

# Úvod do počítačového zpracování řeči

Luděk Bártek<sup>1</sup>

1

—

# Obsah

- 1 Rozpoznávání plynulé řeči
- 2 Syntéza řeči
- 3 Syntéza ve frekvenční oblasti
- 4 Syntéza řeči v časové oblasti

# Úvod

- Hlavní rozdíly oproti rozpoznávání slov:
  - nelze vytvořit analogii databáze vzorů
  - prozodické faktory
  - nutnost určovat hranice mezi slovy
  - výplňkové zvuky a chyby řeči
- Řešení - statistický přístup
  - použití jazykových modelů
  - HMM vrátí stejnou pravděpodobnost např. pro slova "máma" a "nána"
    - ➊ máma je častější - vhodné použít máma

# Jazykové modely

- Posloupnost slov (promluva)  $W = (w(1)w(2)\dots w(n))$ .
- Posloupnost akustických vektorů -  $O = O(o(1)o(2)\dots o(t))$ .
- Chceme nalézt  $W^*$  (množinu všech promluv) maximalizující  $P(W—O)$ .
- Dle Bayesova pravidla platí:  $P(W^*—O) = \max P(W—O) = \max P(W)*P(O—W)/P(O)$
- Pro nalezení maxima potřebujeme znát:
  - model řečníka  $P(O—W)$
  - jazykový model  $P(W)$
- Model řečníka se nahrazuje pravděpodobností generování  $W$  odpovídajícím Markovovým modelem.
- Trigramový model:
  - Platí:  $P(w(n)|w(1)..w(n-1)) \cong P(w(n)|w(n-2)w(n-1))$

# Rozpoznávání tématu - topic recognition

- Úspěšnost rozpoznávání plynulé řeči 50-99
  - úkolu
  - jazyku
  - mluvčím
  - ...
- Úspěšnost rozpoznávání může zvýšit:
  - znalost tématu promluvy
  - použití gramatiky pro rozpoznávání řeči.
- Mění se stavový prostor a pravděpodobnosti trigramů
  - např. mějme burzovní zprávy - bylo rozpoznáno slovo honey nebo money?
- Známé téma - může být přesnější jazykový model.

# Gramatiky pro podporu rozpoznávání řeči

- Umožňují omezit množinu rozpoznávaných promluv:
  - výhoda - vyšší úspěšnost rozpoznávání
  - nevýhoda - nižší volnost vyjadřování
- Používají se bezkontextové gramatiky.
- V praxi často používané formáty gramatik:
  - JSGF (<http://www.w3.org/TR/jsgf/>) - původně definována v Java Speech API (<http://java.sun.com/products/java-media/speech/>)
  - SRGS (<http://www.w3.org/TR/speech-grammar/>) - součást standardů W3C Voice Browser Activity (<http://www.w3.org/Voice>)
    - Určeny pro tvorbu dialogových a hlasových rozhraní.

# Ukázka gramatiky ve formátu JSGF

```
#JSGF
<koren> = Chci jet <cim>.|  
          Chci jet <cim> z <odkud> do <kam>.|  
          Chci jet <cim> z <odkud> do <kam> v <kdy>.;  
<cim> = vlakem | autobusem;  
<odkud> = <czMesto>;  
<kam> = <czMesto>;  
<kdy> = <czCas>;
```

# Ukázka odpovídající gramatiky v XML formátu SRGS

```
<grammar root="koren" version="1.0" xml:lang="cs-CZ">
<rule id="koren">
  <one-of>
    <item>Chci jet <ruleref uri="#cim"/>.</item>
    <item>Chci jet <ruleref uri="#cim"/>
      z <ruleref uri="url db názvů stanic"/>
      do <ruleref uri="url db názvů stanic"/>
    </item>
    ...
  </one-of>
</rule>
```

# Ukázka odpovídající gramatiky v XML formátu SRGS

## Pokračování

```
<rule id="cim">
<one-of>
  <item tag="vlak">vlakem</item>
  <item tag="autobus">autobusem</item>
  ...
</one-of>
</rule>
</grammar>
```

# Ukázka gramatiky v ABNF formátu SRGS

```
root=$koren;
language = cs-CZ;
...
$koren = Chci jet $cim. |
          Chci jet $cim z $<url db stanic>
          do $<url db stanic>|
          ...
$cim = autobusem {$out=autobus} | vlakem {$out=vlak}
```

# Úvod

- Úkol:
  - Převod psaného textu na mluvenou řeč.
  - Co nejpřirozenější řeč - ideálně k nerozeznání od člověka:
    - správná intonace
    - správné umístění přízvuků
    - správná koartikulace
    - správný rytmus
    - ...

# Druhy syntézy řeči

- Druhy syntézy řeči
  - ve frekvenční oblasti
  - v časové oblasti
  - korpusová
  - problémově orientovaná syntéza:
    - hlášení nádražního rozhlasu
    - automatizované linky telefonické podpory

# Fáze syntézy řeči

- ① Fonetický přepis.
- ② Syntéza fonetické transkripce
- ③ Případný postprocessing:
  - intonace
  - správné časování - modifikace délky fonémů, ...
  - větné přízvuky
  - ...

# Fonetický přepis

- Slouží k přesnému, jednoznačnému zápisu mluvené řeči.
- Využívá fonetickou abecedu:
  - mezinárodní fonetická abeceda - IPA (součást standardu UNICODE)
  - 7bitový přepis IPA pomocí ASCII - SAMPAMa:S se dobr'e / ma:S se dobRe
- Nelze si pamatovat fonetický přepis každé promluvy - nutno zabezpečit automatický přepis:
  - fonologická pravidla
- Při transkripci češtiny se některé české znaky nevyužívají:
  - ch - x
  - w - v
  - y/ý - i/í
  - q - kv
- Koartikulace

# Pravidla fonetického přepisu češtiny

- ch → x
- ů → ú
- w → v
- q → kv
- y → i
- ý → í
- ě → je /po b,p,f,v
- dě, tě, ně, mě
  - dě → ðe
  - tě → ðe
  - ně → ñe
  - mě → mňe

# Pravidla fonetického přepisu češtiny

- di, ti, ni
  - di → čí
  - ti → čí
  - ni → čí
- X:
  - x → ks — začátek slova před samohláskou, mezi samohláskami nebo před neznělou souhláskou a nebo na konci slova, s výjimkou exjsamohláskař → egz
  - x → gz — před znělou souhláskou

# Změny na při spojování souhlásek

- Dochází k nim při spojování souhlásek.
- Způsobeny přenastavováním mluvidel.
- 2 druhy:
  - spodoba znělosti - změna znělosti párových souhlásek
    - ZPS → ZPS
    - NPS → NPS
    - dub → dup
    - zpěv → spjef
    - sběr → zbjer
    - když → gdiš
  - spodoba artikulační - při spojení dvou souhlásek s různou artikulací
    - banka, tango
    - tramvaj, nymfa
    - punča, pindík
    - odpovědně, sto dní, vodní
    - ts → c, tš → č
    - ds → c, dš → č

# On-line přístupné ukázky syntézy řeči

- AT&T Labs Natural Voices© Text-To-Speech (<http://www2.research.att.com/~ttsweb/tts/demo.php>)
- Free demo to create avatars using TTS by SitePal ([http://www.oddcast.com/home/demos/tts/tts\\_example.php](http://www.oddcast.com/home/demos/tts/tts_example.php))
- Cepstral Text-to-Speech (<http://cepstral.com/demos/>)
- Festival Online Demo (<http://www.cstr.ed.ac.uk/projects/festival/onlinedemo.html>)
- Speechtech s.r.o. (<http://www.speechtech.cz/cs/produkty/demo.html#Iva210>)

# Syntéza ve frekvenční oblasti

- Emulace funkce hlasového ústrojí pomocí FM syntezátoru.
- Nutno uchovávat:
  - frekvenční charakteristika použitého hlasu
  - parametry buzení.
- Využívá:
  - systém frekvenčních generátorů - simulují hlasivky
  - filtry a zesilovače - simulace rezonance v dutinách
  - Tyto komponenty ovládány parametry modelu.
- Nejběžněji použité způsoby kódování zdroje:
  - Řečová syntéza formantového typu - uchovávají se parametry průběhu jednotlivých formantů a buzení.
  - LPC řečová syntéza - uchovávají se F0, příznak znělosti, amplituda budícího signálu G a koeficienty LPC,


# Syntéza ve frekvenční oblasti

- Výhody
  - menší paměťové nároky - uchovávají se pouze parametry modelu.
- Nevýhody:
  - oproti syntéze v časové oblasti může být výsledek méně přirozený - "robotické" hlasy
  - Softwarová - výpočetně relativně náročné - lze implementovat přímo na úrovni HW
    - skládání jednotlivých frekvencí, které tvoří příslušné fonémy
    - řešení koartikulace
    - ...
  - Neexistuje dostatečně přesný matematický model


# Využití syntézy ve frekvenční oblasti

- Využití dříve:
  - malé paměťové nároky
  - domácí počítače (Amiga, Atari, ...)
  - syntéza realizována většinou hardwarově
- Dnes:
  - Syntéza na zařízeních s nedostatkem paměti.
  - Syntéza realizovaná hardwarově pomocí zákaznických obvodů.
- Doplnění syntézy v časové oblasti o prozodické jevy:
  - Větná intonace
  - ...
  - Realizováno programově pomocí modifikace  $F_0$  a formantů.

# Schéma syntetizéru formantového typu



# Schéma LPC syntetizéru



# Syntéza v časové oblasti

- Princip
  - spojování navzorkovaných řečových segmentů uložených v databázi.
- Využívají se různé typy základních segmentů:
  - větší
    - lépe se modelují některé další charakteristiky jako intonace, přízvuky, ...
    - větší nároky na paměť - větší množství segmentů (potenciálně až  $2n$ , kde  $n$  je délka segmentu)
    - příklady – slova, části vět, ...
  - menší
    - menší paměťové nároky - menší množství segmentů
    - horší možnost modelování větné intonace, přízvuků, ... (viz oblasti spektrální stacionarity řeči).

# Používané řečové segmenty

- Alofóny
  - poziciální varianty fonémů - obsahuje i části okolních fonémů
  - počet  $n^3$  ( $n$  - počet fonémů)
- Difóny
  - začínají uprostřed jednoho fonému a končí uprostřed následujícího
  - počet  $n^2$
  - často využívané pro syntézu i rozpoznávání:
    - MBrola  
(<http://tcts.fpms.ac.be/synthesis/mbrola.html>)

# Používané řečové segmenty

## Pokračování

- Trifóny
  - začínají uprostřed levého sousedního fonému a končí uprostřed pravého sousedního
  - počet  $n^3$
  - často využívané pro rozpoznávání a syntézu
- Slabičné segmenty.
- Segmenty proměnné délky získané z korpusu.
- Rámce

# Slabiky

## • Slabika

- Slabikovat se učí už děti v první třídě.
- Nejmenší jednotka organizační jednotka řeči.
- Nelze odvodit strukturu slabik - nejednoznačnost dělení některých slov na slabiky
  - funk-ční vs funkč-ní.
- Počet slabik - uvádí se cca 10000.
- Struktura slabiky
  - preatura (onset)
  - nukleus (vokalické jádro) - bývá to samohláska, příp. dvojhláska, sonora - např. krk, frikativa - např. pst, nazála - např. sedm
  - koda - nemusí se vyskytovat
  - nukleus + koda jsou považovány za základ slabiky
  - svahy – preatura a koda; jedná se většinou o jednu nebo více souhlásek.

# Slabičné segmenty

- Definovány uměle
- Řešení nejednoznačnosti hranice slabiky.
- Frekventované slabičné typy:
  - V (samohláska/dvojhláska) - ú - kol
  - KV (souhláska - samohláska) - vo - da
  - KVK - jed-not-ka
  - KK - tr-sy
  - KKV - dna
  - KKVK - dmout
- Tvoří více než 95 % slabik
- Umožňují automatickou segmentaci textu.
- Používají se např. v syntetizéru Demosthénes (doc. Kopeček LAF (LSD) FI)