

Syntéza a rozpoznávání řeči

Pavel Cenek, Aleš Horák

E-mail: hales@fi.muni.cz
http://nlp.fi.muni.cz/poc_lingv/

Obsah:

- ▶ Syntéza řeči
- ▶ Rozpoznávání řeči
- ▶ Související technologie

Syntéza řeči

- ▶ Text to Speech, TTS
- ▶ Konverze textu do mluvené podoby
- ▶ V ideálním případě by měla syntetizovaná řeč znít tak, jako kdyby daný text přečetl člověk
- ▶ Probíhá obvykle ve 4 fázích
 - Normalizace textu
 - Fonetický přepis
 - Prozodický přepis
 - Akustické modelování

První 3 fáze = NLP modul, čtvrtá fáze = DSP modul

Normalizace textu

- ▶ Rozčlenění textu na věty
- ▶ Rozvinutí zkratk, měrných jednotek, čísel apod.



Fonetický přepis

- ▶ Převeďte předzpracovaný text do **fonetické podoby** (tj. do tvaru, který popisuje výslovnost daného textu)
- ▶ **Mezinárodní fonetická abeceda (IPA)** – v češtině cca 40 fonémů
- ▶ Fonetický přepis **češtiny** musí zohlednit např.
 - Spodoba znělosti (včela/fčela, du**b**/dup)
 - Krajské zvyky (např. **sh**oda/**zh**oda nebo **sch**oda)
- ▶ Problémy přináší přepis **cizích vlastních jmen** a **cizích slov** obecně (např. faux pas nebo francouzská vlastní jména)
- ▶ Dvě základní metody
 - Fonetický přepis založený **na pravidlech** (např. pro češtinu funguje dobře)
 - Fonetický přepis pomocí **výslovnostních lexikonů**
- ▶ Obě metody lze kombinovat

Prozodický přepis

- ▶ tzv. **suprasegmentální rysy**
- ▶ popisuje řečový proud spolu s přepisem do fonémů
- ▶ obohacení textu o informace (viz SSML dále) o **lokálních fyzikálních charakteristikách** výsledné zvukové vlny:
 - **délka** fonému – **tempo** řeči, pauzy
 - **intonace** věty – vzor pro hladinu **základní frekvence** (*pitch*)
 - **tón** – v některých (tzv. **tónových**) jazycích určuje význam
 - lexikální **přízvuk** – v **přízvukových jazycích** ovlivňuje délku, hlasitost a tón slov
- ▶ kvalitní výpočet prozodie = **přirozenost** syntetizované řeči
např. u *tonálních jazyků* silně ovlivní i porozumění
- ▶ Emoce
 - člověk je při projevu používá
 - výzkum syntézi s emocemi je o dost složitější

Speech Synthesis Markup Language (SSML)

- ▶ Doporučení W3C (jako HTML, XML, ...) – standardní způsob pro doplnění fonetiky a prozodie do textu
- ▶ Pokrývá první 3 fáze syntézy řeči (normalizace, fonetický přepis, prozodie)
- ▶ **<say-as>** – explicitní určení typu dat (např. **Type="Acronym"**, viz Normalizace)
- ▶ **<phoneme>** – fonetický přepis textu
- ▶ **<voice>** – změna hlasu (atributy *věk, muž/žena, ...*)
- ▶ **<emphasis>** – přidání/odebrání důrazu
- ▶ **<break>** – vložení/zrušení pauzy
- ▶ **<prosody>** – ovlivnění prozodie (výška hlasu, kontura, rychlost, hlasitost atd.)

Speech Synthesis Markup Language (SSML) – příklad

```
<?xml version="1.0" encoding="UTF-8"?>
<vxml version="2.0" xmlns="http://www.w3.org/2001/vxml">
<form>
  <block>
    <prompt>
      <voice gender="male"><emphasis>Hello</emphasis> Jane.</voice>
      <voice gender="female"><emphasis>Hello</emphasis> Mike,
        how <emphasis>are</emphasis> you?</voice>
      <voice gender="male">I am fine. And how are
        <emphasis>you</emphasis> Jane?</voice>
      <voice gender="female">Not bad.</voice>
      <voice gender="male">OK, Goodbye.</voice>
      <voice gender="female"><emphasis>Goodbye</emphasis>
        Mike.</voice>
    </prompt>
  </block>
</form>
</vxml>
```

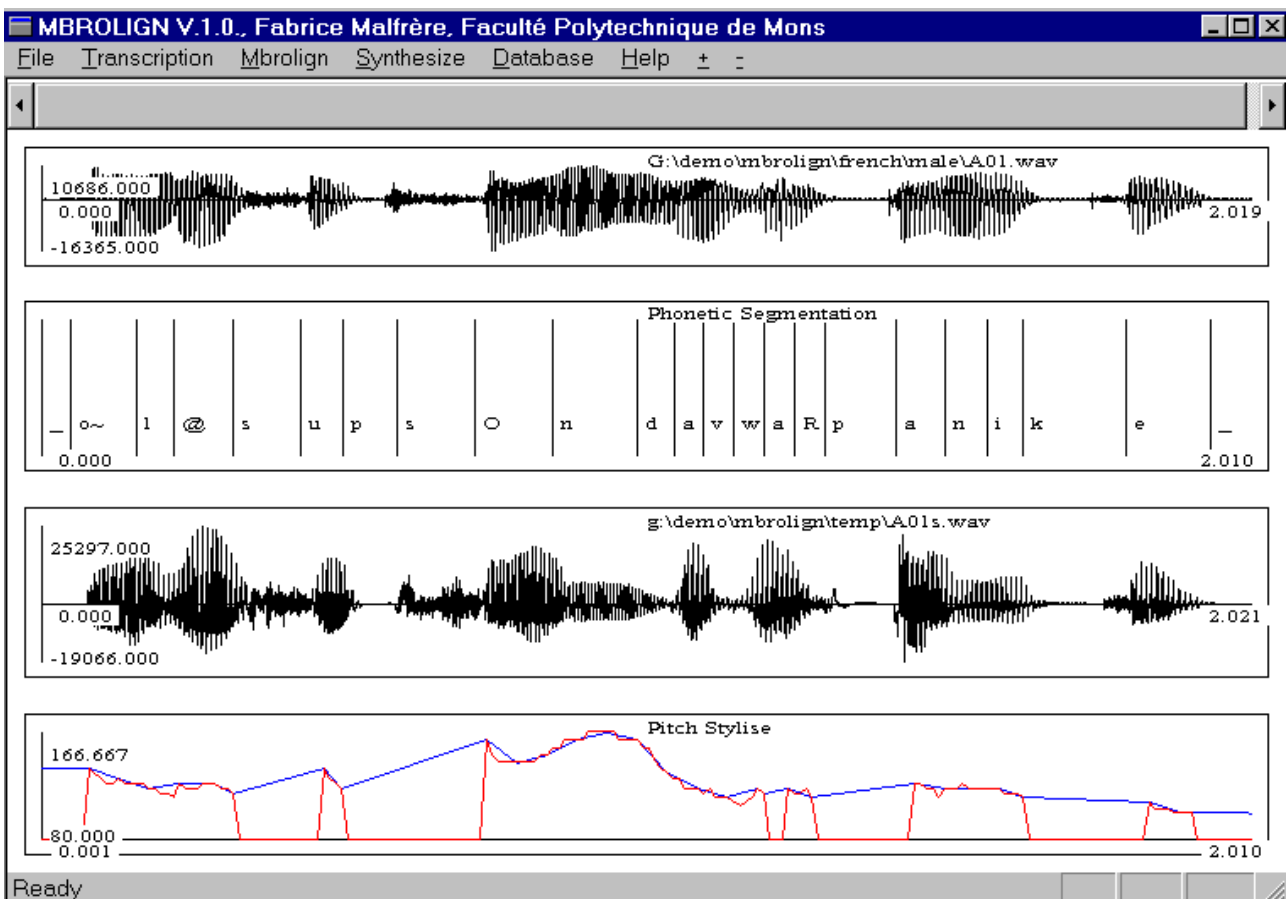
Akustické modelování

- ▶ **Generování** výsledného akustického **signálu** z předzpracovaného textu (řeší DSP modul)
- ▶ Dva základní přístupy
 - syntéza řeči v **časové oblasti**
 - syntéza řeči ve **frekvenční oblasti**
- ▶ v posledních letech i modelování pomocí **hlubokých neuronových sítí** (**WaveNet**)
 - ze začátku příliš výpočetně náročné pro aplikace v reálném čase
 - aktuálně používané v **Google Assistant**
 - umožňuje snadněji trénovat **nové hlasy**

I. Syntéza řeči v časové oblasti

- ▶ = **konkatenativní syntéza**
- ▶ Výsledná řeč se skládá z vybraných, dopředu namluvených **segmentů** řeči (difónů, trifónů, slabik apod.)
- ▶ Relativně jednoduché na implementaci
- ▶ Nutnost vytvoření rozsáhlé **databáze segmentů** (koartikulace, např. 'á' zní jinak v **tá**ta a **má**ma):
 - difóny – t **á** t a
 - trifóny – t **á** t a
 - kombinace – heterogenní segmenty (někdy difóny, trifóny i celá slova)
- ▶ Dochází k **deformaci segmentů** jejich spojováním a aplikací prozodických pravidel – “tajemství” komerčních aplikací

Semiautomatická tvorba difónové databáze



II. Syntéza řeči ve frekvenční oblasti

2 hlavní přístupy:

▶ Modelování hlasového ústrojí

- generovaný zvuk závisí na parametrech tohoto hlasového ústrojí.
- ⊕ velká **flexibilita** (nový hlas lze vytvořit pouhou změnou parametrů)
- ⊖ velmi **náročné výpočty** (řeší se fyzikální rovnice modelující situaci ve vokálním traktu, diferenciální rovnice, větš. degradují na válce/koule, ale stejně moc náročné) ⇒ v praxi se téměř nepoužívá

▶ Formantová syntéza

- modelování (jen) **hlavních** akustických rysů řečového signálu
- model **zdroj/filtr** – zdroj generuje základní tón pro znělé části řeči a šum pro neznělé části řeči a filtry modifikují zvukové spektrum a napodobují tak hlavní funkce lidského vokálního traktu
- zdroj i filtr jsou řízeny množinou fonetických **pravidel** → syntéza založená na pravidlech
- lze počítat v **reálném čase**
- mnohem **menší data** než u konkatenační syntézy → vhodné i pro *embedded devices*
- **espeak** – open source projekt espeak.sourceforge.net

TTS systémy ve světě

nejčastější použití – telefonní systémy

- ▶ ©Nuance (<http://www.nuance.com/>)
- ▶ ©Loquendo – nyní Nuance
- ▶ ©Acapela group (<http://www.acapela-group.com/>)
 - založena v roce 2004 třemi společnostmi, jedna z nich autor MBROLA
- ▶ ©IBM (<http://www.research.ibm.com/tts/>)
- ▶ ©AT&T (<http://www.research.att.com/>)
- ▶ Festival (<http://www.cstr.ed.ac.uk/projects/festival/>)
- ▶ MBROLA (<https://github.com/numediart/MBROLA>)
- ▶ FreeTTS (<http://freetts.sourceforge.net/>)

České TTS systémy

- ▶ EPOS TTS (<http://epos.speech.cz/>) ▶ DEMO
 - Česká akademie věd + Karlova univerzita
- ▶ Demosthenes, Popokatepetl
 - LSD FI
- ▶ ERIS TTS (<http://www.speechtech.cz/>), heterogenní segmenty ▶ DEMO
 - SpeechTech, s.r.o. + katedra kybernetiky FAV ZČU
© verze je nejlepší český
- ▶ Český hlas pro MBROLA
 - Mikuláš Piňos, NLP lab FI

Rozpoznávání řeči

- ▶ Automatic Speech Recognition, ASR
- ▶ Konverze řeči na text
 - Výstupem je většinou množina hypotéz spolu s pravděpodobností správnosti dané hypotézy. K výběru správné hypotézy se běžně využívají jazykové modely
- ▶ Lze zhruba rozdělit na
 - Rozpoznávání izolovaných slov – slyšitelná pauza mezi slovy
 - Rozpoznávání kontinuální řeči – plynulá řeč (řeč školeného mluvčího nebo čtený text)
 - Rozpoznávání spontánní řeči – přeroky, pauzy, začátky vět (*false-starts*)

Rozpoznávání řeči pokrač.

- ▶ Diktovací stroje (např. Dragon Naturally Speaking)
 - Schopné rozpoznat cokoliv
 - N -gramové statistické jazykové modely
 - Závislé na mluvčím (je potřeba je natrénovat)
- ▶ Rozpoznávače založené na gramatikách
 - Rozpoznají jen fráze popsané (regulární) gramatikou (gramatika = jazykový model)

$$S \rightarrow \text{"Jedu do " MESTO}$$

$$\text{MESTO} \rightarrow \text{"Prahy"} \mid \text{"Brna"}$$
 - Nezávislé na mluvčím – telefonní aplikace
 - Speech Recognition Grammar Specification (SRGS)
 - standard W3 konzorcia, à la BNF
 - existují 2 notace – XML a šipková pro čtení
 - dá se do ní dát i “význam” vstupu

Rozpoznávání řeči pokrač.

Probíhá obvykle ve 3 fázích:

1. Vstup signálu

- Amplituda akustického vlnění je snímána v pravidelných intervalech a uložena ve formě celého čísla (digitalizace a vzorkování signálu)

2. Vytvoření akustických charakteristik signálu (akustické vektory)

- Snižuje variabilitu a odstraňuje redundanci (řeč 300 000× redundantní)
- Počítají se rozdělením na segmenty 10–40 ms, ze kterých se odečítají charakteristiky, jako je počet průchodů nulou nebo prvních 12 koeficientů FFT (cca 40 čísel, není přesně dané které, ale výběr velice ovlivní výsledek)

3. Porovnávání vektorů parametrů

- K získané sekvenci vektorů parametrů se hledá co nejpodobnější sekvence známých, předem naučených, vektorů reprezentující např. fonémy, trifóny, slabiky, celá slova apod.

Porovnávání vektorů parametrů

- ▶ Algoritmus borcení časové osy (dynamic time warping, DTW)
 - odstraňuje časové nerovnoměrnosti v akustickém signálu
- ▶ Skryté Markovovy modely (*Hidden Markov Models, HMM*)
 - Pravděpodobnostní konečné automaty
 - V každém okamžiku je hlasové ústrojí v určitém stavu a může s určitou pravděpodobností přejít do jednoho z následujících stavů
 - Jako doplněk se mohou využít neuronové sítě
 - Je nejprve potřeba natrénovat za pomoci dat z řečového korpusu

ASR systémy ve světě

- ▶ ©Nuance (<http://www.nuance.com/>)
- ▶ ©Loquendo – nyní Nuance
- ▶ ©LumenVox (<http://www.lumenvox.com/>)
- ▶ ©IBM ViaVoice – nyní Nuance Dragon Naturally Speaking
<http://www.nuance.com/dragon/>
- ▶ Sphinx (<http://cmusphinx.sourceforge.net/>)

České ASR systémy

- ▶ Laboratoř počítačového zpracování řeči na Fakultě mechatroniky Technické univerzity v Liberci (<http://www.ite.tul.cz/speechlab/>)
- ▶ ERIS ASR (<http://www.speechtech.cz/>)
 - SpeechTech, s.r.o. + katedra kybernetiky FAV ZČU
- ▶ Speech@FIT VUT Brno (<http://speech.fit.vutbr.cz/>)
 - keyword spotting – jestli se vyskytlo dané slovo v běžné řeči

Mozilla Common Voice

- ▶ voice.mozilla.org
- ▶ iniciativa Mozilly pro vytvoření komunitního ASR
- ▶ můžete sami přispět k dostupnosti rozpoznávání řeči pro váš jazyk
- ▶ uživatelé:
 - vybírají věty (je potřeba > 5,000 vět/jazyk)
 - kontrolují věty
 - nahrávají věty (za všechny jazyky je nyní nahráno 18,000 hodin, za češtinu 67 hodin)
 - kontrolují nahrávky vět
- ▶ <https://commonvoice.mozilla.org/cs>,
<https://www.mozilla.cz/zpravicky/tag/voice/>

Související technologie

- ▶ Dialogové systémy
 - Počítačové systémy komunikující s uživatelem pomocí přirozeného jazyka
 - Využívají ASR a TTS jako své komponenty
- ▶ Rozpoznávání mluvího
 - identifikace mluvího – určení, který z registrovaných mluvích pronesl danou větu
 - verifikace mluvího – akceptování nebo odmítnutí identity mluvího
- ▶ Identifikace mluveného jazyka
 - fonémicko-fonetický rozpoznávač pro každý rozpoznávaný jazyk – sledují se fonémy specifické pro každý jazyk
 - daná promluva je zpracována všemi rozpoznávači a jako jazyk dané promluvy je zvolen jazyk, jehož rozpoznávač dosáhl nejvyššího skóre