

Dialogové systémy

Rozpoznávání řeči

Luděk Bártek

Laboratoř vyhledávání a dialogu, Fakulta Informatiky Masarykovy Univerzity,
Brno

jaro 2016

Zpracování digitalizovaného signálu

Úvod

Dialogové
systémy

Luděk Bártek

Zpracování di-
gitalizovaného
signálu

Zpracování v
časové oblasti
Zpracování ve
frekvenční
oblasti

Rozpoznávání
řeči

Rozpoznávání
izolovaných slov

- Zvuk je neměnný pouze na krátkých časových úsecích – metody krátkodobé analýzy.
- Tento interval se nazývá mikrosegment – velikost 10 — 40 ms.
- Metody krátkodobé analýzy:
 - V časové oblasti – zpracovávají se přímo hodnoty jednotlivých vzorků.
 - Ve frekvenční oblasti – ze vzorků se získávají frekvenční charakteristiky, které jsou následně zpracovány.
- Modelování funkce Cortiho ústrojí – pomocí diferenciálních rovnic se simuluje rezonance na určitých vláčkách Cortiho ústrojí.

Zpracování digitalizovaného signálu

Váhové okénko

Dialogové
systémy

Luděk Bártek

Zpracování di-
gitalizovaného
signálu

Zpracování v
časové oblasti
Zpracování ve
frekvenční
oblasti

Rozpoznávání
řeči

Rozpoznávání
izolovaných slov

- Při krátkodobé analýze předpokládáme, že signál je v okolí mikrosegmentu periodický se stejnou periodou jako uvnitř.
- Vzniklá chyba se kompenzuje použitím „okénka”.
- Okénko – posloupnost vah pro vzorky v mikrosegmentu.
- Tyto váhy by měly odpovídat tomu, jak je daný vzorek ovlivněn okolím mikrosegmentu.
- Nejčastěji používané typy okének:
 - pravoúhlé okénko
 - Hammingovo okénko

Zpracování digitalizovaného signálu

Hammingovo okénko

Dialogové
systémy

Luděk Bártek

Zpracování di-
gitalizovaného
signálu

Zpracování v
časové oblasti
Zpracování ve
frekvenční
oblasti


Rozpoznávání
řeči

Rozpoznávání
izolovaných slov

- Vychází z předpokladu, že čím jsou vzorky blíže středu mikrosegmentu, tím méně jsou ovlivněny okolím.
- Pro výpočet vah se používá vzorec:

$$w(n) = \begin{cases} n = 0 \dots N - 1 & 0,54 - 0,46 \cos\left(\frac{2\pi n}{(N-1)}\right) \\ n < 0 \vee n \geq N & 0 \end{cases}$$

- Průběh vah okénka na mikrosegmentu:



- Vychází se z předpokladu:
 - 1 vzorky mikrosegmentu nejsou pro naše potřeby ovlivněny okolím mikrosegmentu
 - 2 všechny vzorky mikrosegmentu jsou ovlivněny stejně.
- Všechny vzorky mikrosegmentu mají shodnou váhu.

$$w(n) = \begin{cases} 0 \leq n < N & 1 \\ n < 0 \vee n \geq N & 0 \end{cases}$$

Analýza digitalizovaného signálu v časové oblasti

Dialogové
systémy

Luděk Bártek

Zpracování di-
gitalizovaného
signálu

Zpracování v
časové oblasti

Zpracování ve
frekvenční
oblasti

Rozpoznávání
řeči

Rozpoznávání
izolovaných slov

- Vychází přímo z hodnot vzorků, nikoliv z hodnot spektra.
- Používané metody:
 - funkce krátkodobé energie
 - funkce krátkodobé intenzity
 - funkce středního počtu průchodů nulou
 - diference 1. řádu
 - autokorelační funkce
 - ...

Analýza v časové oblasti

Funkce krátkodobé energie

Dialogové
systémy

Luděk Bártek

Zpracování di-
gitalizovaného
signálu

Zpracování v
časové oblasti

Zpracování ve
frekvenční
oblasti

Rozpoznávání
řeči

Rozpoznávání
izolovaných slov

- Využívá funkci průměrné energie v rámci segmentu:

$$E(n) = \sum_{k=-\infty}^{\infty} (s(k)\omega(n-k))^2$$

- $s(k)$ – vzorek v čase k
- $\omega(n-k)$ – váha odpovídajícího okénka pro čas k
- Výstupem je průměrná energie v daném okénku.
- Druhá mocnina zvyšuje dynamiku zvukového signálu.
- Použití:
 - automatické oddělení ticha řeči (signálu)
 - příznaky v jednoduchých klasifikátorech slov
 - oddělení znělých a neznělých částí promluvy.

- Funkce intenzity signálu v daném okénku.

$$I(n) = \sum_{k=-\infty}^{\infty} |s(k)|\omega(n-k)$$

- $|s(k)|$ – absolutní hodnota vzorku v čase k
- $\omega(n-k)$ – váha odpovídajícího okénka pro čas k
- Použití – stejné jako funkce krátkodobé energie.
- Oproti krátkodobé energii nezvýrazňuje tolik dynamiku řečového signálu.

Analýza v časové oblasti

Krátkodobá funkce středního počtu průchodu nulou

Dialogové
systémy

Luděk Bártek

Zpracování di-
gitalizovaného
signálu

Zpracování v
časové oblasti

Zpracování ve
frekvenční
oblasti

Rozpoznávání
řeči

Rozpoznávání
izolovaných slov

- Počítá změny znaménka digitalizovaného signálu.

$$Z(n) = \sum_{k=-\infty}^{\infty} |\operatorname{sgn}[s(k)] - \operatorname{sgn}[s(k-1)]| \omega(n-k)$$

- Varianta – počet lokálních extrémů.
- Obě metody mohou být negativně zatíženy šumem zvukového pozadí.
- Použití:
 - detekce ticha
 - detekce začátku a konce i zašuměné promluvy
 - přibližné určení základního hlasivkového tónu a formantů
 - příznaky jednodušších klasifikátorů slov

Analýza v časové oblasti

Autokorelační funkce

Dialogové
systémy

Luděk Bártek

Zpracování di-
gitalizovaného
signálu

Zpracování v
časové oblasti
Zpracování ve
frekvenční
oblasti

Rozpoznávání
řeči

Rozpoznávání
izolovaných slov

- Vrací podobnost úseků daného mikrosegmentu (čím větší výsledná hodnota, tím podobnější úseky posunuté o m vzorků).

$$R(m, n) = \sum_{k=-\infty}^{\infty} (s(k)\omega(n-k))(s(k+m)\omega(n-k+m))$$

- Je-li signál periodický s periodou P , $R(m, n)$ nabývá maxima pro $m=0, P, 2P, \dots$
- Předpokládá délku mikrosegmentu aspoň $2P$.
- Použití:
 - Používá se k zjišťování periodicity signálu základního tónu řeči.
 - Základ pro výpočet koeficientů LPA.

Analýza signálu ve frekvenční oblasti

Dialogové
systémy

Luděk Bártek

Zpracování di-
gitalizovaného
signálu

Zpracování v
časové oblasti
Zpracování ve
frekvenční
oblasti

Rozpoznávání
řeči

Rozpoznávání
izolovaných slov

- Transformuje digitální řečový signál z časové oblasti do frekvenční oblasti.
- Využívá k tomu nejčastěji Fourierovu transformaci.
- Nejčastěji používané druhy analýzy ve frekvenční oblasti:
 - krátkodobá Fourierova transformace
 - krátkodobá diskrétní Fourierova transformace
 - rychlá Fourierova transformace
 - keprstrální analýza
 - lineární predikce
 - ...

Analýza signálu ve frekvenční oblasti

Krátkodobá Fourierova transformace

Dialogové
systémy

Luděk Bártek

Zpracování di-
gitalizovaného
signálu

Zpracování v
časové oblasti

Zpracování ve
frekvenční
oblasti

Rozpoznávání
řeči

Rozpoznávání
izolovaných slov

- Vychází z Fourierovy transformace:

$$S(\omega, t) = \sum_{k=-\infty}^{\infty} s(k)h(t-k)e^{-i\omega k}$$

- Obyčejnou Fourierovu transformaci získáme fixací času t .
- $|S(\omega, t)|$ – amplituda složky akustického spektra odpovídající frekvenci ω v čase t .
- $h(n)$ – váhová funkce okénka.
- Předpokládá na vstupu periodickou funkci – zvuk je periodický na krátkých časových úsecích.
- Při jejím použití se předpokládá, že zpracovávaný mikrosegment se periodicky opakuje.

Analýza signálu ve frekvenční oblasti

Diskrétní Fourierova transformace

Dialogové
systémy

Luděk Bártek

Zpracování di-
gitalizovaného
signálu

Zpracování v
časové oblasti
Zpracování ve
frekvenční
oblasti

Rozpoznávání
řeči

Rozpoznávání
izolovaných slov

- Používá se pro vyjádření spektrálních vlastností periodických posloupností s periodou N vzorků resp. konečných posloupností délky N vzorků.
- Výpočet koeficientů $X(k)$ DFT:

$$X(k) = \sum_{n=0}^{N-1} x(n) e^{-i \frac{2\pi}{N} kn} = \sum_{n=0}^{N-1} x(n) W_N^{-kn}$$

- $|X(k)|$ – intenzita k. spektrálního koeficientu, frekvence závisí na velikosti mikrosegmentu N a vzorkovací frekvenci.
 - $x(n)$ – n. vzorek daného mikrosegmentu
 - $W_n = e^{i \frac{2\pi}{N}} = \cos(2\pi/N) + i \cdot \sin(2\pi/N)$.
- Výpočet n. vzorku na základě hodnot $X(k)$ – IDFT:

$$x(n) = \frac{1}{N} \sum_{k=0}^{N-1} X(k) e^{i \frac{2\pi}{N} kn} = \frac{1}{N} \sum_{k=0}^{N-1} X(k) W_N^{kn},$$

Analýza signálu ve frekvenční oblasti

Rychlá diskretní Fourierova transformace

Dialogové
systémy

Luděk Bártek

Zpracování di-
gitalizovaného
signálu

Zpracování v
časové oblasti
Zpracování ve
frekvenční
oblasti

Rozpoznávání
řeči

Rozpoznávání
izolovaných slov

- Výpočet spektrálních koeficientů pomocí DFT – n^2 operací nad komplexními čísly.
- Pomocí FFT – $N \cdot \log_2 \frac{N}{2}$ operací násobení.
- FFT požaduje, aby délka analyzovaného segmentu byla mocninou 2.
 - využívá metodu rozděl a panuj pro optimalizovaný výpočet DFT
 - zvláště se provádí výpočet lichých a sudých členů sumy
 - předchozí lze chápat jako transformaci dvou vektorů $(x_0, x_2, \dots, x_{N-2})$ a $(x_1, x_3, \dots, x_{N-1})$, lišících se pouze členem $(e^{-i\frac{2\pi}{N}})^k$, a vlastní transformace se neliší.

Analýza signálu ve frekvenční oblasti

Kepstrální analýza

Dialogové
systémy

Luděk Bártek

Zpracování di-
gitalizovaného
signálu

Zpracování v
časové oblasti
Zpracování ve
frekvenční
oblasti

Rozpoznávání
řeči

Rozpoznávání
izolovaných slov

- Vychází z modelu činnosti hlasového ústrojí.
- Řečové kmity lze modelovat jako odezvu lineárního systému na buzení sestávající ze sledu pulzů pro znělou řeč a šumu pro neznělou.
- Kepstrum – $X(k) = IFFT(\log|FFT(x(k))|)$
- Kepstrální analýza umožňuje z řeči oddělit parametry buzení a parametry hlasového ústrojí.
- Využití:
 - ocenění fonetické struktury řeči – znělost, perioda základního tónu, formanty, ...
 - rozpoznávání slov
 - verifikace a identifikace mluvčího
 - ...

Analýza signálu ve frekvenční oblasti

Lineární prediktivní analýza

Dialogové
systémy

Luděk Bártek

Zpracování di-
gitalizovaného
signálu

Zpracování v
časové oblasti

Zpracování ve
frekvenční
oblasti

Rozpoznávání
řeči

Rozpoznávání
izolovaných slov

- Jedna z nejefektivnějších metod analýzy akustického signálu – zajišťuje velmi přesné odhady parametrů při relativně malé zátěži.
- Vychází z předpokladu, že $s(k)$ lze popsat jako lineární kombinaci N předchozích vzorků a buzení $u(k)$:

$$s(k) = - \sum_{i=1}^N a_i s(k-i) + Gu(k)$$

kde G je koeficient zesílení a N řád modelu.

- Použití:
 - určování spektrálních charakteristik modelu hlasového ústrojí
 - z chyby predikce lze odvodit poznatky o znělosti a určit frekvenci základního hlasivkového tónu
 - koeficienty a_i nesou informaci o spektrálních vlastnostech – lze je použít jako příznaky pro rozpoznávání řeči.

- Rozpoznávání plynulé řeči – převádí souvislou promluvu na psaný text.
- Rozpoznávání izolovaných slov/příkazů.
- Princip rozpoznávání:
 - 1 získání vektoru příznaků pomocí metod krátkodobé analýzy signálu,
 - 2 klasifikace na základě vektoru příznaku získaného v předchozím kroku.

Rozpoznávání izolovaných slov

Dialogové
systémy

Luděk Bártek

Zpracování di-
gitalizovaného
signálu

Zpracování v
časové oblasti
Zpracování ve
frekvenční
oblasti

Rozpoznávání
řeči

Rozpoznávání
izolovaných slov

- Slouží k rozpoznání povelů nebo slov (příkazů) zřetelně oddělených na začátku a konci mezerou.
- Odpadá problém stanovení začátku a konce slova v souvislé promluvě.
- Obvykle systémy závislé na uživateli:
 - nutnost natrénování
 - omezená kapacita slovníku.
- Obtíže při rozpoznávání izolovaných slov:
 - Určení začátku a konce promluvy:
 - odlišení šumu od sykavek,
 - detekce nahodilého zvukového vzruchu (klepnutí, ...)
kontra okluzívy, které obsahují pauzy,
 - možná přítomnost infrazvuků.
 - ...