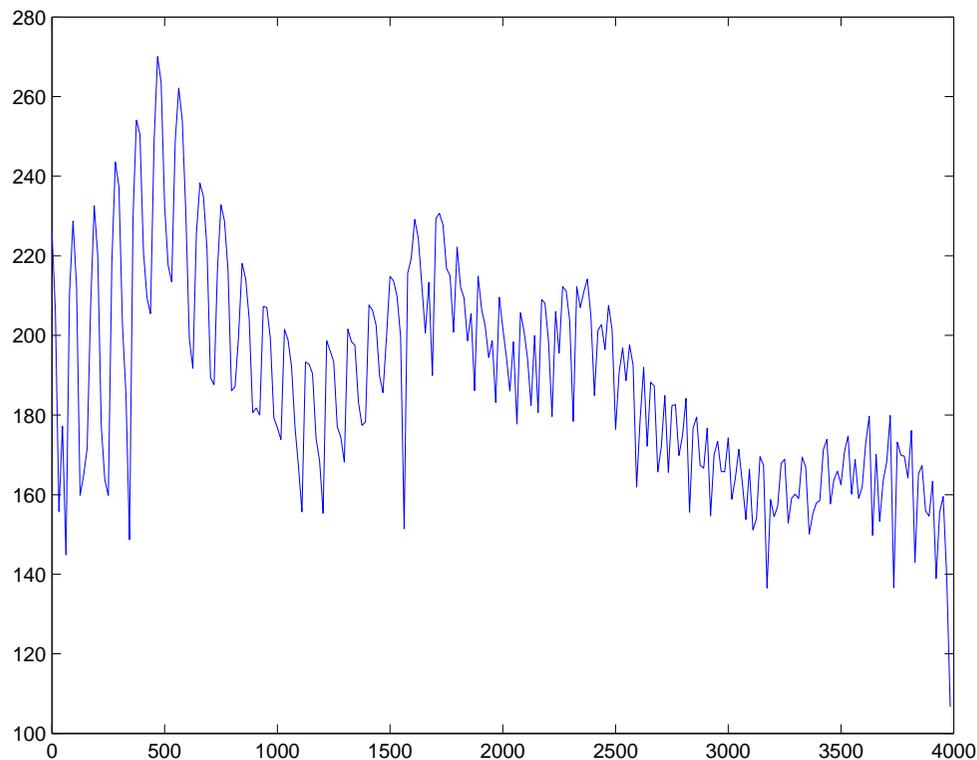
short-term: `specgram(s,256,8000,hamming(50));`



CEPSTRUM

pro oddělení buzení a modifikace – v kódování se nám s nimi pracuje lépe samostatně, v rozpoznávání buzení zahazujeme úplně (příliš závislé na řečnickovi, náladě, ...).

Návrh č. 1: odfiltrujeme část pod 400 Hz a zbavíme se základního tónu ... **BAD IDEA:**



- násobky základního tónu jsou “rozesety” po celém spektru.
- mohli bychom přijít o první formant.
- telefonní pásmo začíná na 300 Hz a také perfektně slyšíme, s jakou výškou hlasu člověk mluví.
- ...takže budeme potřebovat něco lepšího.

⇒ **Cepstrum**

The problem

Buzení $e(t)$ je konvoluováno s impulsní odezvou filtru:

$$s(t) = g(t) \star h(t) = \int_{-\infty}^{+\infty} g(\tau)h(t - \tau)d\tau, \quad (18)$$

v kmitočtové oblasti *součin*:

$$S(f) = G(f)H(f). \quad (19)$$

ani v jedna z oblastí nelze dvě složky dobře oddělit. Řešení: **nelinearita**, která dokáže převést součin na součet.

Definice cepstra

$$\ln G(f) = \sum_{n=-\infty}^{+\infty} c(n) e^{-j2\pi f n} \quad (20)$$

Hodnoty $c(n)$ jsou **cepstrální koeficienty**. Jelikož $G(f)$ je sudá funkce, jsou $c(n)$ reálné a platí:

$$c(n) = c(-n) \quad (21)$$

Suma v rovnici je definicí DFT, proto můžeme $c(n)$ vypočítat jako:

$$c(n) = \mathcal{F}^{-1} [\ln G(f)] \quad (22)$$

DFT-cepstrum

$$c(n) = \mathcal{F}^{-1} \{ \ln |\mathcal{F}[s(n)]|^2 \}, \quad (23)$$

- spectrum \longrightarrow cepstrum.
- frekvence \longrightarrow kvefrence.
- filtrování \longrightarrow liftrování.
- atd.

Opravdu to dokáže “rozetnout” konvoluci ?

$$s(n) = e(n) \star h(n), \quad (24)$$

$$S(f) = E(f)H(f) \quad \text{a tedy} \quad |S(f)|^2 = |E(f)|^2 |H(f)|^2. \quad (25)$$

Při výpočtu cepstra využíváme linearitu zpětné Fourierovy transformace:

$$\mathcal{F}^{-1}(a + b) = \mathcal{F}^{-1}(a) + \mathcal{F}^{-1}(b).$$

Dostáváme:

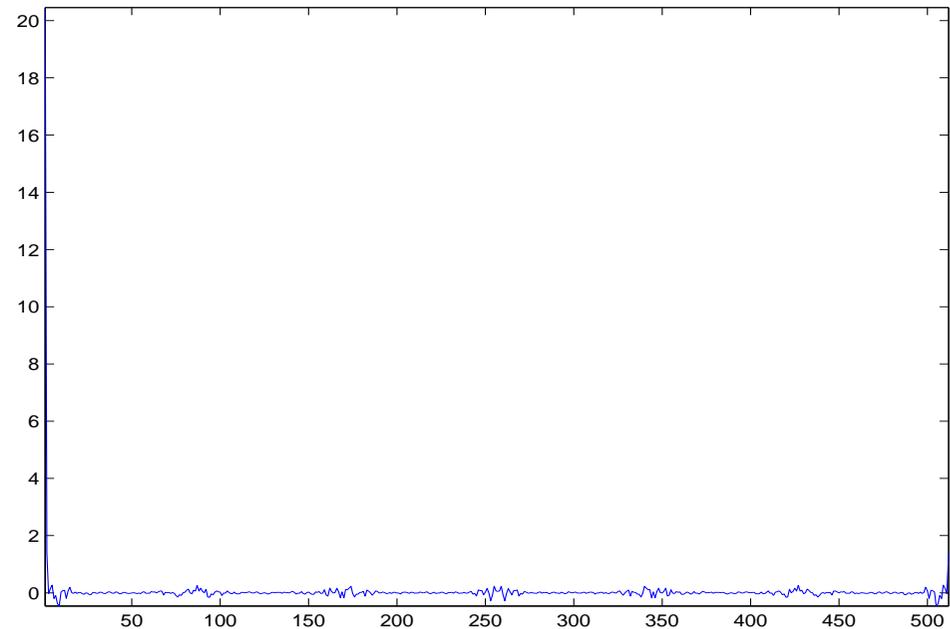
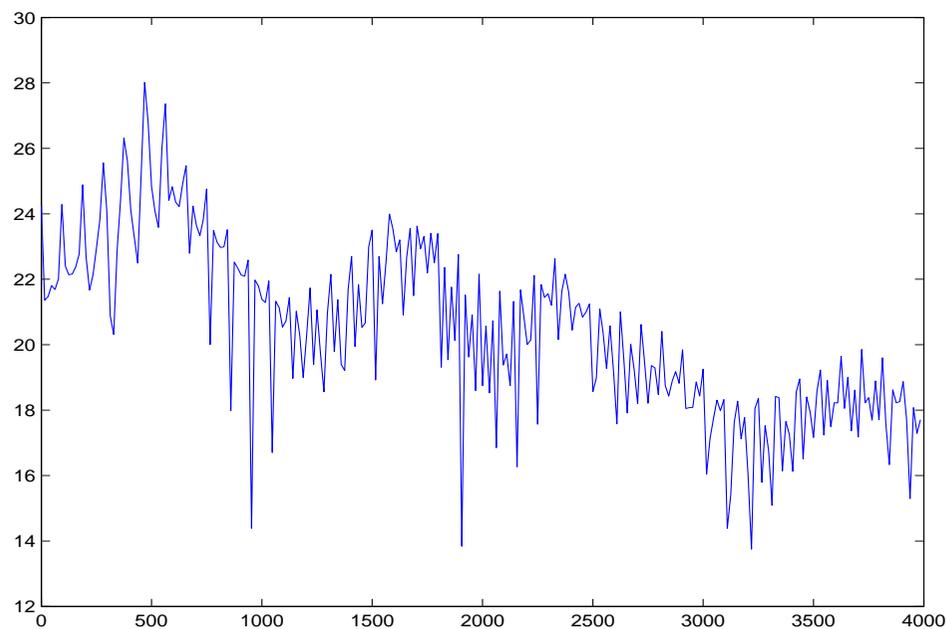
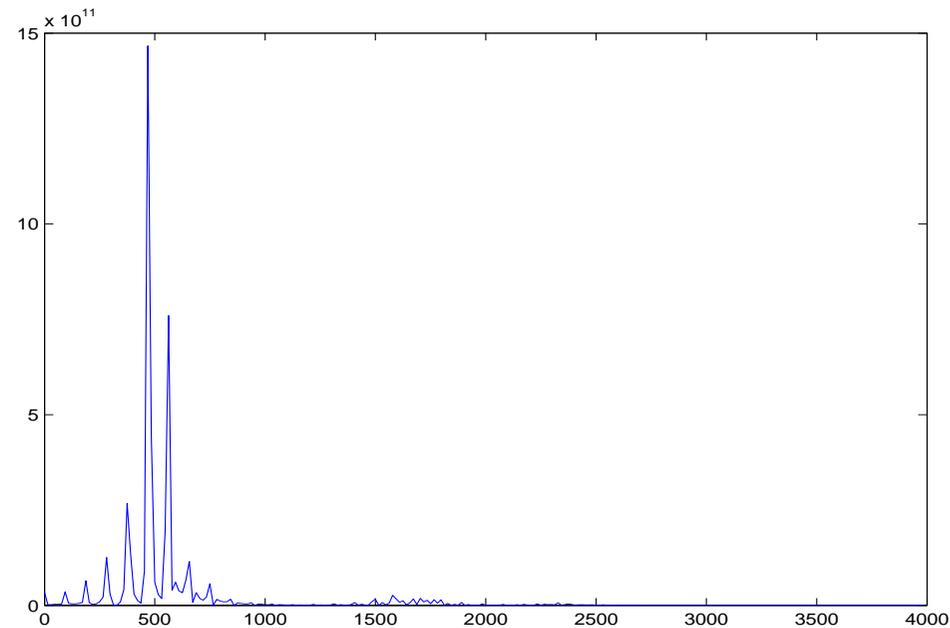
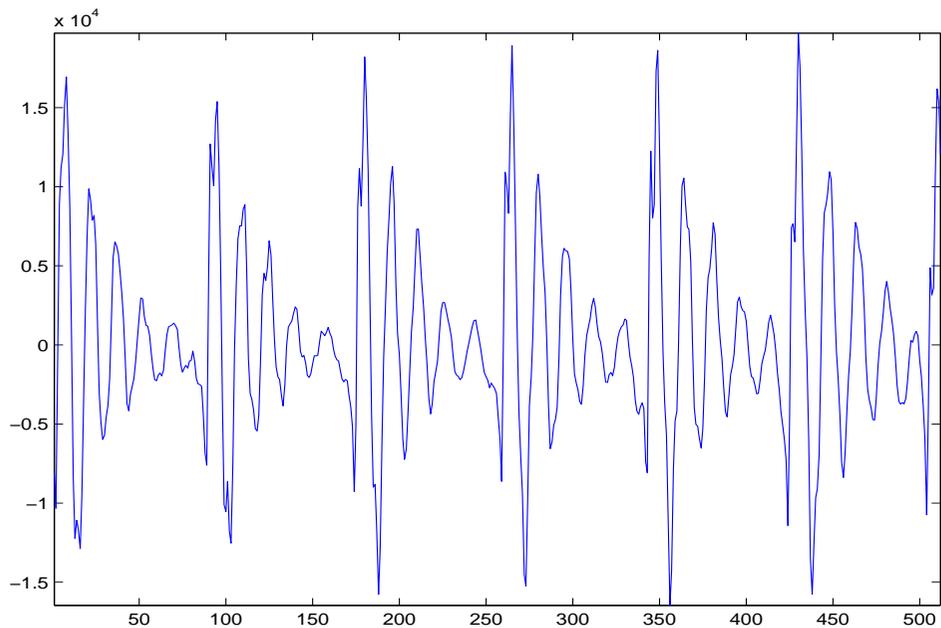
$$c(n) = \mathcal{F}^{-1} \{ \ln[|E(f)|^2 |H(f)|^2] \} = \mathcal{F}^{-1} \{ \ln |E(f)|^2 + \ln |H(f)|^2 \} = \quad (26)$$

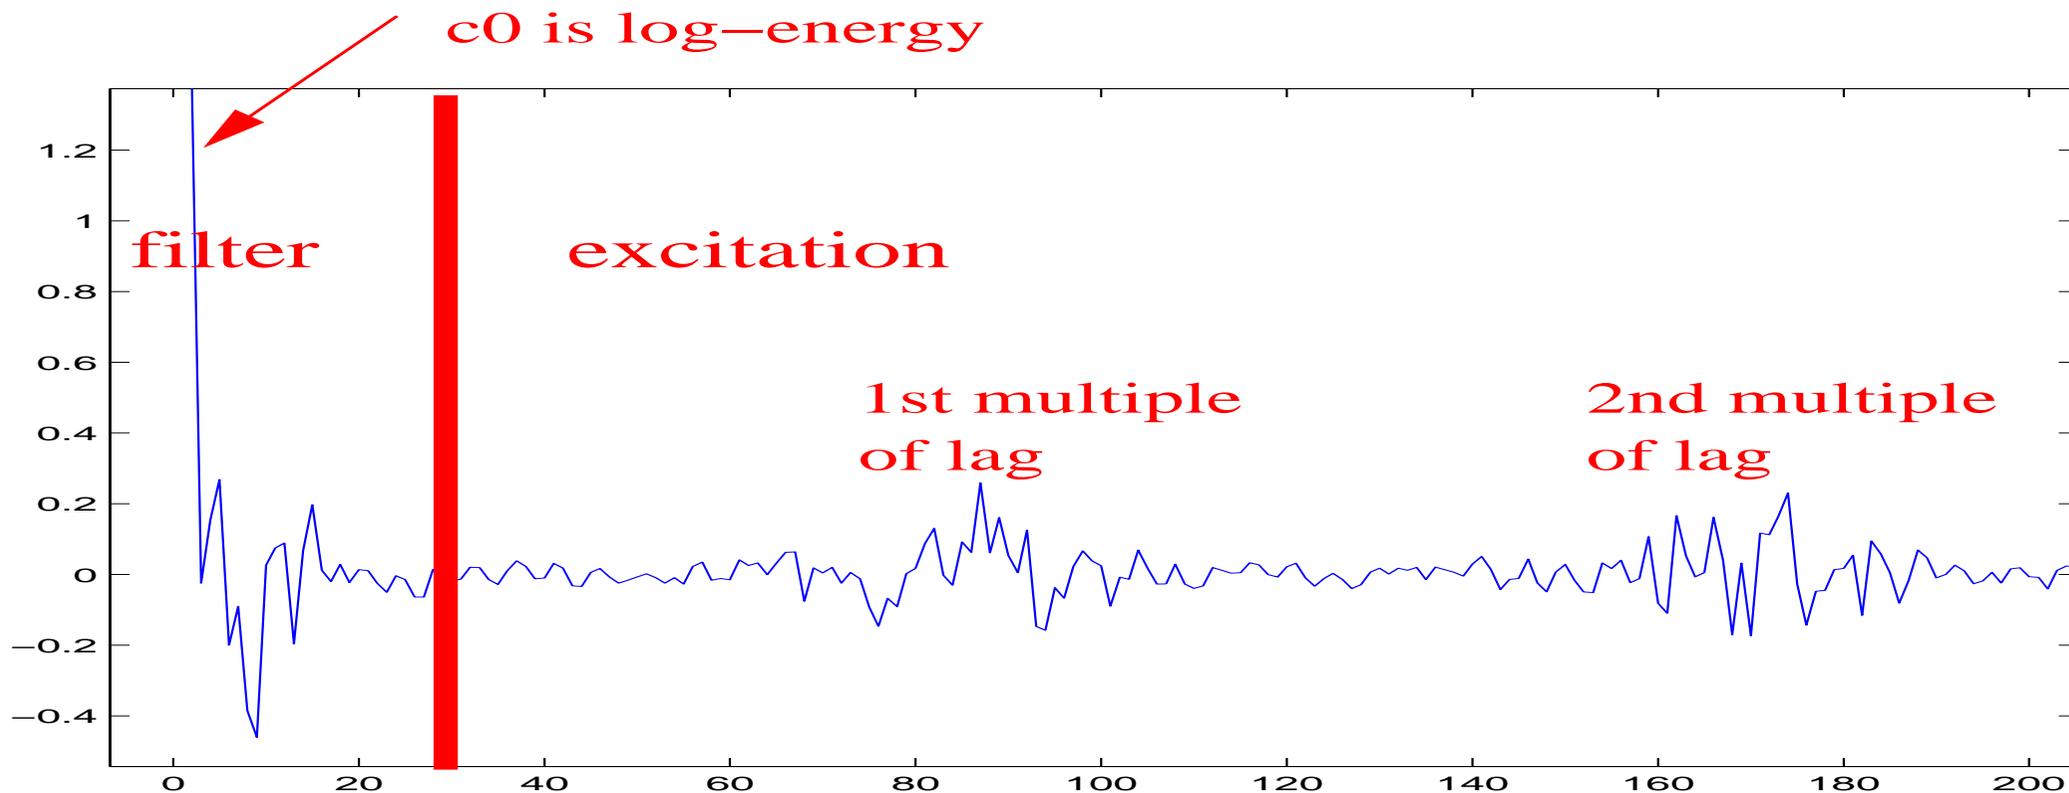
$$= \mathcal{F}^{-1} \{ \ln |E(f)|^2 \} + \mathcal{F}^{-1} \{ \ln |H(f)|^2 \} = c_e(n) + c_h(n) \quad (27)$$

$$(28)$$

Z konvoluce se stal **součet**. Pokud jsou koeficienty $c_e(n)$ a $c_h(n)$ odděleny na kvefrenční ose, je možné je separovat jednoduchým oknem — naštěstí **jsou**.

signál, $|\mathcal{F}[s(n)]|^2$, $\ln |\mathcal{F}[s(n)]|^2$, $\mathcal{F}^{-1} \{ \ln |\mathcal{F}[s(n)]|^2 \}$.

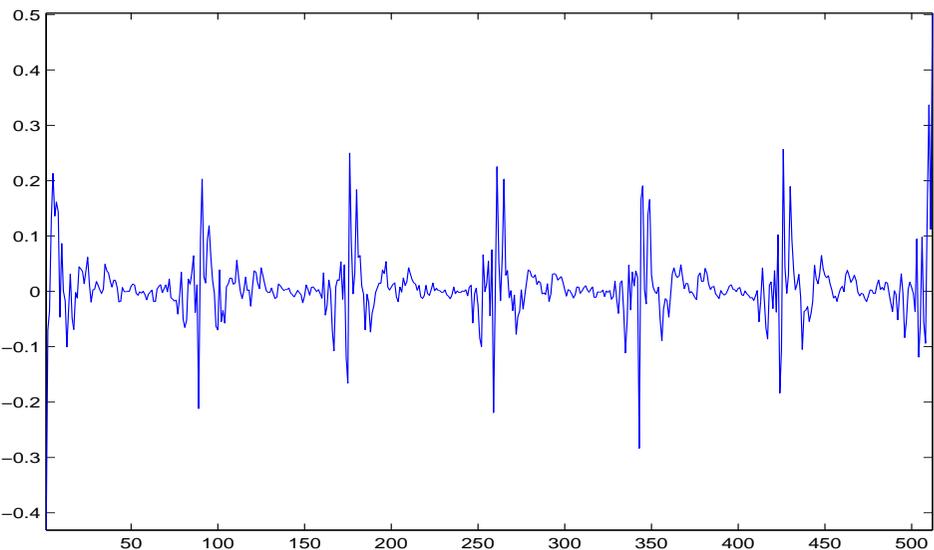
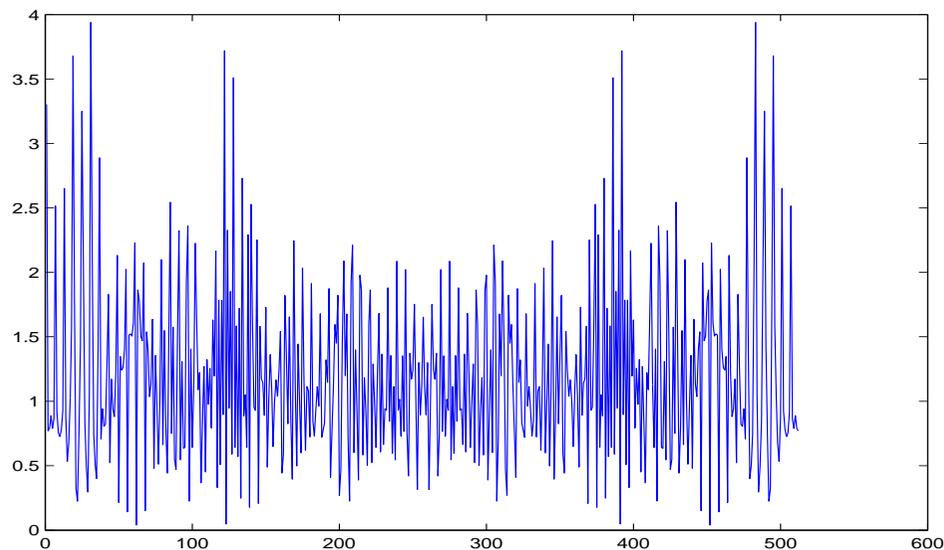
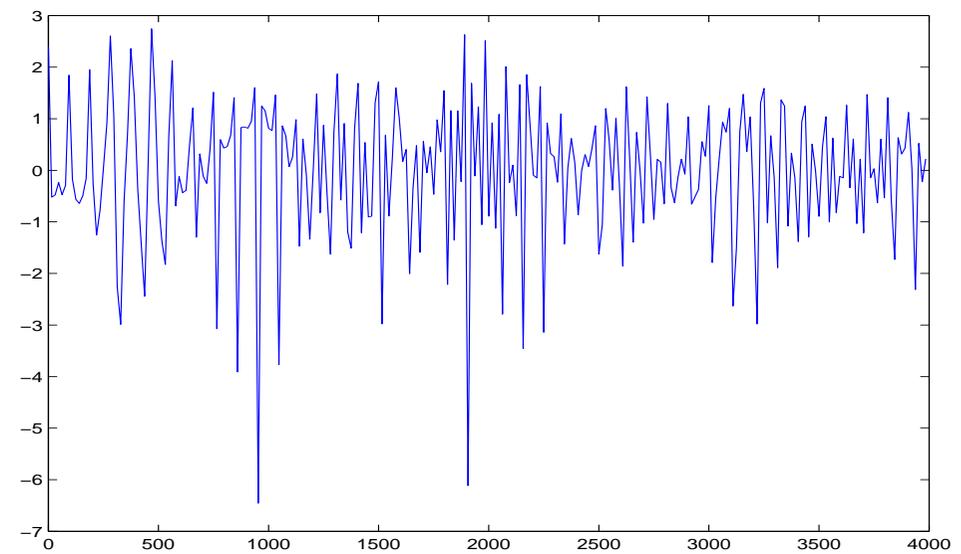
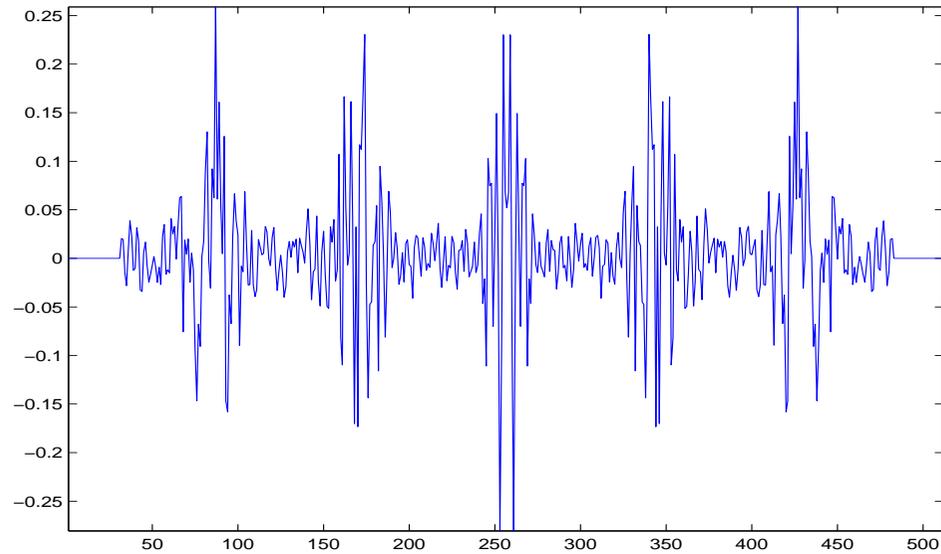




Pro vzorkovací frekvenci $F_s = 8000$ Hz můžeme na kvefrenční ose oddělit vliv buzení a filtru separací s hranicí 30.

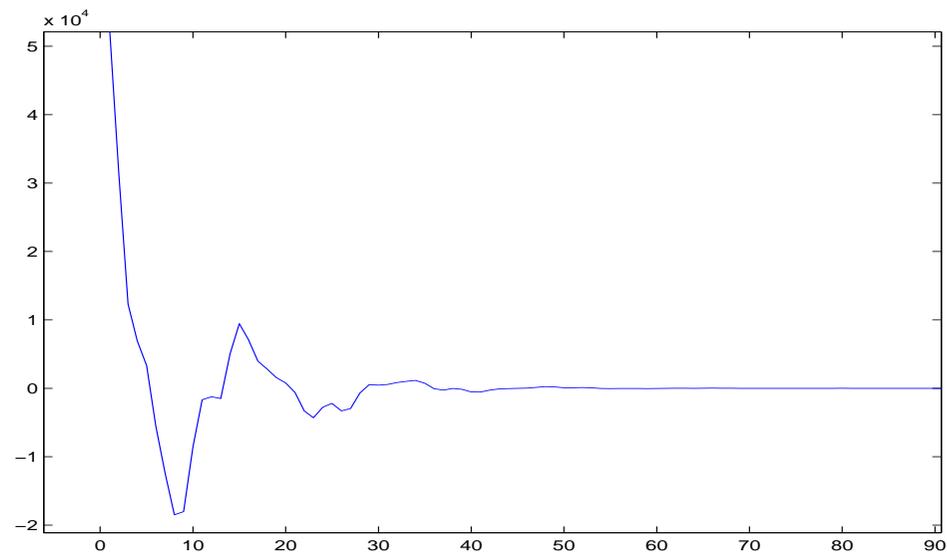
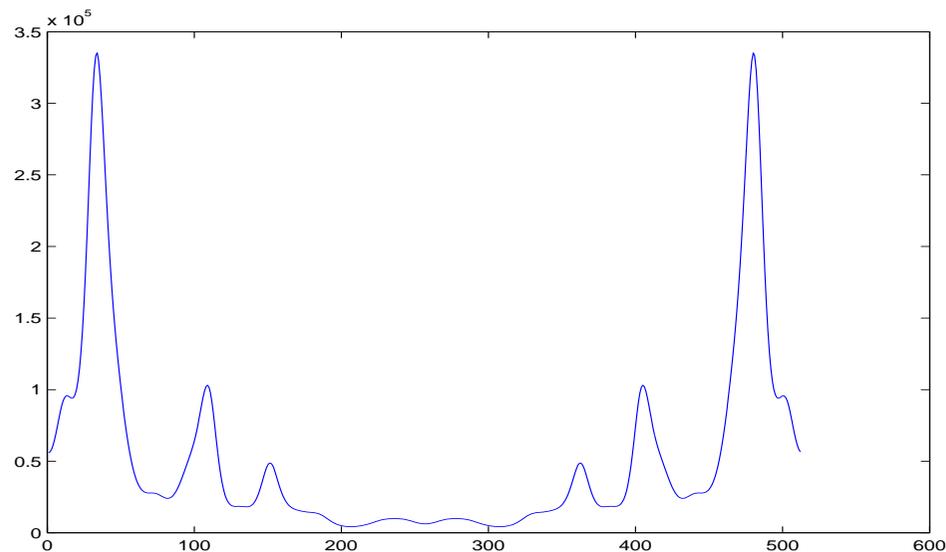
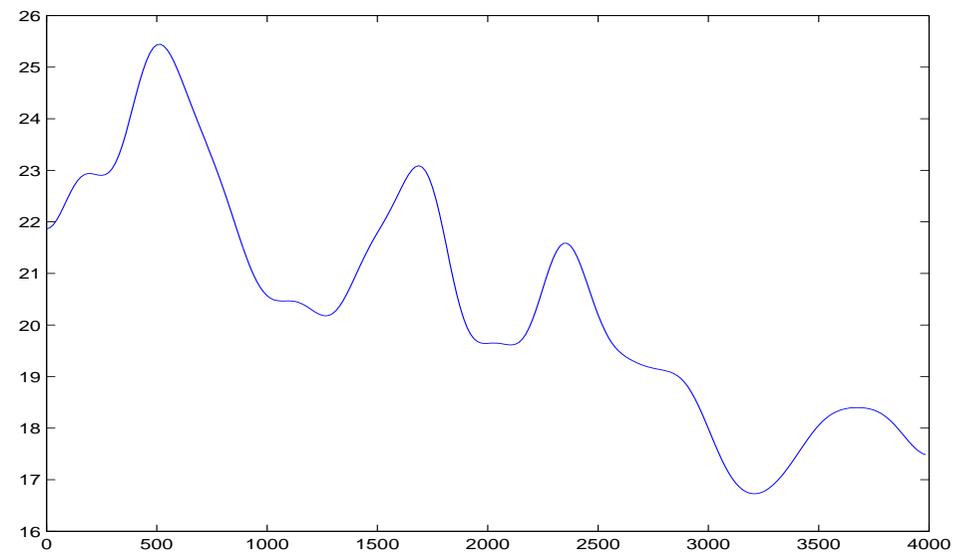
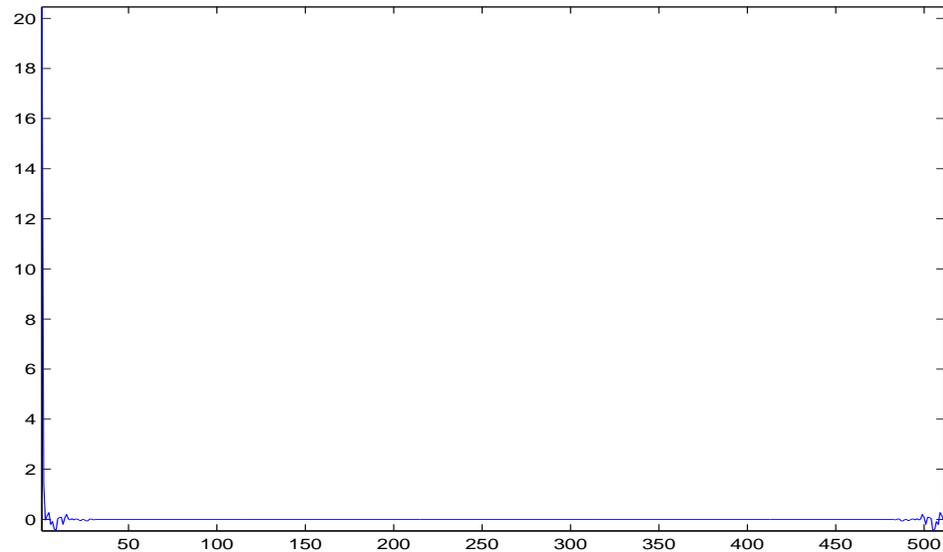
Pouze buzení – vynulujeme cepstra patřící filtru:

vynulované cepstrum, $\ln |\mathcal{F}[s(n)]|^2$, $|\mathcal{F}[s(n)]|$, signál (při IDFT byly použity fáze původního signálu).



Pouze filtr – vynulujeme cepstra patřící buzení:

vynulované cepstrum, $\ln |\mathcal{F}[s(n)]|^2$, $|\mathcal{F}[s(n)]|$, signál (při IDFT byly použity fáze nula).



Mel-frequency cepstrum – MFCC

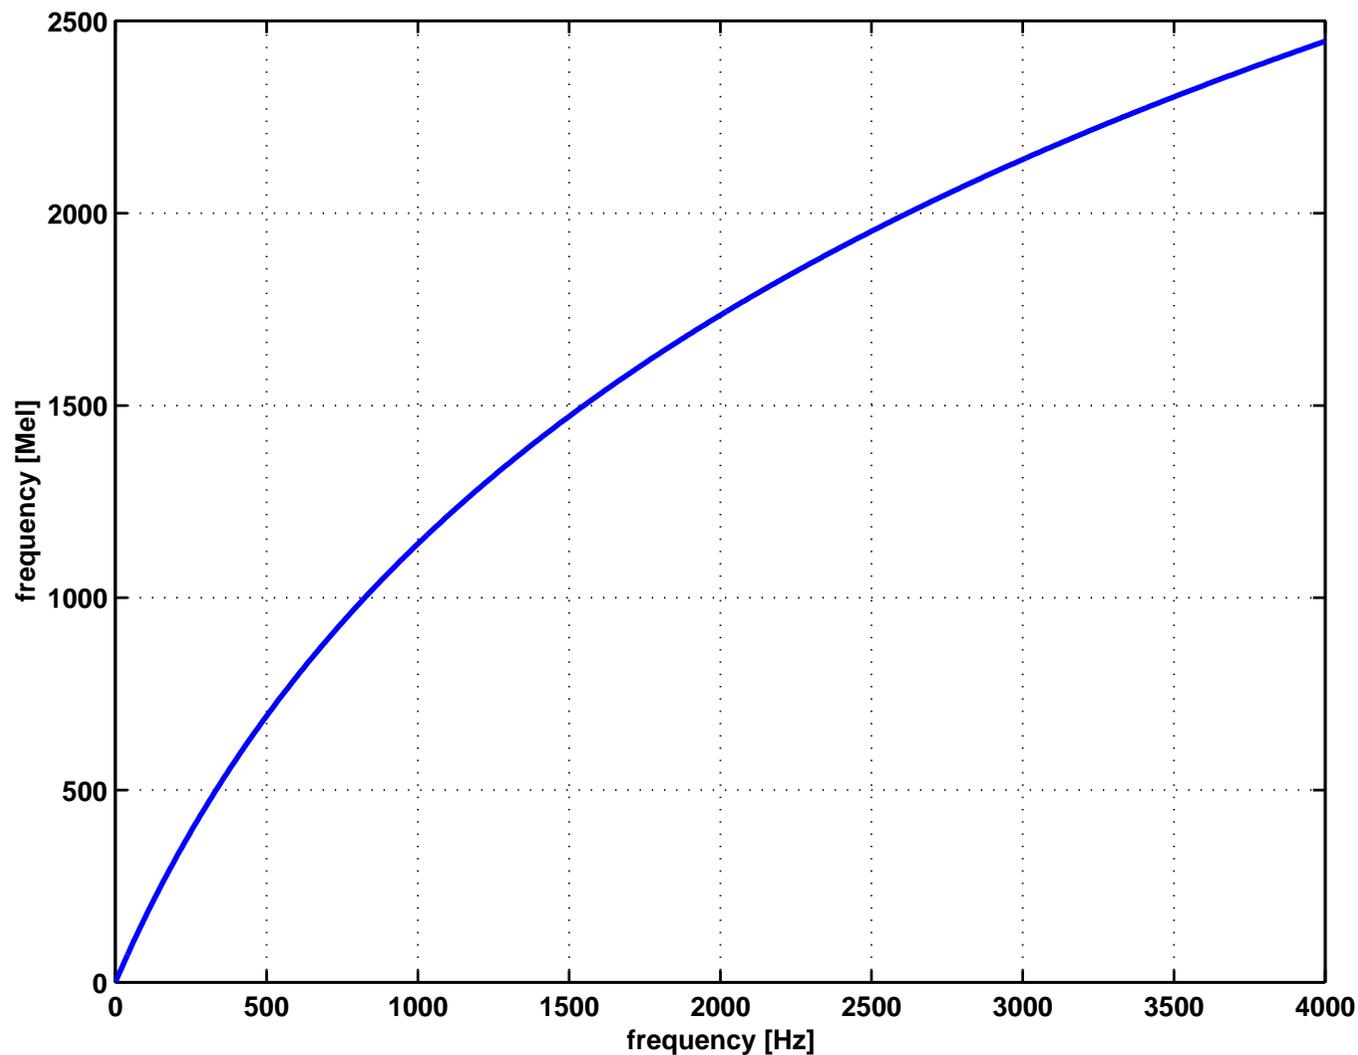
- DFT má všude stejné frekvenční rozlišení.
- Lidské ucho má na nízkých frekvencích větší rozlišení než na vysokých.
- Pro rozpoznávače řeči chceme přiblížit cepstrum slyšení.

Jak na to ?

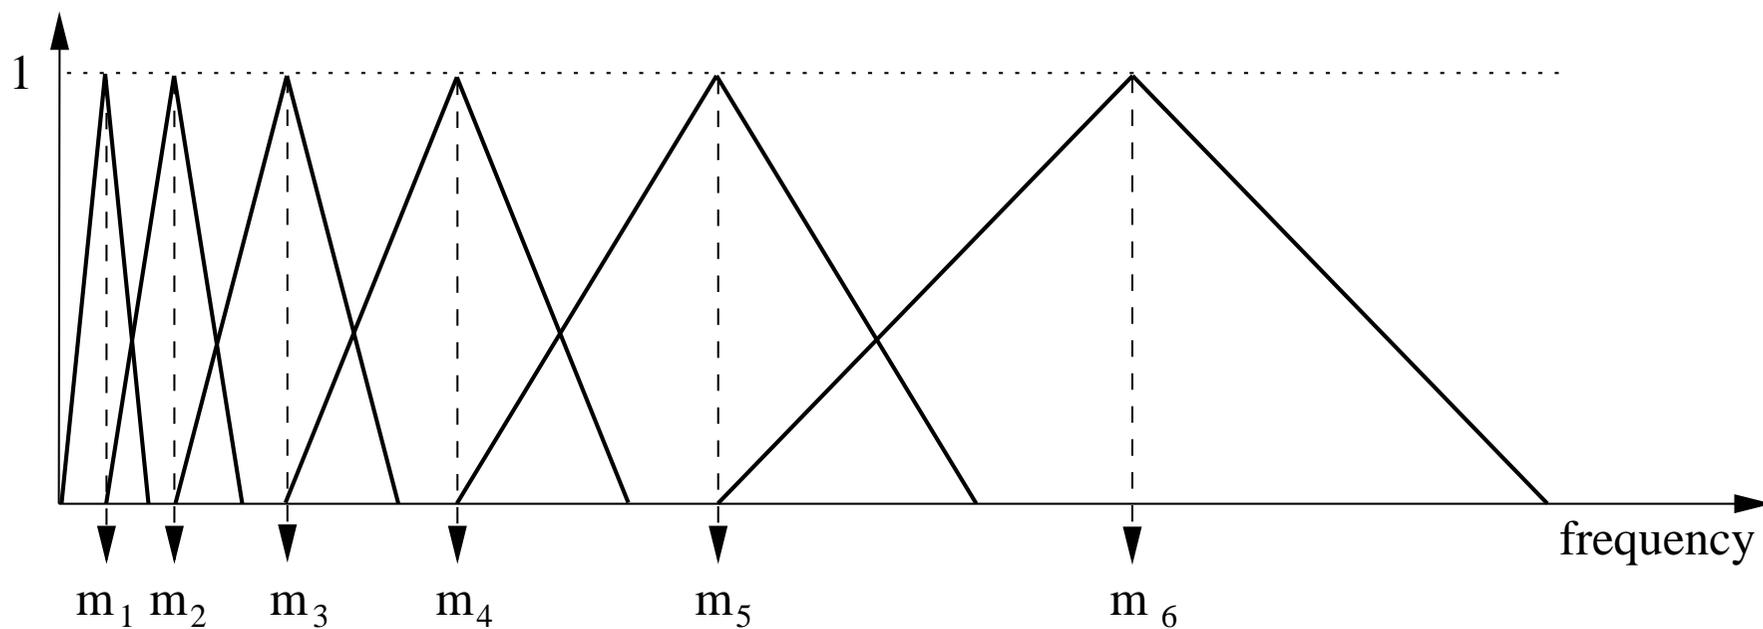
- Na frekvenční osu rozmístíme **nelineárně** filtry, měříme energii na jejich výstupu, použijeme je místo DFT při výpočtu cepstra.
- Frekvenční osu můžeme nelineárně upravit a na upravené ose pak filtry rozmístit rovnoměrně.

Používaná nelineární úprava využívá převodu Hertzů na Mely:

$$F_{Mel} = 2959 \log_{10}\left(1 + \frac{F_{Hz}}{700}\right) \quad (29)$$



Lineární rozmístění filtrů na Mel-ové ose má za následek nelineární rozmístění na standardní kmitočtové ose v Hz:



Výpočet energií:

1. zkonstruujeme banku filtrů, vstupní signál filtrujeme v časové oblasti a počítáme energie: $\sum_n s_i^2(n)$... MOC SLOŽITÉ.
2. provedeme DFT, umocníme, vynásobíme trojúhelníkovým oknem a sečteme. (použito v toolkitu pro rozpoznávání řeči HTK Hidden Markov Model ToolKit).

Zpětnou FT můžeme realizovat pomocí diskrétní cosinové transformace (DCT) ... (bez odvození: využíváme symetrie spektra a toho, že výsledek musí vyjít reálný):

$$c_{mf}(n) = \sum_{k=1}^K \log m_k \cos \left[n(k - 0.5) \frac{\pi}{K} \right] \quad (30)$$

⇒ **Mel-frekvenční cepstrální koeficienty (MFCC)**

