


Spektrálne charakteristiky signálu




Euklidovská vzdialenosť




Obsah

- Spektrálna analýza na báze DFT
- LPC spektrálna analýza
- Dlhodobá spektrálna analýza
- Kepstrálna analýza
- Koherenčné charakteristiky viackanálových signálov
- Momentové charakteristiky



Rozdelenie


- Metódy spektrálnej analýzy pre spracovanie reči sa zvyčajne delia podľa dvoch hľadísk:
- Podľa metódy spracovania
 - Klasické metódy používajúce DFT
 - Parametrické metódy
 - Pre reč: lineárna predikčná analýza - LP
- Podľa dĺžky spracovávaného signálu
 - Krátkodobá analýza
 - Dlhodobá analýza



Spektrálna analýza na báze **DFT**

- definované *Fourierovou transformáciou*
- Spektrum diskrétného signálu je *spojité* a *periodické* s periódou ekvivalentnou F_{vz} .
- DFT spektrum spočítané z N vzoriek signálu potom obsahuje N vzoriek jednej periódy spojitého diskrétného signálu (ak neurčíme ináč).
- Pri analýze reči je významné hlavne amplitúdové spektrum $|X[k]|$.
- Dôležitá charakteristika – *výkonová spektrálna hustota*.

Spektrálna analýza na báze **LPC**




- je štandardným nástrojom analýzy rečového signálu.
- Predpokladajme, že reč je modelovaná *autoregresným (AR) modelom*,
 - kde budúcu vzorku je možné predikovať lineárnou kombináciou p minulých vzoriek (teda lineárnym prediktorom p -tého rádu).
 - **Cieľom analýzy je určiť koeficienty tejto lineárnej kombinácie tak, aby energia chyby predikcie bola minimálna:**

(1)

$$e[n] = x[n] - \tilde{x}[n] = x[n] + \sum_{k=1}^p a_k x[n-k]$$

- **Parametrický popis analyzovaného signálu potom predstavujú koeficienty a_k nazývané autoregresné koeficienty signálu.**
- Je možné ukázať, že minimalizácia chyby predikcie vedie k dekorelovanosti vzoriek chybového signálu, ktorý má potom charakter bieleho šumu.
- Rovnica 1 je **diferenčnou rovnicou FIR filtra s prenosovou funkciou $A(z)$.**

LPC spektrálna analýza



- Ak má chybový signál charakter bieleho šumu, znamená to, že spektrálne vlastnosti signálu $x[n]$ sú určené frekvenčnou charakteristikou filtra → **syntetizujúci filter AR modelu**
 - Jeho prenosová funkcia je inverzná k prenosovej funkcii $A(z)$.
 - Spektrum analyzovaného signálu $x[n]$ je modelované frekv. charakteristikou prenosovej funkcie:


$$H(z) = \frac{G}{A(z)} = \frac{G}{1 + \sum_{k=1}^p a_k \cdot z^{-k}}$$

- **LPC spektrum** (=vyhladený odhad spektrálnej výkonovej hustoty) je definované:

$$S_x(e^{j\theta}) = \left| H(e^{j\theta}) \right|^2 = \frac{G^2}{\left| A(e^{j\theta}) \right|^2}$$





Diskrétne LPC spektrum $S_x[k]$ s N vzorkami dostaneme dosadaním za $\theta = k \cdot f_s / N$

LPC spektrálna analýza




- Jadro analýzy na báze LP spočíva vo výpočte parametrov AR modelu a_k a zisku G pomocou autokorelačnej matice signálu => Levinson-Durbin.
- Rád modelu sa volí podľa počtu formantov, ktoré chceme pozorovať. Typické hodnoty sú $p=12$ (maximálne 6 formantov, pri $f_{vz} = 8\text{kHz}$).
- LPC spektrum predstavuje vyhladený odhad spektra analyzovaného signálu.
- Oproti DFT spektru je LPC spektrum vždy hladké, lebo:
 - Nie je v ňom obsiahnutá informácia o periodicite! Táto informácia je v chybovom signáli, ktorého tvar charakterizuje typ budenia.



Príklad: odhad spektr. hustoty výkonu pomocou DFT a LPC na znelom a neznelom rámcí



Dlhodobá spektrálna analýza




- Dlhodobá analýza – analýza takého úseku signálu, kde sa už prejavuje nestacionarita reči
 - Periodogram alebo spektrálna hustota výkonu (získaný Welchovou metódou)
- Dlhodobá analýza je nevhodná pre analýzu spektrálnych charakteristík reči!
- Ale je možné ju použiť pre získanie kvalitatívnej informácie o rozdieloch spektra reči a šumového pozadia.
- Pre sledovanie vývoja reči sa používa prevažne krátkodobé amplitúdové spektrum usporiadané do **spektrogramu**.



Kepstrálna analýza

Problém oddelenia budenia a vplyvu artik. traktu

- pre oddelenie budenia a vplyvu artikulačného traktu (modifikácie) – v kódovaní sa s nimi pracuje lepšie oddelene, pri rozpoznávaní reči, budenie zahadzujeme úplne (budenie je príliš závislé na rečníkovi, nálade a pod.)
- **1. možnosť:** odfiltrujeme frekvencie pod 400Hz (max. hlasivkova frekv. je cca 400Hz) a zbavíme sa základného tónu ...
 - nebude to fungovať, lebo:
 - násobky základného tónu sú „rozsiate“ po celom spektre.
 - mohli by sme prísť o prvý formant
 - telefónne pásmo začína na hodnote 300Hz.
 - odstránenie informácie o výške hlasu hovoriaceho
 - potrebujeme lepší spôsob



CEPSTRUM


- Problém! Budenie $g(t)$ je konvoluované s impulznou odozvou filtra:

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


- teda vo frekv. oblasti súčin:

$$S(f) = G(f)H(f).$$

- Ani v jednej oblasti nejde tieto dve zložky dobre oddeliť.
- Riešenie: ***nonlinearita***, ktorá prevedie súčin na súčet



Kepstrálna analýza




- **Inverzná Fourierová transformácia logaritmu komplexného spektra.**
- Ak nepotrebujeme fázovú informáciu stačí nám amplitúdové spektrum.

$$c_n = IDFT \{ \ln |X[k]| \} = \sum_{k=0}^{N-1} \ln |X[k]| e^{jkn \frac{2\pi}{N}}$$

- **Koeficienty c_n nazývame (reálnym) kepstrom signálu**
- Použitie logaritmu umožňuje vykonať dekonvolúciu vstupného signálu, ak je jedna z jeho zložiek periodická postupnosť impulzov => možnosť použiť na meranie periodicity
- Kepstrálna transformácia prevádza pôvodné vzorky (periodické a neperiodické) signálu $x[n]$ na ich súčet.
 - Ak je neperiodická zložka (sústredená okolo nulových kviefrencií) silno utlmená, je možné ju od periodickej zložky oddeliť jednoduchým výberom (lifráciou) koeficientov c_n .
- Výber koeficientov ovplyvňuje tvar spektra signálu. Pri výbere malého počtu (napr. 10) prvých kepstrálnych koeficientov získame aproximáciu spektra signálu (vyhladené spektrum).

Kepstrálna analýza




- Je možné ju použiť aj pre výpočet euklidovskej vzdialenosti.
- Spojenie kepstrálneho popisu signálu a nelineárnej frekvenčnej osi (výsledkom môžu byť MFCC koeficienty) umožňuje aproximáciu fyziológie počutia a je odolnejšie voči šumom ako AR koeficienty.
- Reálne *kepstrum* je možné získať aj pomocou AR koeficientov, ak rozvinieme prirodzený logaritmus zo vzťahu pre výpočet kepstra do Taylorovho radu a vykonáme deriváciu rádu aj logaritmu podľa premennej z získame rekurentný vzťah pre koeficienty a_n a c_n :

$$c_0 = \ln G$$

$$c_n = -a_n - \frac{1}{n} \sum_{k=1}^{n-1} (n-k)a_k c_{n-k}$$

- Ak vypočítame kepstrum z AR koeficientov, dostaneme vyhladené LPC kepstrum.

Definícia kepstra



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


- $G(f)$ je *spektrum budenia*
- Hodnoty $c(n)$ sú *kepstrálne koeficienty*.
- Nakoľko je $G(f)$ párna funkcia, sú $c(n)$ **reálne** a platí: $c(n) = c(-n)$
- Suma v rovnici je definíciou **DFT**, preto môžeme $c(n)$ vypočítať ako:

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

Terminológia:


spektrum	→	cepstrum
frekvency	→	quefreny
filtrng	→	liftring

Mel-frequency cepstrum - MFCC




- **DFT** má všade **rovnomerné frekvenčné rozlíšenie**
- *ľudské ucho* má na nízkych frekvenciách väčšie rozlíšenie než na vysokých -
nonlinearita
- Napr. Pre účely rozpoznávania reči chceme **priblížiť kepstrum akustickým vlastnostiam ucha.**
- Ako na to?
 - na frekvenčnú os rozmiestnime **nelineárne filtre**, meriame energiu na ich výstupe a použijeme ju namiesto DFT pri výpočte kepstra.
 - **frekvenčnú os** môžeme **nelineárne upraviť** a na upravenú os potom filtre rozmiestniť rovnomerne



Používaná **nelineárna úprava** využíva prevod $Hz \rightarrow Mel$:



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



- Lineárne rozmiestnenie filtrov na Mel-ovej osi má za následok **nelineárne rozmiestnenie** na štandardnej frekvenčnej osi v Hz.



Výpočet energie:


1. Skonstruujeme banku filtrov, vstupný signál filtrujeme v časovej oblasti a počítame energiu:

$\sum_n s_i^2(n)$... je to veľmi komplikované!

2. Vykonáme DFT, umocníme, vynásobíme trojuholníkovým oknom a spočítame.

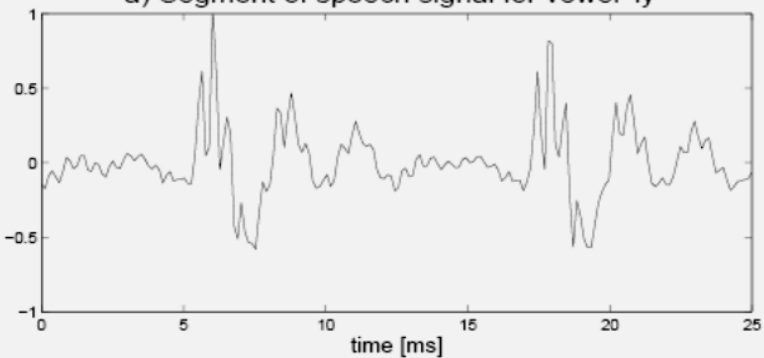
Spätnú FT môžeme realizovať pomocou diskkrétnej kosínusovej transformácie (DCT):

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

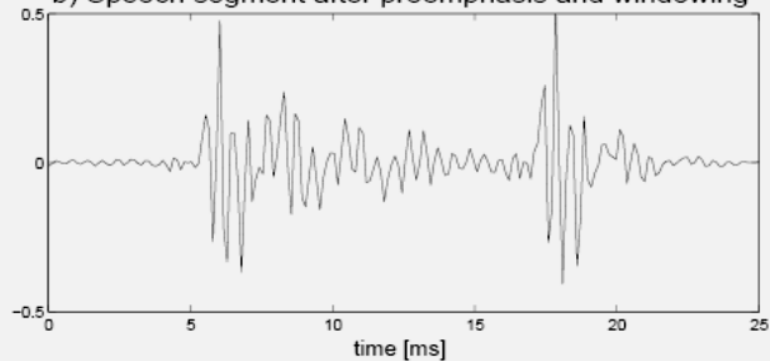


Mel-frekvenčné cepstrálne koeficienty (MFCC)


a) Segment of speech signal for vowel 'iy'




b) Speech segment after preemphasis and windowing



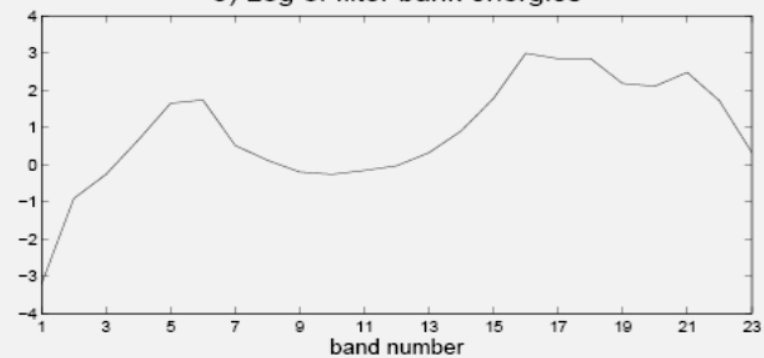
c) Fourier spectrum of speech segment



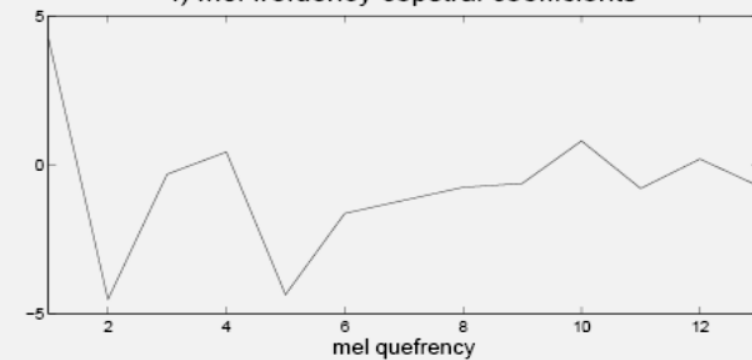
d) Filter bank energies – smoothed spectrum




e) Log of filter bank energies



f) Mel frequency cepstral coefficients





Koherenčné charakteristiky viackanálových signálov.


- *Koherenčná funkcia pre dvojicu signálov rozširuje informácie o vzájomnej korelovanosti medzi analyzovanými signálmi.*
- Na rozdiel od korelácie *je koherencia medzi dvoma signálmi definovaná vo frekvenčnej oblasti a vyjadruje mieru korelovanosti medzi jednotlivými signálmi pre jednotlivé frekvenčné zložky.*
- Často používanou charakteristikou je *kvadrát modulu koherenčnej funkcie* označovaný ako **MSC** (Magnitude Squared Coherence):

$$\gamma_{xy}^2[k] = \frac{|S_{xy}[k]|^2}{S_x[k]S_y[k]}$$

- Kde $S_x[k]$ a $S_y[k]$ sú odhady spektrálnej výkonovej hustoty signálov $x[n]$ a $y[n]$ a $S_{xy}[k]$ je odhad vzájomnej spektrálnej výkonovej hustoty:

$$S_{xy}[k] = \frac{1}{M} \sum_{i=0}^{M-1} \frac{1}{N} X_i^*[k]Y_i[k]$$


Nutné vychádzať z vyhladených odhadov spektra!!!



Koherenčné charakteristiky viackanálových signálov

- Výhody:
 - Koherenčná funkcia nie je veľmi citlivá na posun signálov, ak je menší ako dĺžka analyzovaného segmentu
 - Koherencia poskytuje informáciu o korelovanosti jednotlivých fr. zložiek.
- Ak rečový signál vychádza z jedného zdroja (úst, reproduktora) a je snímaný vo viacerých kanáloch je silne korelovaný v celom frekv. rozsahu a hodnota MSC sa blíži k 1.
- Naproti tomu, ak šum pozadia nevychádza z jedného zdroja (odrazy reči, hluk v miestnosti, zvuky automobilu) koherencia je podstatne nižšia. => vhodnosť koherenčnej charakteristiky pre detekciu reči v šumovom pozadí.

Momentové charakteristiky





- Prvý spektrálny moment je váhovaným priemerom spektrálnych čiar:

$$mom_1 = \frac{\sum_{k=1}^{N/2} k |X[k]|}{\sum_{k=1}^{N/2} |X[k]|}$$


- Predstavuje **ťažisko rozloženia amplitúd jednotlivých spektrálnych zložiek**.
- Druhý spektrálny moment je ekvivalentný statickému rozptylu a **je indikátorom rozprestretia spektra**:

$$mom_2 = \sqrt{\frac{\sum_{k=1}^{N/2} k^2 |X[k]|}{\sum_{k=1}^{N/2} |X[k]|} - (mom_1)^2}$$

- Vyššie hodnoty majú tie hlásky, ktorých energia je viac rozprestretá cez celé spektrum.



Euklidovská vzdialenosť



Euklidovská vzdialenosť

- Pre klasifikáciu reči (hlások) do fonetických tried sa používajú rôzne druhy parametrov, ktoré vytvárajú parametrické vektory s rôznou dĺžkou (LPCC, MFCC).
- Ak máme fonetické triedy popísané množinou M parametrov, potom najjednoduchším rozhodnutím o zaradení pozorovaných dát do týchto tried je využitie **euklidovskej vzdialenosti**:

$$d = \sqrt{\sum_{m=1}^M (r[m] - o[m])^2}$$

- Kde $r[m]$ je M parametrov (vektor) referenčného vzoru
- A $o[m]$ je M parametrov (vektor) pozorovaného úseku signálu