

# Kódování řečí I.

Jan Černocký ÚPGM FIT VUT Brno, cernocky@fit.vutbr.cz

FIT VUT Brno

## Plán

- Dělení kodérů
- Vyhodnocování kvality
- Kódování “tvaru vlny” (waveform coding)
- Vokodéry
- Vektorové kvantování

## Proč ?

Naprostá většina komunikací probíhá v dnešní době číslicově.

- co nejmenší počet bitů.
- co největší kvalitu.
- co nejmenší zpoždění.
- co největší odolnost proti chybám.
- co nejmenší výpočetní náročnost.

... jednotlivá kriteria jsou samozřejmě v rozporu.

**Kódování — komerčně nejdůležitější součástí ASŘ (automatického zpracování řeči)**

## Standardizace

- CCITT (Centre Consultatif International Téléphonique et Télégraphique), ze kterého vznikla ITU-TSS (International Telecommunication Union — Telecom. Standardization Sector). Doporučení Gxxx. <http://www.itu.int>
- US DoD (Department of Defense). Federální standardy FSxxxx.
- ETSI (European Telecommunications Standards Institute), aktivní především v mobilní telefonii. <http://www.etsi.org>
- a další instituce, např. INMARSAT.

## Dělení kodérů – Principiální dělení

- “**kódování tvaru vlny**” (waveform coders) - vzorek po vzorku. Vysoká kvalita, ale za cenu velkého bitového toku. I pro neřečové signály.
- **vokodéry** (vocoders) založeny na poznatcích o tvorbě a slyšení řeči člověkem (buzení + modifikace). Rámce. LP model. Složitější než waveform coders. Střední a nízké rychlosti. Jen řeč.
- (Hybridní) - někdy jsou takto nazývány algoritmy CELP (GSM). Model pro modifikační ústrojí, ale částečné kódování waveform pro buzení.
- **fonetické vokodéry** (phonetic vocoders) – delší řečovými úseky, než rámce (fonémy, automaticky natrénované jednotky). Založené na rozpoznávání v kodéru a syntéze v dekodéru. Dosud pouze laboratorní stadium, zatím žádná normalizace. Jen řeč, závislé na jazyku nebo i na mluvčím.

## Dělení podle bitového toku

Bitový tok (bit rate) = počet bitů za sekundu pro kódování řeči (source coding). Při dalším kódování — channel coding.

- fixed-rate (klasické tlf. sítě)
- variable-rate (paketové).

označení	bitový tok
high rate	> 16 kbit/s
medium rate	8 – 16 kbit/s
low rate	2.4 – 8 kbit/s
very low rate	< 2.4 kbit/s

## Dělení podle kvality

- **broadcast** (rozhlasová) – širší pásmo než telefonní, tok  $> 64$  kbit/s.
- **network** nebo **toll** (sítová) – klasická kvalita analogového telefonního signálu, pásmo 300–3400 Hz.
- **communications** (komunikační) – poněkud horší, avšak srozumitelná, zachovává charakter mluvčího.
- **synthetic** (syntetická) – nepřirozená, nezachovává charakter mluvčího, snížená srozumitelnost.

## Vyhodnocování kvality

- objektivní
- subjektivní

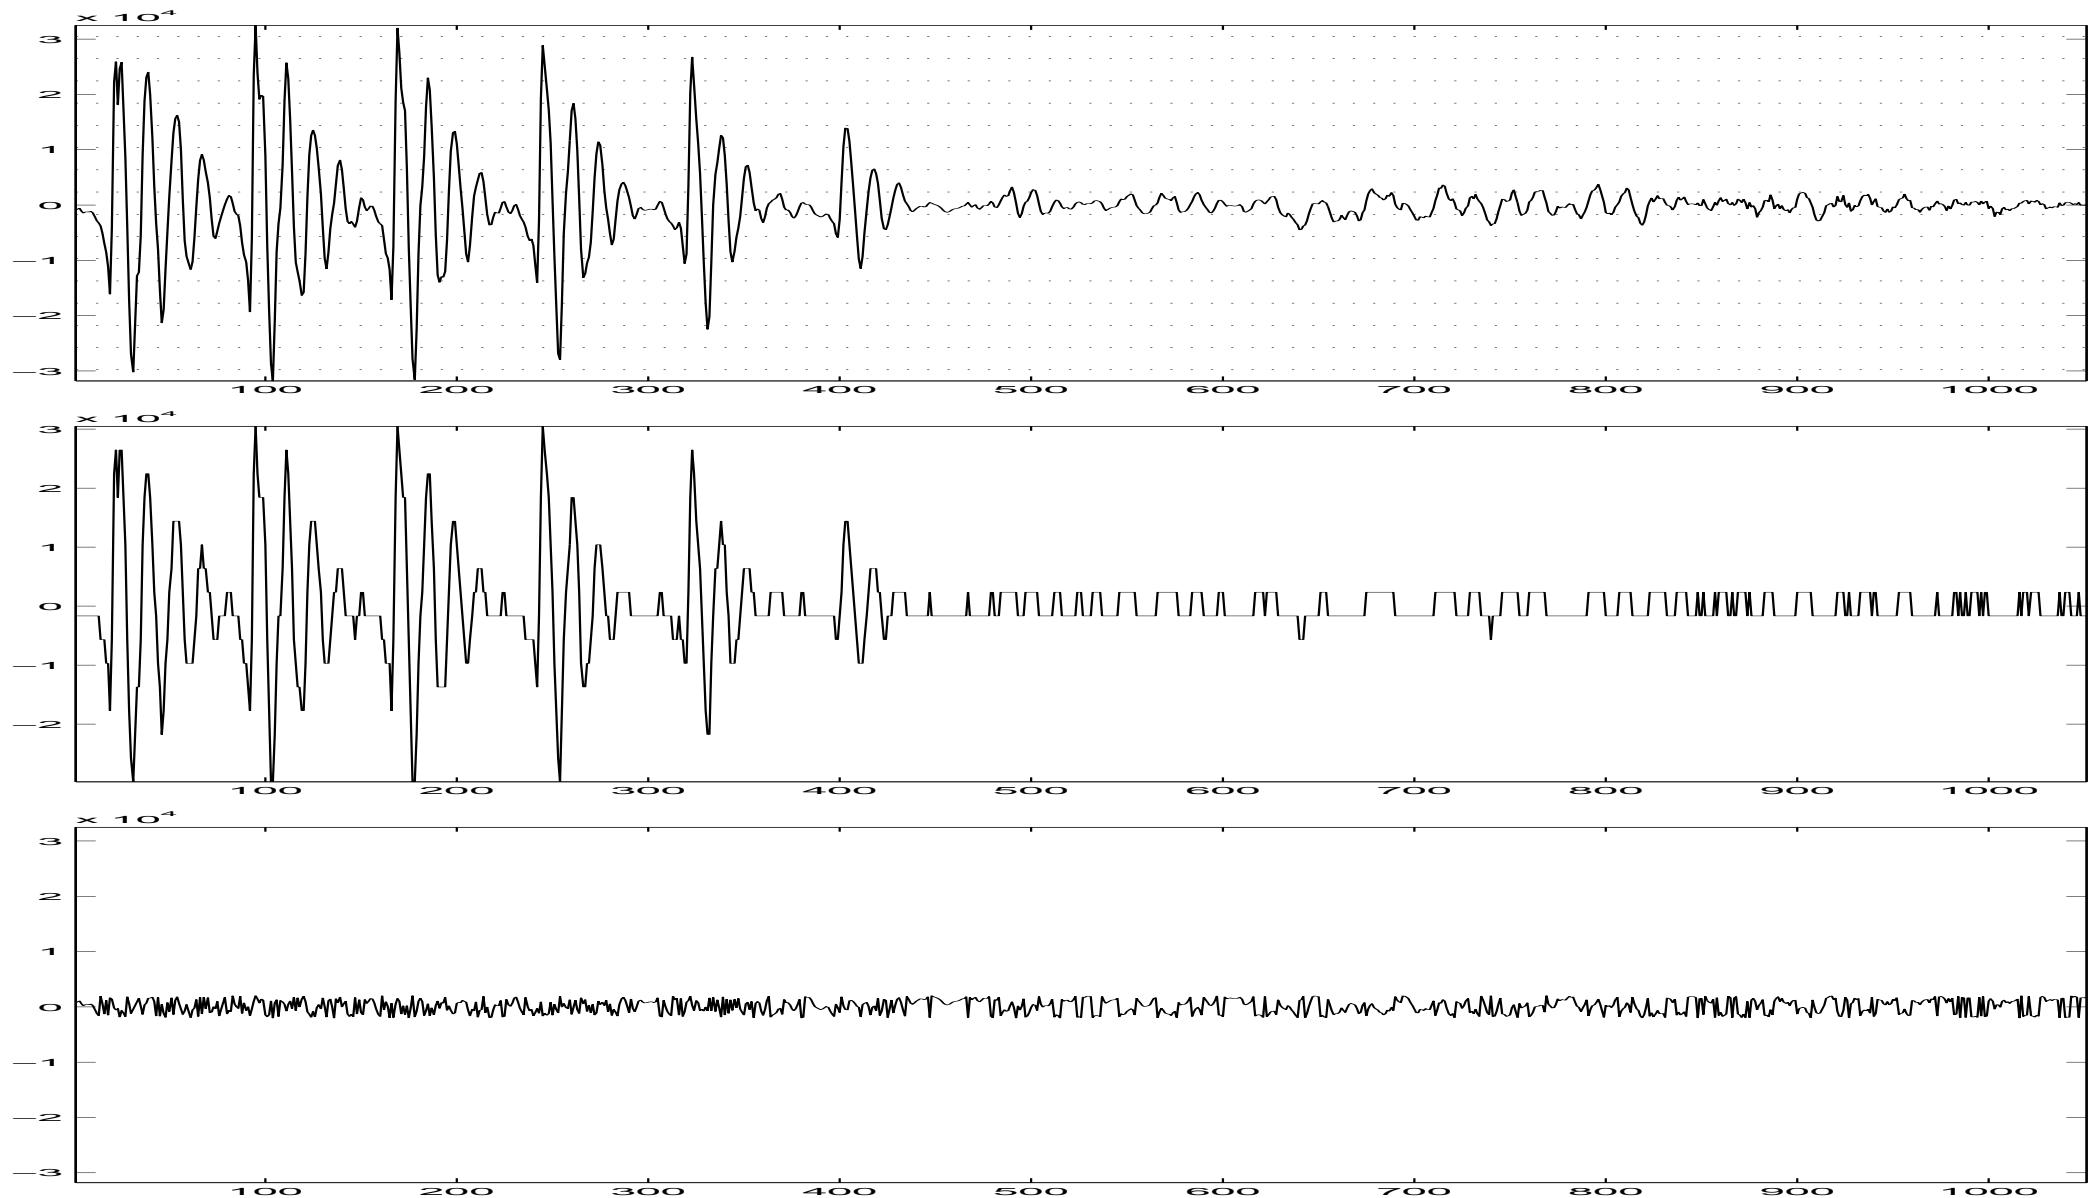
## “Objektivní— vyhodnocování

**odstup signálu od šumu** (nebo poměru signálu k šumu, signal-to-noise ratio SNR):

$$SNR = 10 \log_{10} \left\{ \frac{\sum_{n=0}^{N-1} s^2(n)}{\sum_{n=0}^{N-1} [s(n) - \hat{s}(n)]^2} \right\}$$

Nevýhoda: je, že pohlíží na signály “globálně”

Příklad: kódování slabiky “as” pomocí 4 bitů (16 kvantizačních úrovní)  $SNR = 14.89$  dB.



## segmentální poměr signálu k šumu (SEGSNR)

$$SEGSNR = \frac{10}{N_{ram}} \sum_{i=0}^{N_{ram}-1} \log_{10} \left\{ \frac{\sum_{n=0}^{l_{ram}-1} s^2(il_{ram} + n)}{\sum_{n=0}^{l_{ram}-1} [s(il_{ram} + n) - \hat{s}(il_{ram} + n)]^2} \right\} \quad (1)$$

V tomto případě vycházejí SNR v jednotlivých rámcích (při "klasické" délce rámce 160 vzorků):

20.04    19.63    14.35    0.21    4.26    -0.54(!)

a SEGSNR (jejich průměrná hodnota) je **9.66 dB**, což je podstatně horší, avšak o realitě více vypovídající nežli SNR.

## Logaritmická spektrální vzdálenost – logarithmic spectral distance

počítá zkreslení mezi originálním a kódovaným signálem ve *spektrální oblasti*. ( . . . dá se velmi snadno počítat pomocí LPC-cepstrálních koeficientů – ne integrál, jen suma)

$$d_2 = \sqrt{\int_{-1/2}^{+1/2} |V(f)|^2 df}, \quad \text{where } V(f) = 10 \log G(f) - 10 \log \hat{G}(f), \quad (2)$$

kde  $G(f)$  a  $\log \hat{G}(f)$  jsou spektrální hustoty výkonu originálního a kódovaného rámce.

## Subjektivní měření kvality

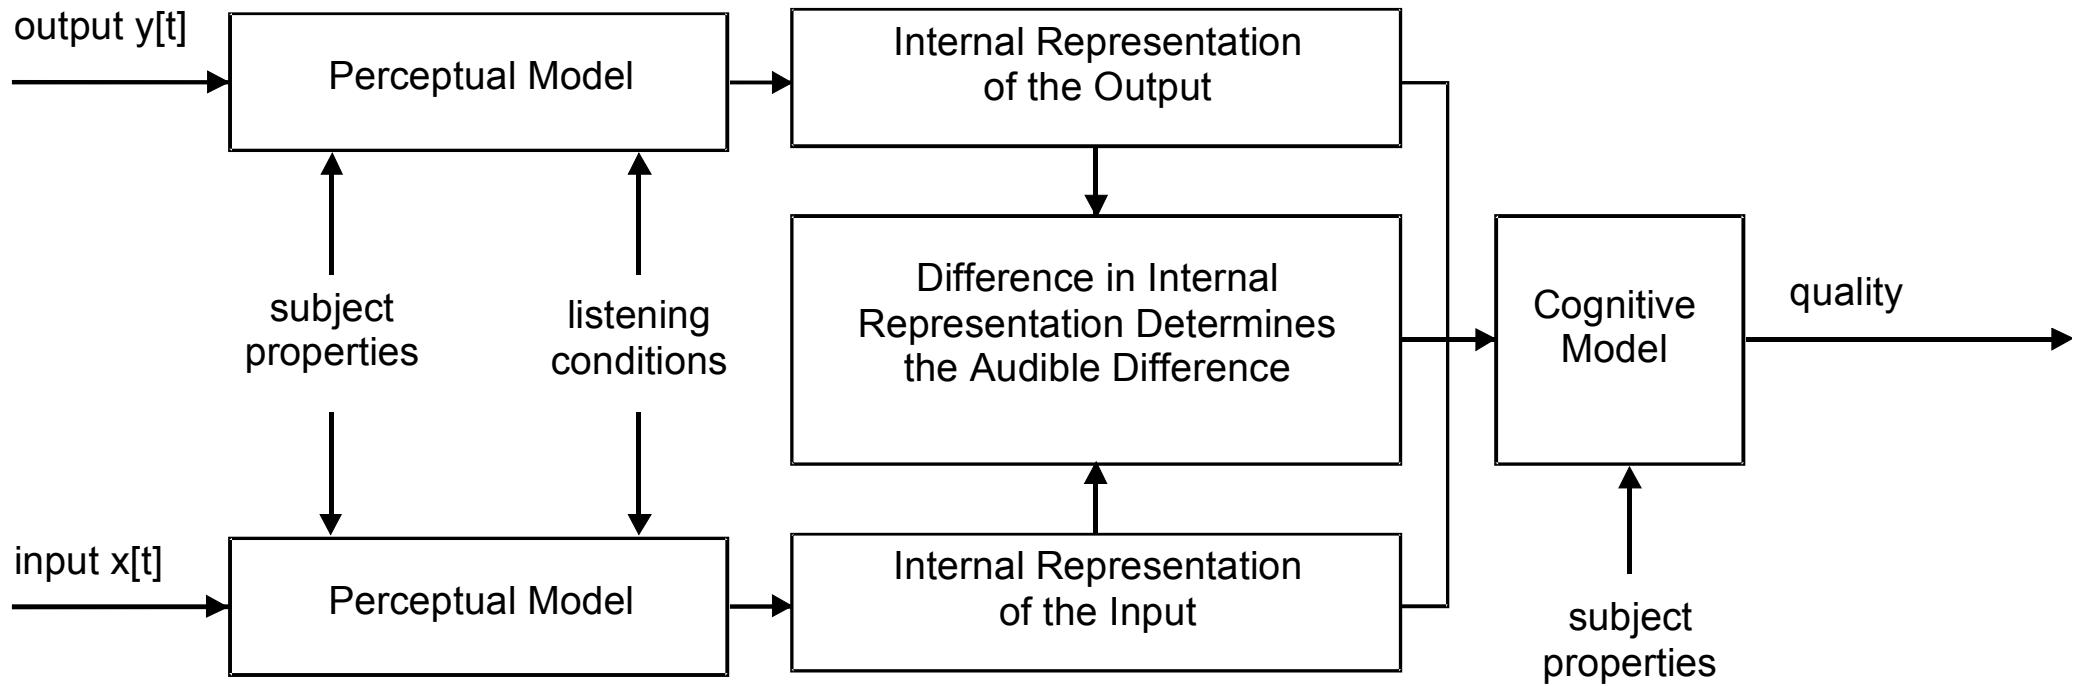
normalizované postupy vyžadují vždy skupinu posluchačů, kteří kvalitu posuzují.

- DRT (Diagnostic Rhyme Test) – měření srozumitelnosti pomocí párů podobných slov (např. meat×heat).
- DAM (Diagnostic Acceptability Measure) – soubor několika metod hodnotících kvalitu komunikačního systému.
- MOS (Mean Opinion Score) – skupina 12–64 posluchačů hodnotí kvalitu podle pětibodové stupnice. Posluchači jsou nejprve “kalibrováni” signály se známými hodnotami MOS:

MOS	kvalita	poznámka
1	bad (unacceptable)	velmi rušivý šum a artefakty v signálu
2	poor	...
3	fair	něco mezi
4	good	...
5	excellent	nerozeznatelné od originálu, bez slyšitelného šumu

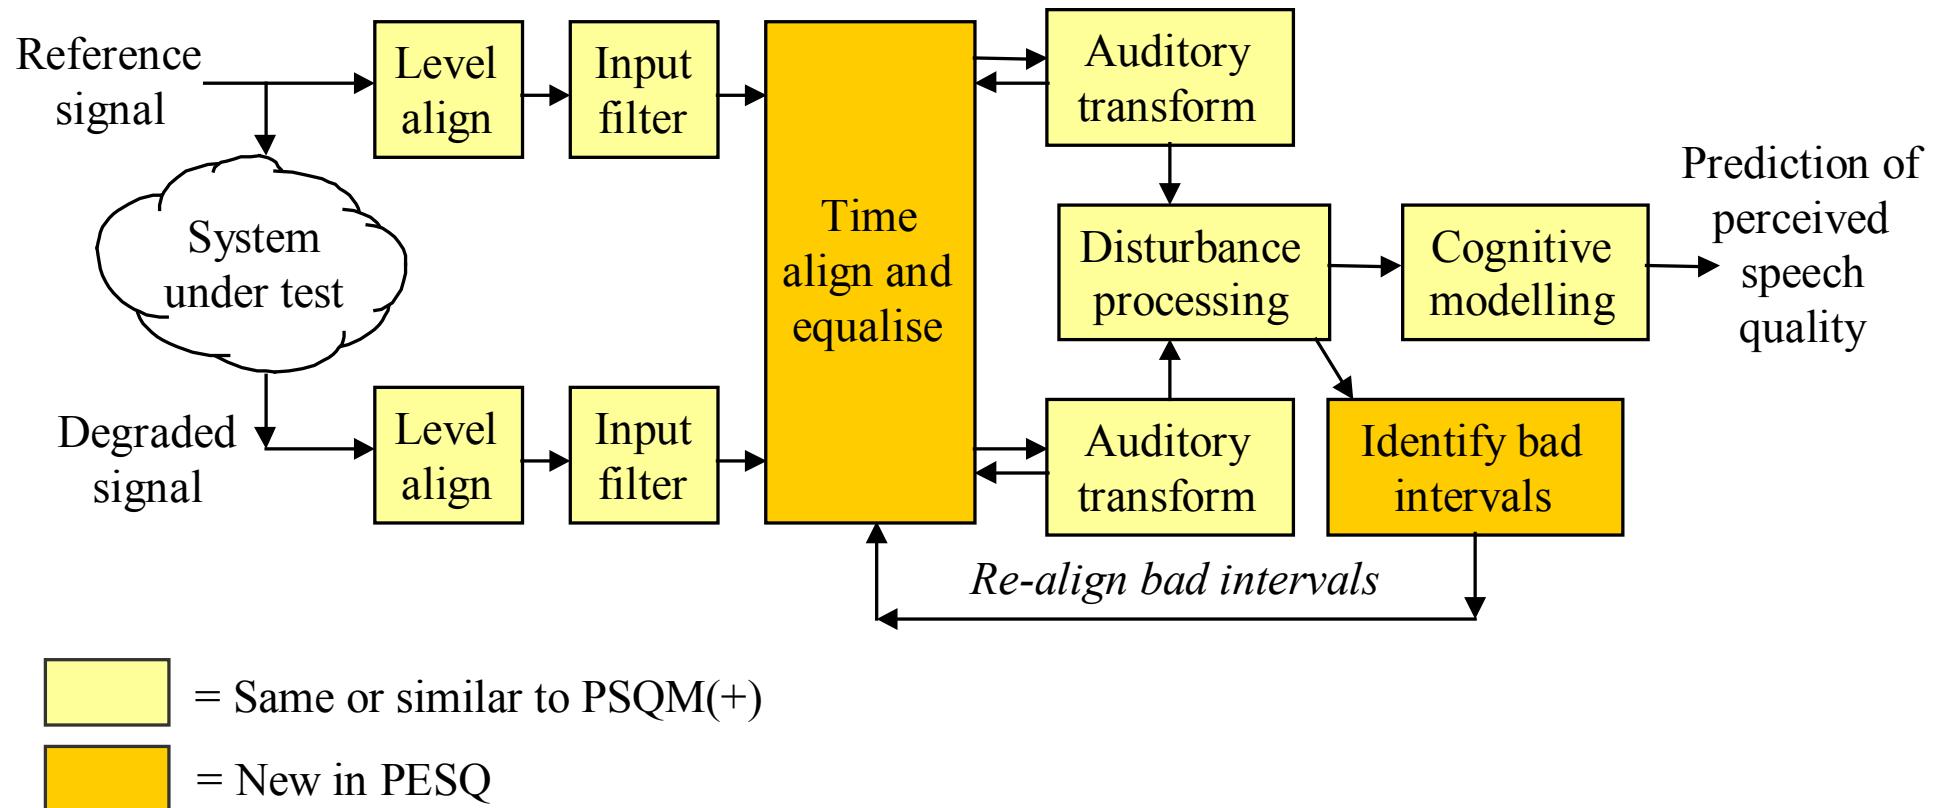
## Měření kvality inspirované lidským slyšením

### Perceptual Speech Quality Measure – PSQM



source: OPTICOM Whitepaper on "State-of-the-Art Voice Quality Testing", 2000  
ITU standard 1996, P.861.

## Perceptual Evaluation of Speech Quality – PESQ



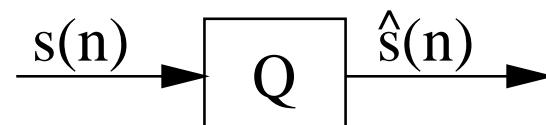
source: OPTICOM Whitepaper on "State-of-the-Art Voice Quality Testing", 2000  
ITU standard P.862

A.W.Rix et al.: Perceptual evaluation of speech quality (PESQ) a new method for speech quality assessment of telephone networks and codecs, Proc. ICASSP 2001.

## KÓDOVÁNÍ TVARU VLNY (WAVEFORM CODING)

### Pulsní kódová modulace – Pulse code modulation (PCM)

historický název, nezávislé kvantování jednotlivých vzorků pomocí fixního počtu bitů



Lineární kvantování (Q krok konstantní):

$$SNR = 6B + K \quad (3)$$

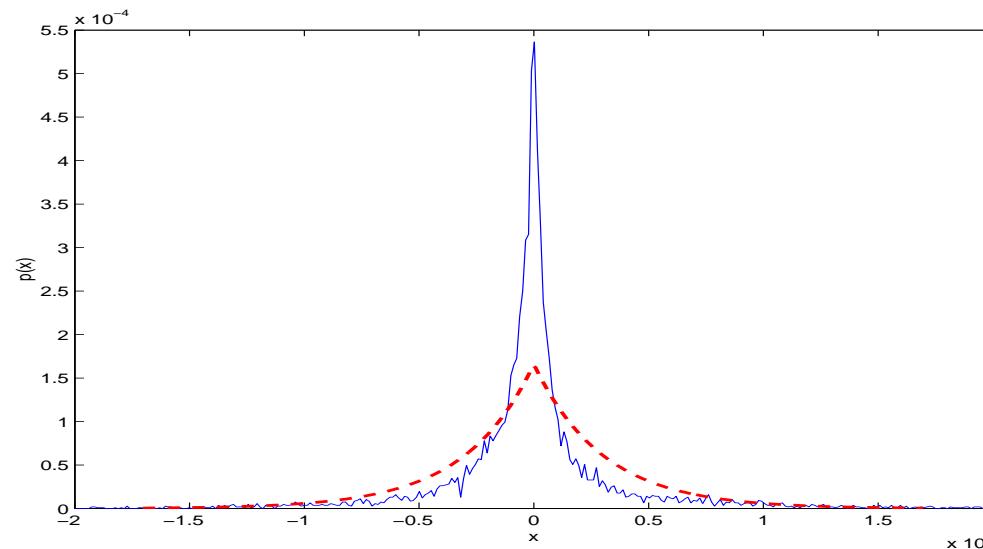
v [dB], kde  $B$  je počet bitů a  $K$  je konstanta závisející na charakteru signálu. Pro CD teoreticky:  $16 \times 6 = 96$  dB. Interpretace rovnice: přidáme-li 1 bit, SNR se zlepší o 6 dB.

Pro řečové signály ale není lin. kvantování to nevhodnější:

1. řeč obsahuje mnoho “malých vzroků”, její funkce hustoty rozdělení pravděpodobnosti (probability density function – PDF) může být approximována Laplacovým rozložením:

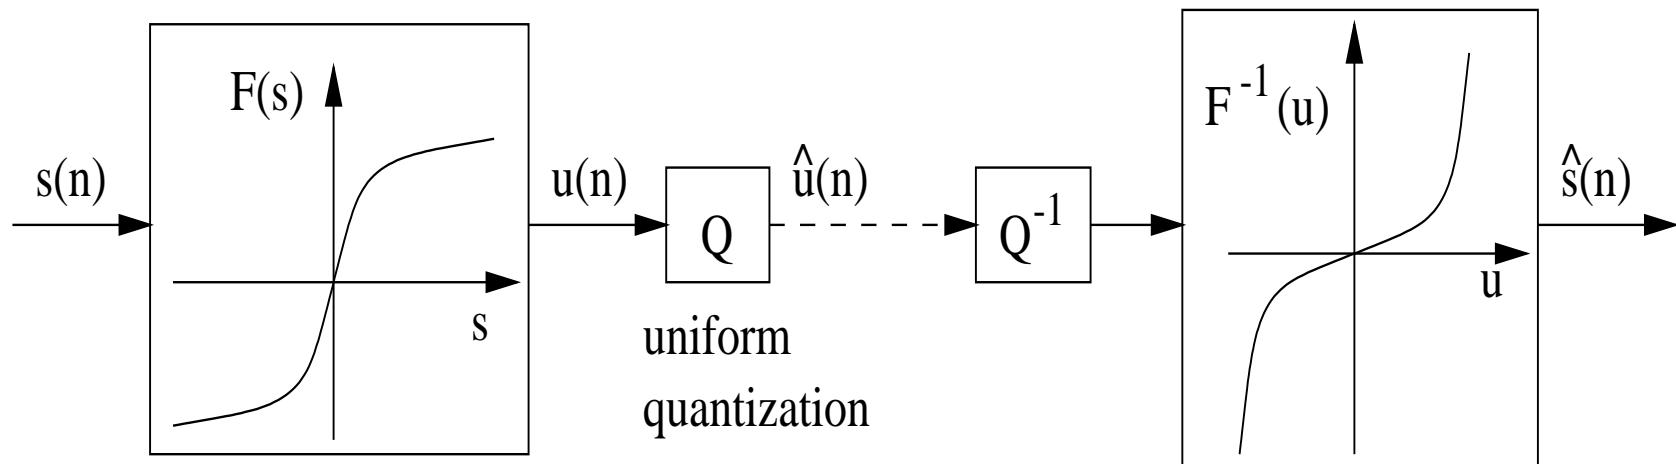
$$p(x) = \frac{1}{\sqrt{2}\sigma_x} e^{-\frac{\sqrt{2}|x|}{\sigma_x}}, \quad (4)$$

kde  $\sigma_x$  je směrodatná odchylka. Příklad: česká věta, bez ticha:



2. z perceptuálních studií víme, že ucho má logaritmickou citlivost na amplitudu akustického tlaku.

**logaritmická PCM**, komprese v kodéru a expanze v dekodéru:



Nelinearity cannot be directly log: ( $\log(0) = -\infty$ ), approximation:

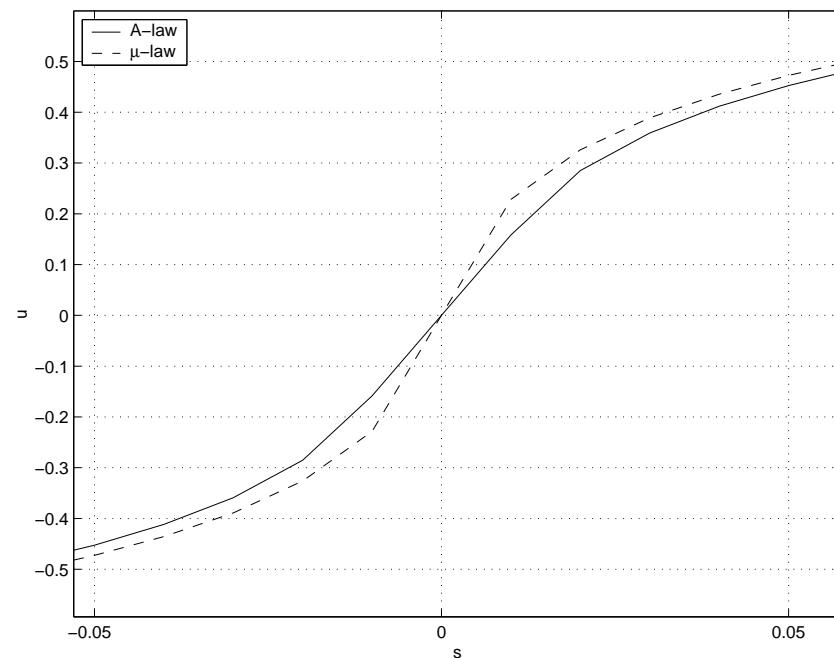
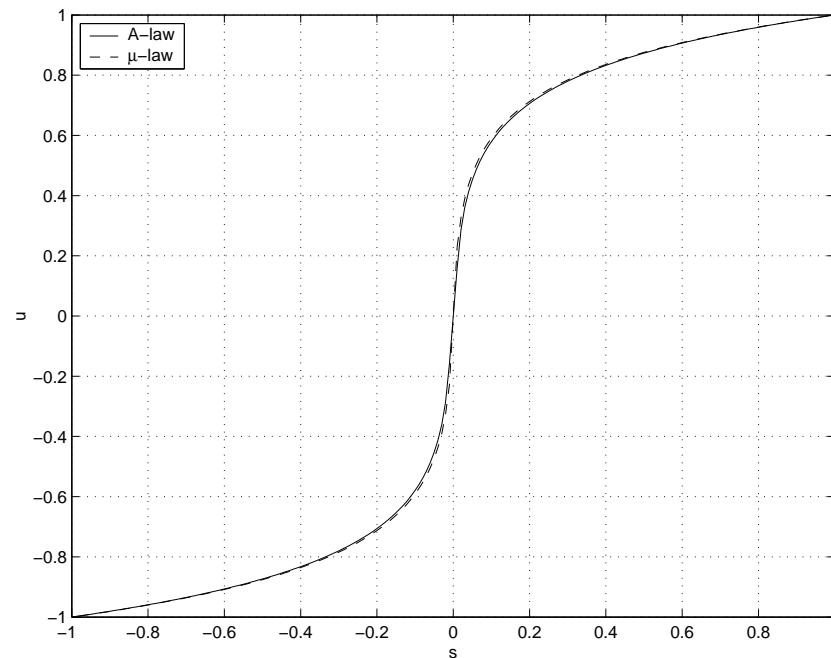
- Europe: **A-law**:

$$u(n) = S_{max} \frac{1 + \ln A \frac{|s(n)|}{S_{max}}}{1 + \ln A} \operatorname{sign}[s(n)], \quad \text{where } A = 87.56. \quad (5)$$

- USA:  $\mu$ -law:

$$u(n) = S_{max} \frac{\ln \left( 1 + \mu \frac{|s(n)|}{S_{max}} \right)}{\ln(1 + \mu)} \operatorname{sign}[s(n)], \quad \text{where } \mu = 255. \quad (6)$$

## Srovnání A-law a $\mu$ -law:



⇒ obě jsou prakticky identická, obě zlepšují SNR pro malé signály o 12 dB. Pro telefonní aplikace, log-PCM s 8 bity má podobnou kvalitu jako 13 bitů lin. CCITT G.711.

## Adaptivní pulsní kódová modulace (APCM)

Rozložení hladin se počítá z bloku několika vzorků. Informace o kvantovacích hladinách:

- se může vysílat do dekodéru jako přídavná informace, tzv. *feed-forward*.
- se může počítat také zpětně z několika minulých vzorků, které má k disposici i dekodér. V tomto případě není nutné informaci přenášet, tzv. *feed-back*.

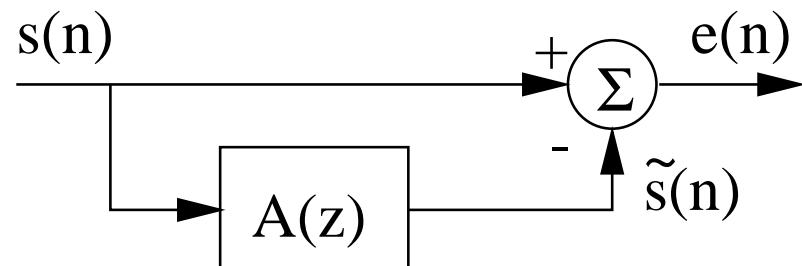
APCM se nepoužívá samostatně, ale jako součást složitějších kodérů (např. full rate GSM: RPE-LTP).

## Diferenční kódová modulace – Differential pulse-code modulation (DPCM)

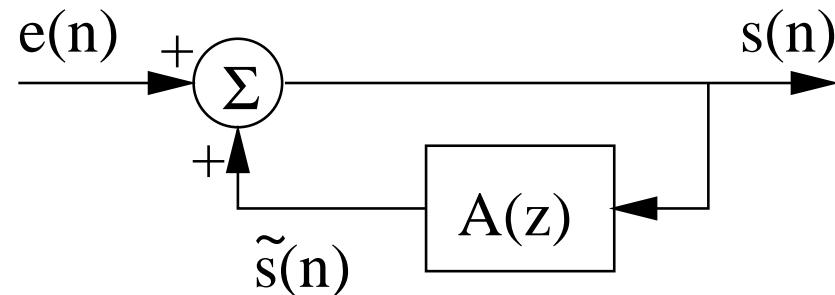
- využívá statistických závislostí mezi vzorky (jediný signál, kde jsou vzorky totálně nezávislé, je bílý šum, ten jen tak lehce nepotkáme).
- současný vzorek je odhadnut z několika předcházejících
- v případě dobrého odhadu bude mít rozdílový (chybový) signál malou energii a malou amplitudu  $\Rightarrow$  méně bitů.

$$A(z) = \sum_{i=1}^P a_i z^{-i} \quad (7)$$

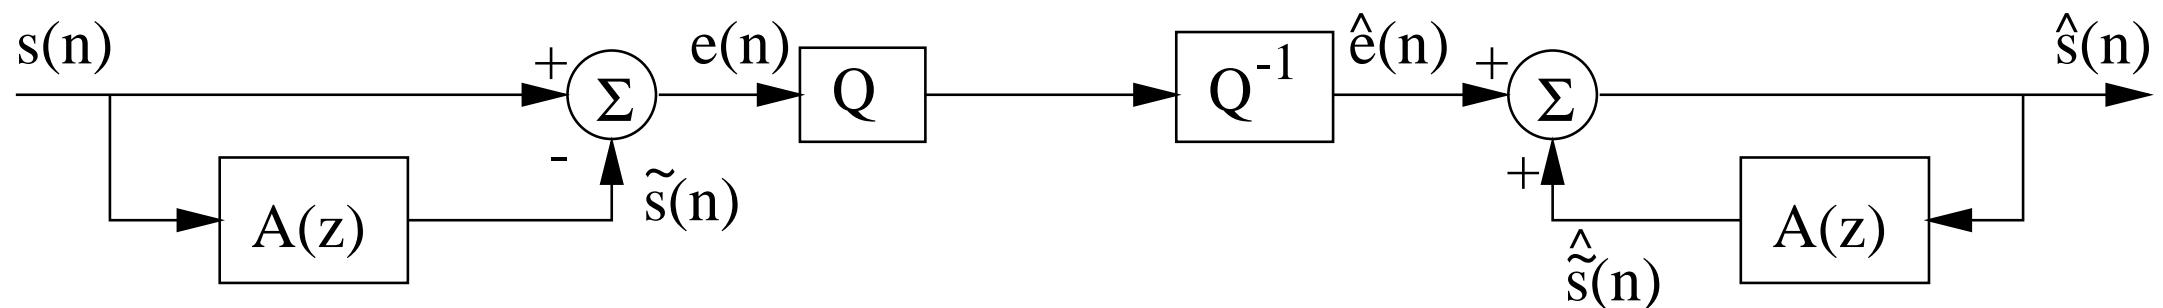
Chybový signál:



Dekodér: současný vzorek je předpovězen z předchozích a přidá se chyba:

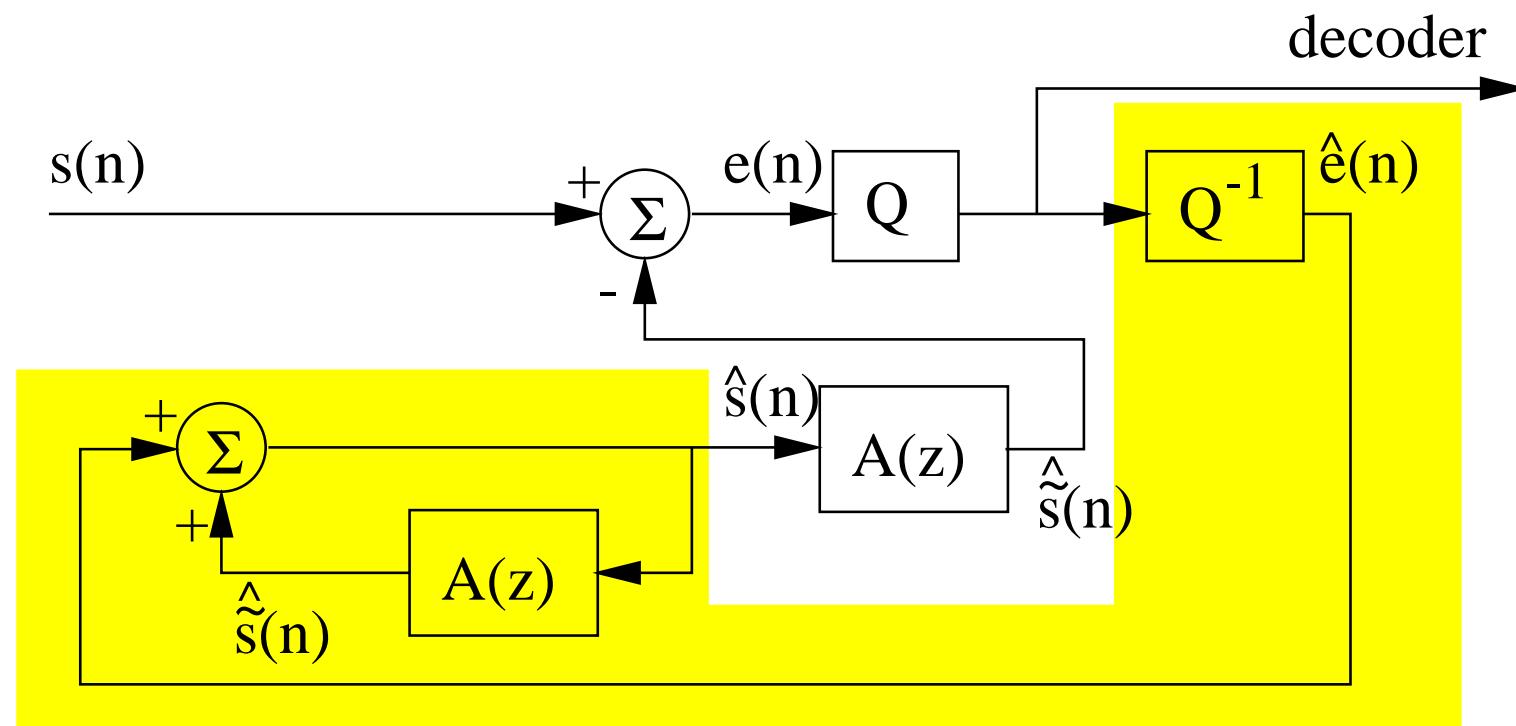


... jenže chybový signál je nutné **kvantovat**



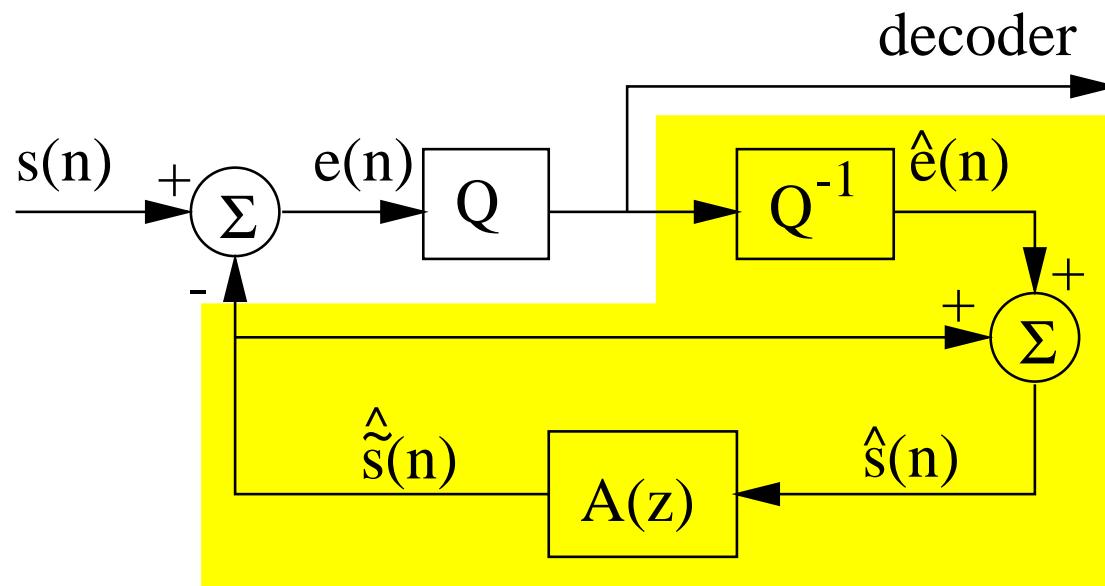
!!! V tomto případě by dekodér odhadoval současný vzorek z něčeho **jiného** než kodér !

- Kodér má:  $s(n)$ .
- Dekodér má  $\hat{s}(n)$ , který se díky kvantování  $e(n)$ , nerovná  $s(n)$  !
- Musíme dekodér "vestavět" do kodéru. Jeho výstup se využije k predikci.



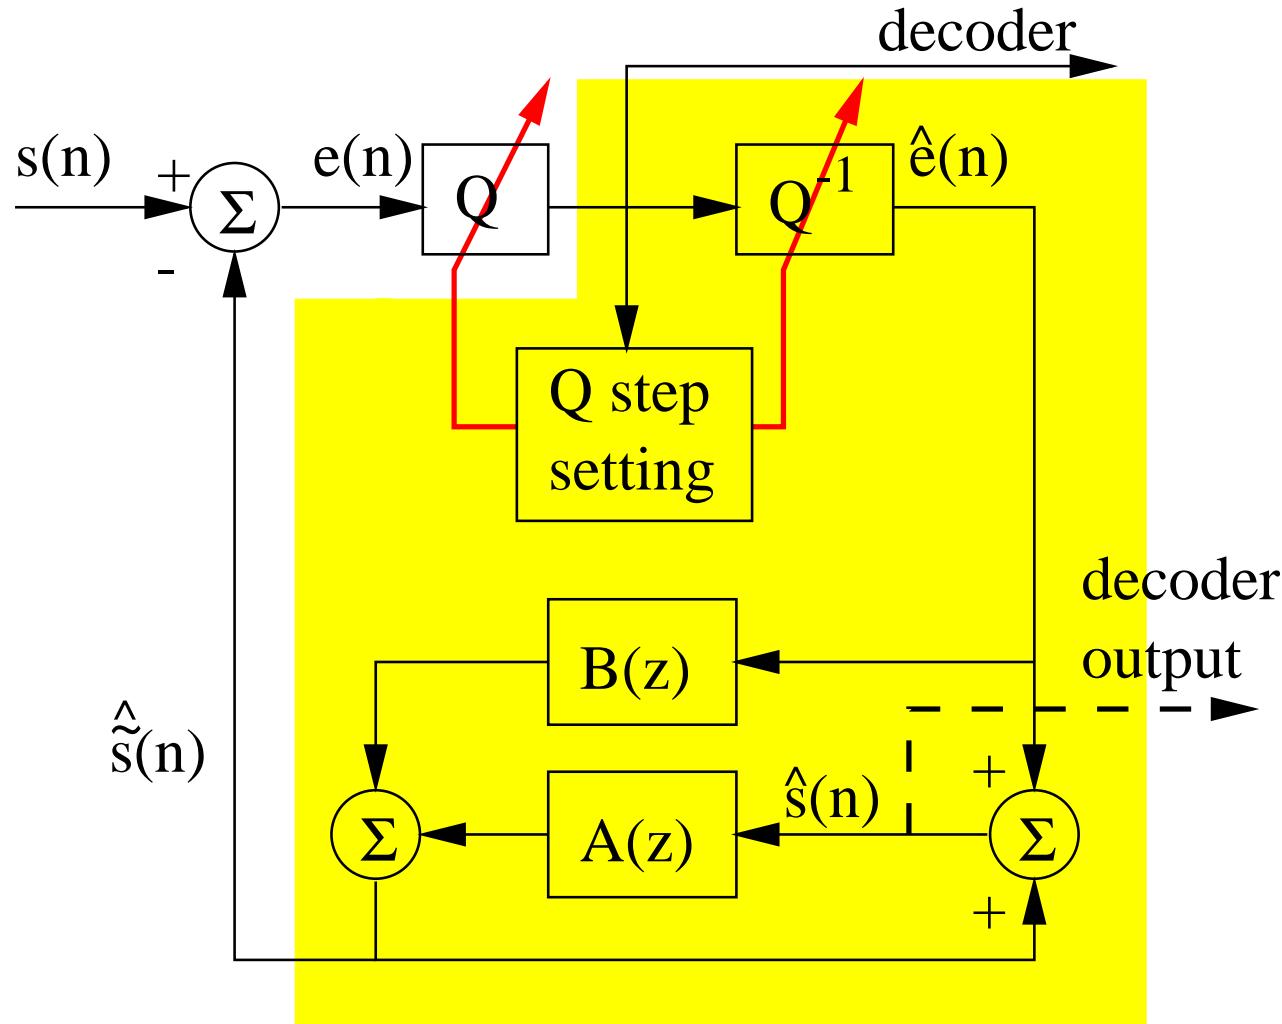
Je to dost komplikované a filtr  $A(z)$  je tam dvakrát a filtruje ten samý signál !

Zjednodušení:



Kodér opět obsahuje celý dekodér (žlutá barva).

## Adaptivní diferenční pulsní kódová modulace (ADPCM) G. 721



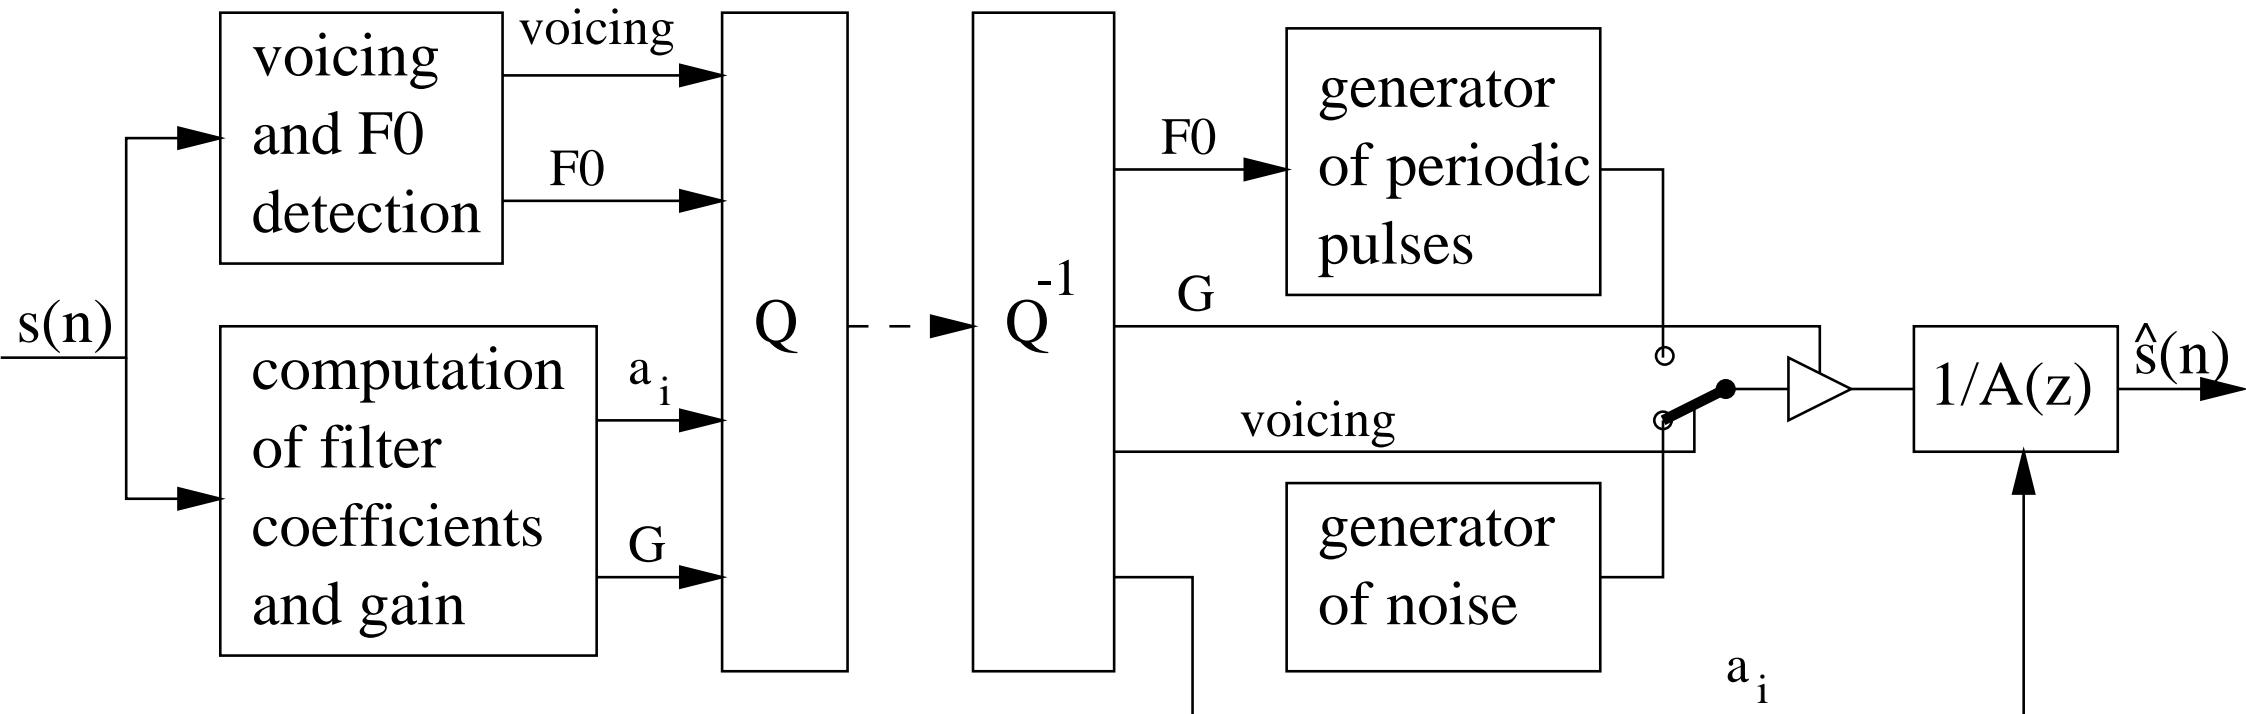
- rozdíl od DPCM - adaptace kvantovacího kroku.
- ADCPM je použito v G.721: log-PCM (64 kbit/s)  $\Rightarrow$  32 kbit/s.
- G.721 obsahuje 2 filtry pro výpočet chybového signálu  $e(n)$ :  $A(z)$  (jako minule),  $B(z)$  odhaduje vzorek chybového signálu z nekolika předešlých hodnot chybového signálu (IIR).
- Blok “Q-step setting” reguluje kvantovací krok.
- Dekodér (žlutý) je zase “schován” v kodéru.
- Informace o Q kroku a odad filtrů je založen na výstupu z kodéru (back-ward).

## VOKODÉRY

- využívají poznatků o lidském řečovém ústrojí pro redukci bitového toku.
- uspokojivě zpracovávají pouze řeč, pokud jsou jim ke kódování předloženy jiné signály (např. hudba), výsledkem je většinou “cosi podobného řeči”, samozřejmě zcela nesrozumitelného.
- využívají modelu buzení—filtr.

## Kodér založený na lineárně prediktivním modelu - LPC

Vstupní signál rozdělen na rámce, z každého je odhadnuta sada koeficientů polynomu:  $A(z) = 1 + \sum_{i=1}^P a_i z^{-i}$ . Spočten gain tohoto filtru  $G$  a je detekována znělost a v případě znělého rámce perioda základního tónu (lag).



Buzení !!!

Příklad: US-DoD FS1015 standard: filtr 1800 bps, buzení 600 bps, 2.4 kbps. Hlavní nevýhodou bylo velmi zjednodušené modelování **buzení**  $\Rightarrow$  nepřirozená řeč. Velké zlepšení v CELP kodérech.

## Residual Excited Linear Prediction – RELP

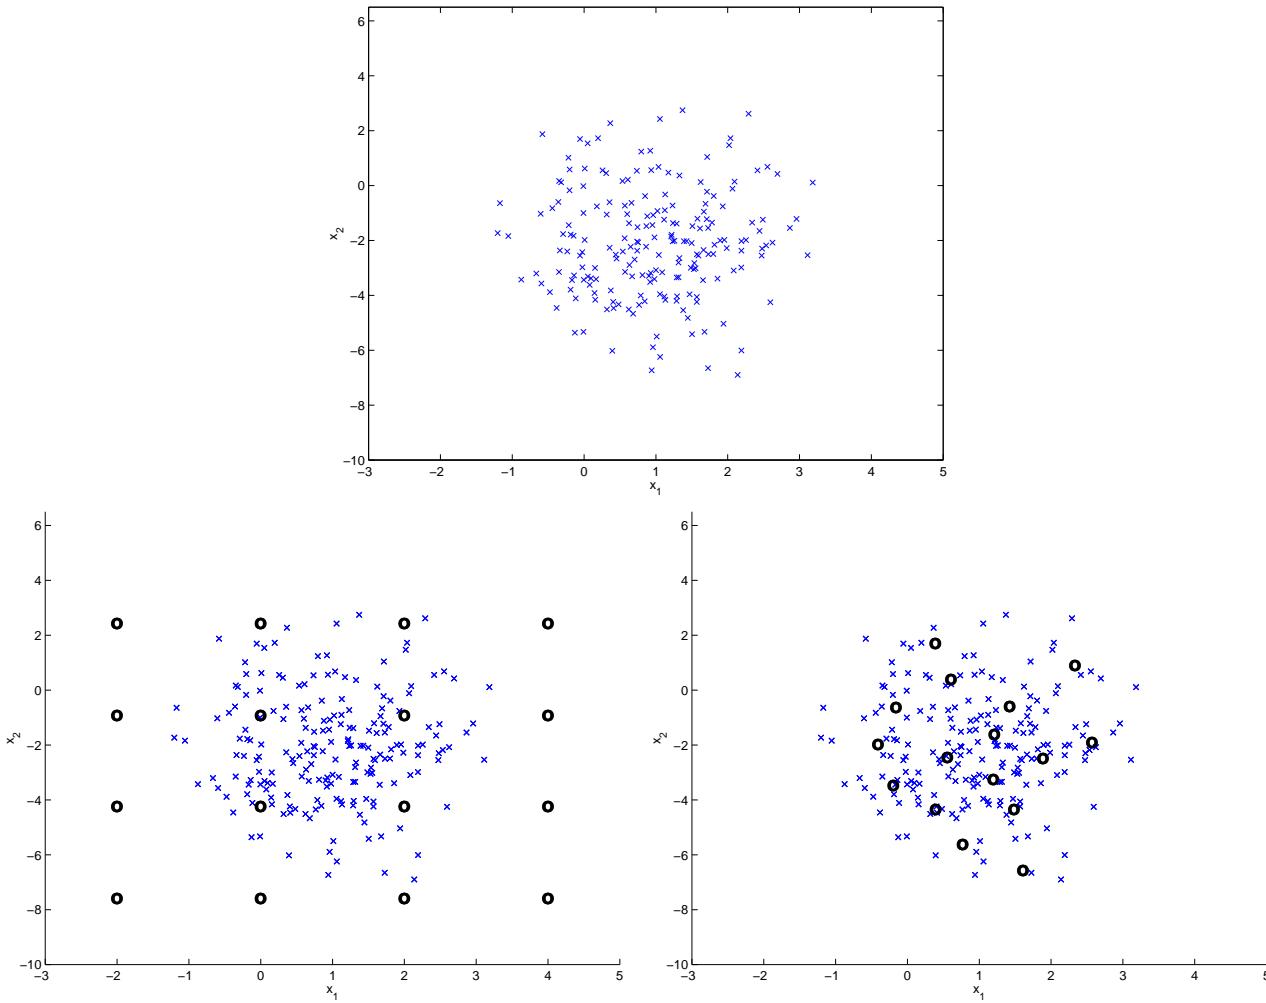
v každém rámci jsou odvozeny parametry filtru  $A(z)$  a je vypočten chybový signál  $e(n)$ :  $E(z) = A(z)S(z)$ . Tento signál je přenesen do dekodéru, kde je filtrován filtrem  $H(z) = \frac{1}{A(z)}$ . Pokud nejsou koeficienty filtru  $a_i$  ani chybový signál  $e(n)$  kvantovány, výsledkem je naprostě přesně vstupní signál  $s(n)$ .

**Zvýšení** bitového toku — Bad...

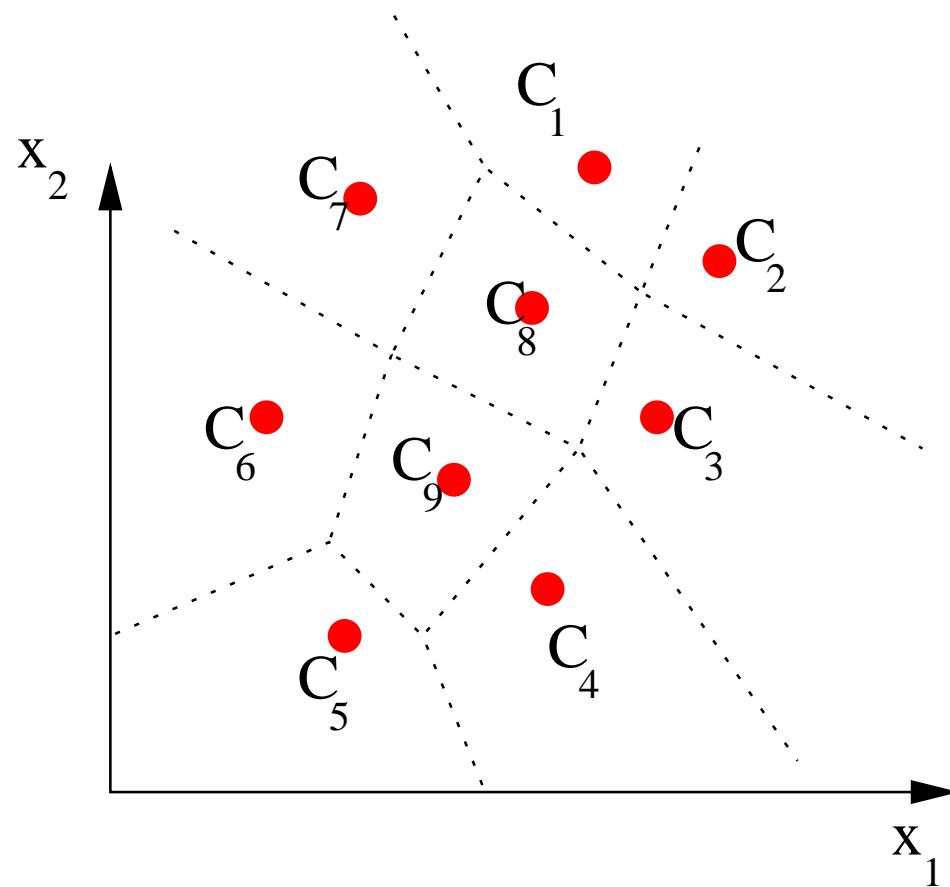
## VEKTOROVÉ KVANTOVÁNÍ

### Proč ?

- Kódování  $P$ -dimenzionálních vektorů je velmi nákladné ( $P$  floatů je  $P \times 4$  byte...)
- Skalární kvantování jednotlivých složek je plýtvání bity.
- Lepší je umístit do  $P$ -rozměrného prostoru “typické” vektory a na ně “zaokrouhlovat”.



## Kódové vektory, centroidy, Voronoiový regiony...



## Trénování kódových vektorů — $K$ -means

kódové vektory je nutné natrénovat na datech.

- máme k disposici  $N$  trénovacích vektorů.
- chceme kódovou knihu (codebook)  $\mathbf{Y}$  o velikosti  $K$ .
- **Inicialisace:**  $k = 0$ , definujeme  $\mathbf{Y}(0)$ .
- **Step 1:** přiřazení vektorů jednotlivým buňkám “kódování”:

$$Q[\mathbf{x}] = \mathbf{y}_i(k) \quad \text{if} \quad d(\mathbf{x}, \mathbf{y}_i(k)) \leq d(\mathbf{x}, \mathbf{y}_j(k)) \quad \text{pro} \quad j \neq i, \quad j \in 1 \dots K \quad (8)$$

Jako  $d(\mathbf{x}, \mathbf{y}_j)$  je možné použít Euklidovu vzdálenost:

$$d(\mathbf{x}, \mathbf{y}) = \sqrt{(\mathbf{x} - \mathbf{y})^T (\mathbf{x} - \mathbf{y})} = \sqrt{\sum_{k=1}^P |x_k - y_k|^2}. \quad (9)$$

Po zakódování “patří” vektor  $\mathbf{x}$  do buňky  $C_i(k)$  ( $k$  je index “generace” kódové knihy).

- **Step 2:** Vyhodnocení kvality kódové knihy – totální vzdálenost (zkreslení):

$$D_{VQ} = \frac{1}{N} \sum_{n=1}^N d(\mathbf{x}(n), Q[\mathbf{x}(n)]) . \quad (10)$$

- **Step 3:** pokud je relativní zlepšení zkreslení pod předem definovaným prahem:

$$\frac{D_{VQ}(k-1) - D_{VQ}(k)}{D_{VQ}(k)} \leq \varepsilon, \quad (11)$$

STOP a prohlásíme  $k$ -tou generaci kódové knihy za výsledek.  $\mathbf{Y} = \mathbf{Y}(k)$ . Pokud stále zlepšení, pokračujeme:

- **Step 4:** Spočítáme nové centroidy buněk, stanou se z nich nové kódové vektory:

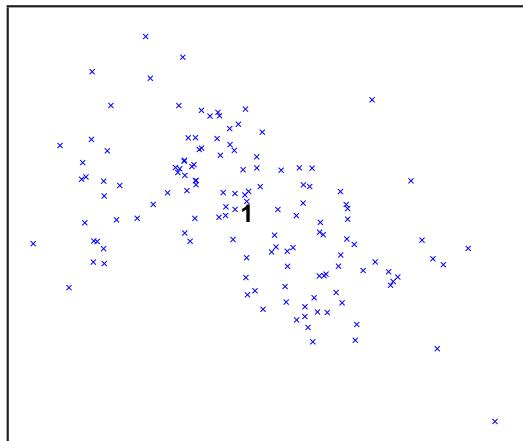
$$\mathbf{y}_i(k+1) = Cent(C_i(k)) = \frac{1}{M_i(k)} \sum_{\mathbf{x} \in C_i(k)} \mathbf{x}, \quad (12)$$

kde  $M_i(k)$  je počet trénovacích vektorů, které pro  $k$ -tou generaci kódové knihy spadly do buňky  $i$ . Jedná se o běžný aritmetický průměr. Inkrement:  $k = k + 1$ , GOTO Step 1.

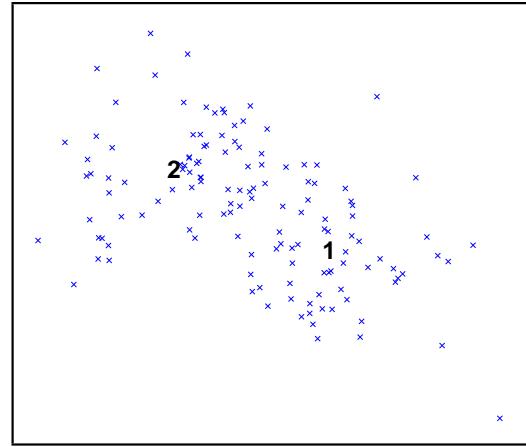
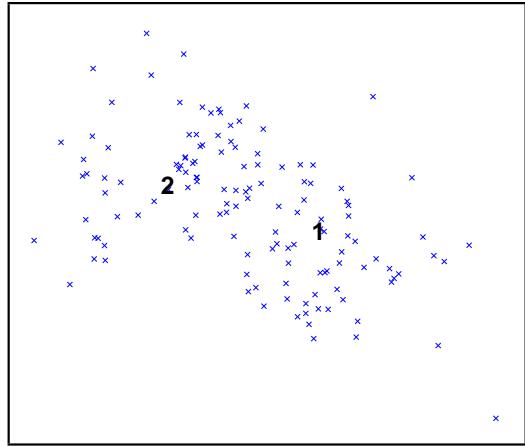
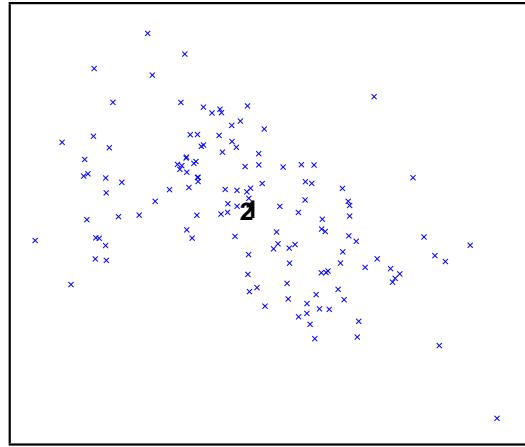
## Linde-Buzo-Gray — LBG

- Algoritmus  $K$ -means má problémy s inicializací (jak inicializovat  $\mathbf{Y}(0)$  – náhodně ? náhodným výběrem vektorů ?)
- může se stát, že při trénování na některý kód. vektor nezbydou žádné trénovací vektory  $\Rightarrow$  dělení nulu  $\Rightarrow$  crash :-(
- LBG řeší postupným štípáním vektorů v kódové knize:

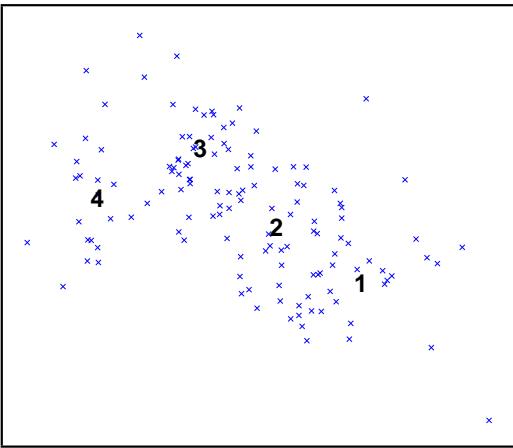
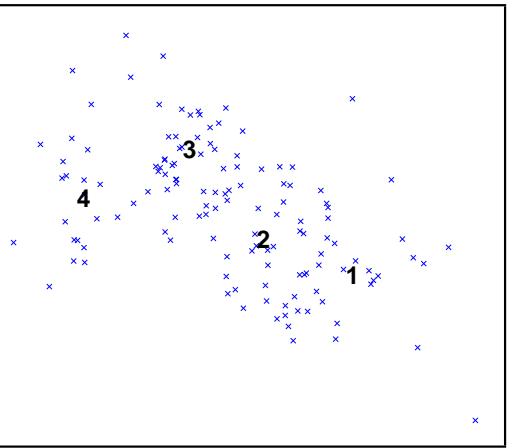
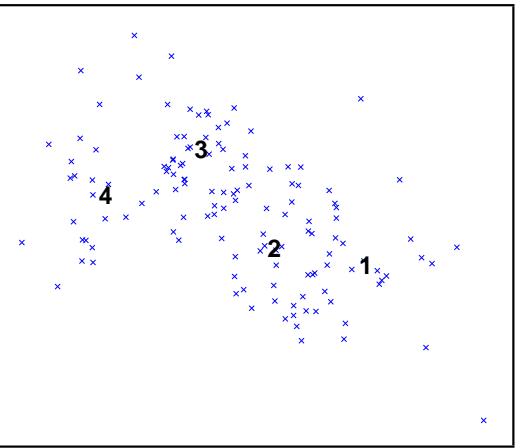
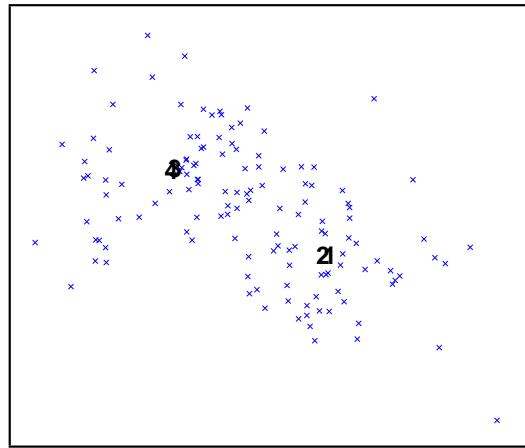
$$r = 0, L = 1$$



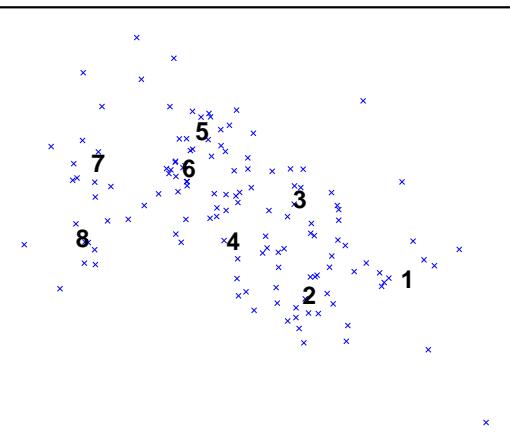
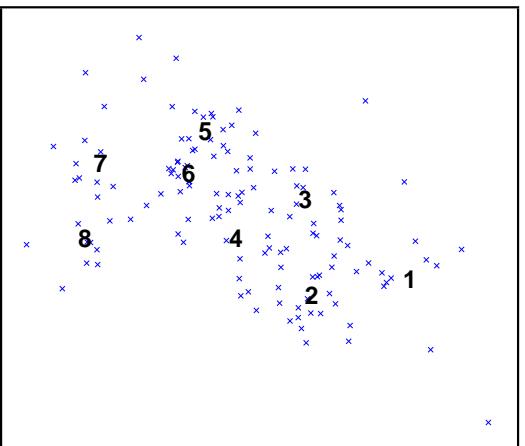
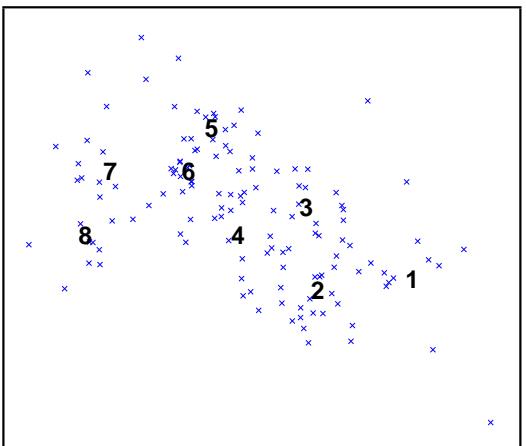
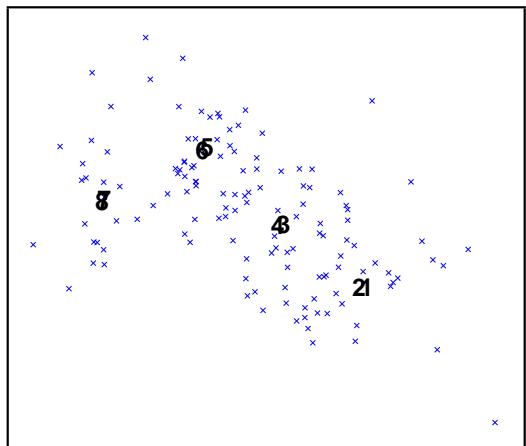
$r = 1, L = 2$



$r = 2, L = 4$



$r = 3, L = 8$



## Kde se VQ používá

1. kódování koeficientů filtru  $a_i$  (nejčastější jsou převedeny na něco vhodnějšího: PARCOR, LAR or LSF).
2. kódování buzení v CELP-like algoritmech, blocky vzorků po krátkodobém prediktoru a  $A(z)$  a dlouhodobém prediktoru  $B(z)$ .

## Varianty VQ

Trénování kódové, ale v případě velkých  $K$  i kódování jsou velmi výpočetně náročné  
⇒ varianty.

- split-VQ: vektor je rozdělen na několik sub-vektorů s méně koeficienty. Použití několika menších codebooků. (typicky 3-3-4 pro  $P=10$ ).
- algebraická VQ: kódové vektory nejsou rozmístěny libovolně, ale jejich pozice jsou deterministické (např. uniformě na hyper-ploše), není nutné porovnávat vstup se všemi kódovými vektory.
- náhodný codebook (pro trénování): pro velká  $K$  se kvalita natrénovaného codebooku blíží náhodnému ⇒ trénování není potřeba!
- tree-structured VQ: zapamatujeme si generace při trénování LBG a předpokládáme, že když byl vektor  $\mathbf{y}^k$  v generaci  $k$  kódové knihy přiřazen nějakému kódovému vektoru, pak pro generaci  $k+1$  může náležet jen jeho dětičkám ⇒ suboptimální, ale potřebuje jen  $2 \log_2 K$  srovnání na rozdíl od  $K$ .
- multi-stage VQ: jsou použity 2 codebooky, ve druhém se kvantuje chyba prvního. Při dekódování jsou kódové vektory z obou sečteny.