

# **Fonetika, rozpoznávání řeči HMM II.**

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

**FIT VUT Brno**

## Plán

- Něco z fonetiky
- fonetické abecedy.
- Rozpoznávání pomocí fonémů
- Tied-state triphones.
- Jazykové modelování (LM)
- Odhad parametrů LM

## Fonetika

Tato sekce podává pouze velmi základní informaci. Podrobnosti ve skriptu: Krčmová N.: Fonetika a fonologie: zvuková stavba současné češtiny. ISBN 80-210-0137-2. Masarykova univerzita, Brno, 1990

Rozeznáváme dvě základní skupiny hlásek (fonémů):

- **samohlásky** (ustálená poloha hlasového traktu).
- **souhlásky** (přechodové stavy hlasového ústrojí).


## Samohlásky – vokály

Čeština má 5, dělíme na krátké a dlouhé. Délka samohlásek je v češtině významotvorná. Následující tabulka udává typickou a možnou délku souhlásek v milisekundách. Délka konkrétní realisace závisí na dialektu, emocích, atd.

samohláska	typ. délka	rozmezí	samohláska	typ. délka	rozmezí
a	120	90–160	á	240	190–300
e	90	60–120	é	190	160–220
i	80	50–100	í	170	140–200
o	100	70–130	ó	200	160–250
u	90	60–120	ú	180	120–240

Rozlišení samohlásek je možné pomocí *formantů*. V češtině jsou určující  $F_1$  a  $F_2$ . Formant  $F_3$  je připisován vlivu dutiny nosní, který je v češtině minimální (srov. s francouzštinou!). Typické “výšky formantů” udává následující tabulka. Vyneseeme-li frekvence  $F_1$  a  $F_2$  logaritmicky, dostaneme tzv. *samohláskový trojúhelník*:

samohláska	$F_1$ [kHz]	$F_2$ [kHz]
a	0,8–1,0	1,2–1,4
e	0,5–0,7	1,6–2,1
i	0,3–0,5	2,1–2,7
o	0,5–0,7	0,9–1,2
u	0,3–0,5	0,6–1,0



## Souhlásky – konsonanty

- jsou podstatně kratší než samohlásky a jejich délka silně závisí na kontextu (samostatně vyslovené “r” má např. okolo 30 ms, kdežto slabikotvorné “r” v “trn” okolo 90 ms).
- Identifikace souhlásek je podstatně těžší.
- vznikají postavením **překážky** do proudu protékajícího vzduchu.

Souhlásky můžeme dělit několika způsoby:

### Podle znělosti

- **znělé** - hlasivky vibrují.
- **neznělé** - hlasivky jsou v klidu, hlasový trakt je buzen proudem vzduchu.

## Podle charakteru překážky

- překážka úplná – **závěrové - okluzívy**.
- překážka neúplná (zúžení cesty výdechového proudu) – **úžinové - frikativy**:
  - vlastní úžinové.
  - bokové (laterály) - “l”.
  - kmitavé (vibranty) - “r, ř”.
- **polozávěrové - semiokluzívy** - “c, č, dz, dž” .

## Podle párovosti

- **párové** – podobné postavením hlasového traktu, liší se znělostí.
- **nepárové** – vždy znělé, nemají neznělý protějšek.

Dělení souhlásek podle znělosti, charakteru překážky a párovosti shrnuje následující tabulka:

Souhlásky		závěrové (okluzívy)	úžinové (frikativy)	polozávěrové
párové	neznělé	p t č k	s š f ch	c č
	znělé	b d č g	z ž v h	dz dž
nepárové	znělé	m n č ř	l j r ř	

## **Podle místa artikulace**

Místem artikulace se rozumí poloha překážky:

- retné – labiální.
- dásňové – alveolární.
- předopatrové – palatální.
- zadopatrové – velární.
- hrtanové – laryngální nebo glotální.

## Mezinárodní normy pro označování fonémů

Mezinárodní fonetická asociace (International Phonetic Association) definovala mezinárodní fonetickou abecedu: **IPA (International Phonetic Alphabet)**. Můžete se na ni podívat na WWW stránce:

<http://www2.arts.gla.ac.uk/IPA/ipa.html>

Pro zápis pomocí této abecedy potřebujete speciální fonty, pro automatické zpracování není příliš vhodná.


Počítačově “čitelnou” variantou je **SAMPA (Speech Assessment Methods Phonetic Alphabet)**. Podrobný přehled viz WWW stránka:

<http://www.phon.ucl.ac.uk/home/sampa/home.htm>

Velmi rozšířenou notcí pro rozpoznávání řeči (US English) je fonémová sada (a její značení) použité v databázi **TIMIT**.

## ZPĚT DO ROZPOZNÁVÁNÍ


opakování - rozpoznávání spojených slov:




## Rozpoznávání pomocí menších jednotek

v případě velkého slovníku nejsme schopni natrénovat model pro všechna slova (málo dat, některá vůbec nejsou v trén. databázi)  $\Rightarrow$  modely menších jednotek.

- **fonémy:** “six” = s i k s. Pivo passing jako v předcházejícím případě, modely slov jsou poskládány z modelů fonémů.
- **kontextově závislé fonémy (CD-phones):** 'n' v “nothing” se podstatně liší od 'n' v “bank”  $\Rightarrow$  přidání závislosti na kontextu. Klasicky 1 vlevo, 1 vpravo, trifony. “six” = s+i s-i+k i-k+s k-s.  
Nevýhoda: mnoho trifonů, nespolehlivý odhad, chybějící trifony.
- **trifony se sdílenými stavami (tied-state triphones):** vázání stavů pro podobné modely, menší množství dat. Vázání pomocí fonetických otázek.



Není ale možné spolehlivě natrénovat každý trifón  $\Rightarrow$  sdílení stavů:



Při rozpoznávání s velkým slovníkem (např. 10000 slov) není možné brát v úvahu pouze akustické modelování

## Jazykové modely – Language Models

zpět do teorie:

$$W_1^{N\star} = \arg \max_{\forall W_1^N} \left\{ \mathcal{P}(W_1^N | \mathbf{O}) \right\},$$

Vyhodnocení pomocí Bayesova vzorce:

$$\mathcal{P}(W_1^N | \mathbf{O}) = \frac{\mathcal{P}(\mathbf{O} | W_1^N) \mathcal{P}(W_1^N)}{\mathcal{P}(\mathbf{O})}$$

## Jazykové modelování: určení pravděpodobnosti $\mathcal{P}(W_1^N)$

- ideálně násobením podmíněných pravděpodobností:

$$\mathcal{P}(W_1^N) = \prod_{i=1}^N \mathcal{P}(W_i | W_1 \dots W_{i-1})$$

pravděpodobnosti nejdou odhadnout...

- zkrácení historie na 1 (bigramy) nebo 2 (trigramy).

## Odhad pravděpodobnosti LM

na velkém korpusu textu:


$$\mathcal{P}(W|H) = N(W, H)/N(H)$$

Ani trigramy není možné spolehlivě odhadnout a chceme se vyvarovat nul v LM:

## Back-off Language models

$$P(W|H) = \begin{cases} (N(W, H) - D)/N(H) & \text{for } N(W, H) > p \\ b(H)P(W|H_{-1}) & \text{for } N(W, H) \leq p \end{cases}$$

Schema rozpoznávače:



Rozpoznávací síť s bigramy:

