

Dialogové systémy

Rozpoznávání řeči

Luděk Bártek

Laboratoř vyhledávání a dialogu, Fakulta Informatiky Masarykovy Univerzity,
Brno

jaro 2018

Rozpoznávání řeči

Dialogové
systémy

Luděk Bártek

Rozpoznávání
řeči

Rozpoznávání
izolovaných slov
Rozpoznávání
plynulé 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

- 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.
 - ...

Rozpoznávání izolovaných slov

Typy klasifikátorů

Dialogové
systémy

Luděk Bártek

Rozpoznávání
řeči

Rozpoznávání
izolovaných slov
Rozpoznávání
plynulé řeči

- Klasifikátory využívající porovnání slov metodou DTW.
 - Snaží se nalézt co největší shodu mezi rozpoznávaným slovem a slovy v databázi.
- Klasifikátory založené na statistických metodách – modelování pomocí skrytých Markovových modelů:
 - simulace procesu tvorby řeči.
- Klasifikátory pracující na dvou úrovních:
 - 1 segmentace a fonetické dekódování jednotlivých segmentů
 - 2 rozpoznání slova na základě dekódovaných segmentů.
- Využití umělých neuronových sítí - více viz:
 - Hinton, O., Teh - A Fast Learning Algorithm for Deep Belief Nets, in Neural Computation, 2006
 - Bengio, L., Popovici, L. - Greedy Layer-Wise Training of Deep Networks, in NIPS' 2006
 - Speech recognition - Lecture 14: Neural Networks

Dynamic Time Warping (DTW)

Dialogové
systémy

Luděk Bártek

Rozpoznávání
řeči

Rozpoznávání
izolovaných slov
Rozpoznávání
plynulé řeči

- Metoda borcení časové osy.
- Používá se pro porovnání dvou číselných řad – dvou úseků promluv (dvou slov).
- Vstup:
 - posloupnost akustických vektorů získaných pomocí metod krátkodobé analýzy signálu
 - databáze akustických vektorů rozpoznávaných slov.
- Výstup – rozpoznané slovo resp. povel.

- Vytvoříme databázi rozpoznávaných slov (referenční posloupnosti akustických vektorů).
 - Obvykle několik posloupností pro každé slovo, které odpovídají několika způsobům vyslovení příkazu.
- Rozpoznávané slovo převedeme na odpovídající posloupnost akustických vektorů.
- Metodou DTW nalezneme referenční posloupnost akustických vektorů s maximální shodou.

- Algoritmus DTW hledá parametrizaci f, g :

$$f, g : i = f(k), j = g(k), k \in \langle 1, K \rangle$$

minimalizující výraz

$$D(A, B) = \sum_{i=1}^K d(a_{f(i)}, b_{g(i)})$$

- d – vzdálenost akustických vektorů (např. Euklidovská metrika)
- $a_{f(i)}$, $b_{g(i)}$ – referenční a rozpoznávaný příkaz.

- f, g – neklesající funkce
- Omezení na lokální souvislost a strmost:
 - $0 \leq f(k) - f(k-1) \leq I^*$
 - $0 \leq g(k) - g(k-1) \leq J^*$
 - většinou platí $I^*, J^* = 1, 2, 3$
 - Z praktických testů vyplynulo, že při příliš strmém přírůstku může dojít k nevhodné korespondenci mezi příliš krátkým segmentem vzorku a a příliš dlouhým segmentem vzorku b .
- Omezení na hraniční body:
 - $f(1) = 1, f(K) = I$, kde I je počet vzorků slova a .
 - $g(1) = 1, g(K) = J$, kde J je počet vzorků slova b .

- Globální vymezení oblasti pohybu funkce DTW:
 - omezení minimální a maximální přípustné směrnice přímky vymezující přípustnou oblast pohybu funkce DTW, při splnění podmínky na hraniční body:

$$1 + \alpha[i(k) - 1] \leq 1 + \beta[i(k) - 1]$$

- α – minimální směrnice přímky omezující přípustnou oblast
- β – maximální směrnice přímky omezující přípustnou oblast.

DTW – Praktická realizace klasifikátoru slov

Blokové schéma

Dialogové
systémy

Luděk Bártek

Rozpoznávání
řeči

Rozpoznávání
izolovaných slov

Rozpoznávání
plynulé řeči



Obrázek: Blokové schéma klasifikátoru slov

■ Obecný postup:

- 1 Řečník resp. skupina řečníků vysloví postupně každé trénované slovo požadovaného slovníku, buď jednou nebo opakovaně.
- 2 Vstupní slova jsou zdigitalizována a následně převedena zvolenou metodou krátkodobé analýzy na posloupnost vektorů příznaků.
- 3 Detekce hranic (počátku a konce) slov:
 - Může být náročné na provedení, např. kvůli rušivému pozadí.
 - Nekorektní detekce hranic slov zhoršuje úspěšnost rozpoznávání.
 - Metody odstraňující i jen částečně vliv akustického pozadí zvyšují výpočetní náročnost.
- 4 Vytvoření referenčních obrazů slov.

DTW – praktická realizace

Metody vytváření referenčních obrazů slov

Dialogové
systémy

Luděk Bártek

Rozpoznávání
řeči

Rozpoznávání
izolovaných slov

Rozpoznávání
plynulé řeči

- Přímé použití obrazů trénovací množiny jako referenčních obrazů slov – DTW nevyžaduje, aby obrazy téhož slova byly stejně dlouhé, ale z důvodu možnosti aplikace pomocných kritérií, je vhodné provést časovou normalizaci každého obrazu.
- Vytváření průměrného vzorového obrazu pro každou třídu slov w :
 - používají se metody lineárního a dynamického průměrování.
- Vytváření vzorových obrazů shlukováním.
 - Vzorové obrazy pro dané slovo se rozdělí do shluků tak, že obrazy uvnitř shluku jsou si „podobné“ a obrazy z různých shluků jsou „nepodobné“.
 - Shlukování lze realizovat interaktivně (poloautomaticky – metoda řetězové mapy, algoritmus ISODATA), automaticky (algoritmy založené na MacQueenově algoritmu). Více viz závěrečná práce Mgr. Jiřího Kučery.

- Nevýhody DTW – vysoké paměťové a výpočetní nároky mohou znesnadňovat klasifikaci v reálném čase i při relativně malém slovníku.
- Metody řešení:
 - Hrubá síla – využití paralelních procesorů popř. zákaznických obvodů – může být drahé.
 - Vhodné zakódování parametrů jednotlivých mikrosegmentů referenčních i testovacích obrazů. Využívá se:
 - vektorová kvantizace – počet různých vzorků je konečný – uloží se do kódové knihy a místo hodnoty vzorku se pracuje s jejich indexy v kódové knize.
 - kódová kniha – abeceda všech hodnot, které se vyskytly v signálu (lze kódovat úsporněji než při použití standardního PCM).

- Využití oblastí spektrální stacionarity – metoda segmentace spektrální stopy.
 - Spektrální stopa – spojnice koncových bodů vektorů příznaků.
 - Lze ji approximovat – např. lineárními úseky.
- Optimalizace vyhledávání nejbližšího souseda:
 - metody prohledávání metrických prostorů
 - nutno ověřit, že vzdálenost použitá v DTW je metrika.

- Redukce výpočetních nároků pomocí heuristik při porovnávání.
 - Vícestupňový rozhodovací postup:
 - 1 porovnání promluvy proti celému slovníku pomocí omezené množiny příznaků
 - 2 dohledání výsledku kroku 1. pomocí klasického DTW.
 - Práh zamítnutí:
 - 1 po každém kroku spočítáme vzdálenost slova a obrazu
 - 2 pokud překročí experimentálně stanovený práh, obraz je zamítnut.

Skryté Markovovské Modely – HMM

Dialogové
systémy

Luděk Bártek

Rozpoznávání
řeči

Rozpoznávání
izolovaných slov

Rozpoznávání
plynulé řeči

- Modelování řeči pomocí HMM vychází z následující představy o tvorbě řeči:
 - Hlasové ústrojí se v krátkém čase nachází v jedné z konečně mnoha artikulačních konfigurací – generuje hlasový signál.
 - Přejde do následující konfigurace.
- Tuto činnost lze modelovat statisticky.
- Kvantizací akustických vektorů lze dosáhnout konečnosti všech parametrů odpovídajícího modelu.

- Jsou generovány dvě vzájemně svázané časové posloupnosti náhodných proměnných:
 - podpůrný Markovův řetězec – posloupnost konečného počtu stavů
 - řetězec konečného počtu spektrálních vzorů.
- Náhodná funkce ohodnocující pravděpodobnostmi vztah vzorů k jednotlivým stavům.
- Pro rozpoznávání řeči jsou nejčastěji využívané levo-pravé Markovovy modely:
 - vhodné pro modelování procesů spjatých se vzrůstajícím časem.

- Markovův proces G se skrytým Markovovým modelem je pětice $G = (Q, V, N, M, \pi)$
 - $Q = q_1, \dots, q_k$ – množina stavů
 - $V = v_1, \dots, v_k$ – množina výstupních symbolů
 - $N = (n_{i,j})$ – matice přechodu. Určuje pravděpodobnost přechodu ze stavu q_i v čase t_1 do stavu q_j v čase t_2 .
 - $M = (m_{i,j})$ – matice přechodu, určující pravděpodobnost generování akustického vektoru v_j , v kterémkoliv čase ve stavu q_i .
 - $\pi = (\pi_i)$ – vektor pravděpodobností počátečního stavu (pravděpodobnost toho, že stav i je počáteční).
- Trojice $\lambda = (N, M, \pi)$ – vytváří model řečového segmentu.
 - např. Vintsjukův model pro slovo – počet stavů 40 — 50 (odvozeno od průměrného počtu mikrosegmentů ve slově; délka mikrosegmentu 10 ms).

- Značíme $P(O|\lambda)$
- Promluva O standardně zpracována do posloupnosti $O = (o_1, \dots, o_T)$
 - T – počet mikrosegmentů promluvy
 - o_i – odpovídají výstupním symbolům.
- Určení $P(O|\lambda)$ – metoda využívající rekurzivní výpočet od předu nebo od zadu generované posloupnosti (forward-backward algorithm).

■ Výpočet odpředu:

- α_i – pravděpodobnost přechodu do stavu q_i při generování posloupnosti $\{o_1, \dots, o_t\}$ ($\alpha_i = P(o_1 \dots o_t, q_i(t) | \lambda)$)
- Rekurzivní výpočet:

- 1 inicializace: $\alpha_1(i) = \pi_i m_i(o_1), i \in <1, N>$
- 2 Rekurzivní krok pro $t=1, \dots, T-1$:

$$\alpha_{i+1}(j) = [\sum_{i=1}^N \alpha_t(i) n_{i,j}] m_j(o_{t+1})$$

pro $j \in <1, N>$, $m(o_t)$ je ekvivalentní zápisu $m_i(l)$,
pokud $o_t = v_l$.

- 3 Výsledná pravděpodobnost:

$$P(O|\lambda) = \sum_{i=1}^N \alpha_T(i)$$

- Nevýhoda předchozího postupu:
 - ve výsledném vztahu jsou zahrnuty pravděpodobnosti všech možných posloupností stavů délky T.
- Řešení:
 - výpočet maximálně pravděpodobné posloupnosti stavů Q.
- Výpočet realizován pomocí Viterbiova algoritmu:
 - problém řešen rekurzivně s použitím technik dynamického programování.

- Nutno stanovit postup při trénování parametrů modelu.
- Cíl trénování:
 - maximalizace pravděpodobnosti $P(O|\lambda)$
- Problém:
 - neexistuje analytická metoda ke zjištění globálního maxima funkce n proměnných.
- Řešení:
 - lze použít iterativní algoritmy zajišťující aspoň lokální maximalitu.
- Nejpoužívanější postup – Baum-Welchův algoritmus.
- Další problém při trénování modelu:
 - vliv konečné trénovací množiny:
 - čím menší trénovací množina a čím větší matice M, tím větší pravděpodobnost, že některé prvky zůstanou nastaveny na 0 (problém chybějících/neadekvátních dat).

■ Používá se princip maximální věrohodnosti.

1 Pro slovo O a všechna λ :

1 Spočítáme $P(O|\lambda)$.

2 Jako výsledek vybereme třídu s maximální hodnotou $P(O|\lambda)$.

■ Modelování povelů:

- nejčastěji se používají modely se 4 — 7 stavů.
- Pro modelovaní lze využít nástroje pro tvorbu HMM
 - HTK – Hidden Markov Model Toolkit.

■ Modelování fonémů:

- obvykle 4 — 7 stavů
- model slova – zřetězení modelů fonémů
- problémy s výpočtem v reálném čase
 - lze řešit pomocí speciálních algoritmů pro hledání maxima $P(O|\lambda)$.

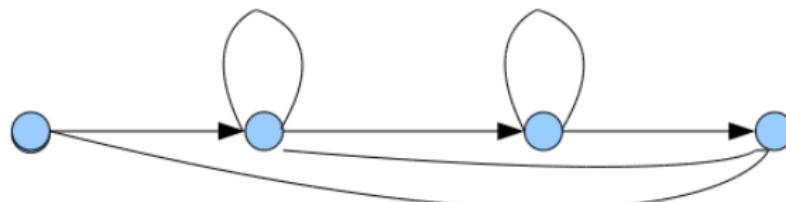
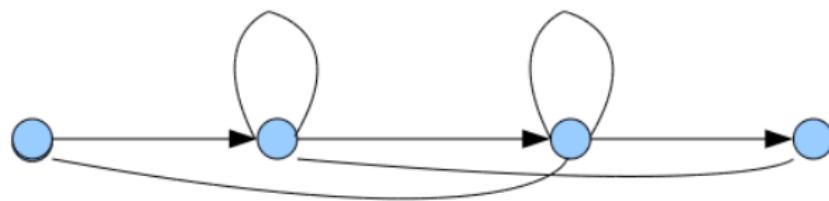
Příklady struktur pro fonémy

Dialogové
systémy

Luděk Bártek

Rozpoznávání
řeči

Rozpoznávání
izolovaných slov
Rozpoznávání
plynulé řeči



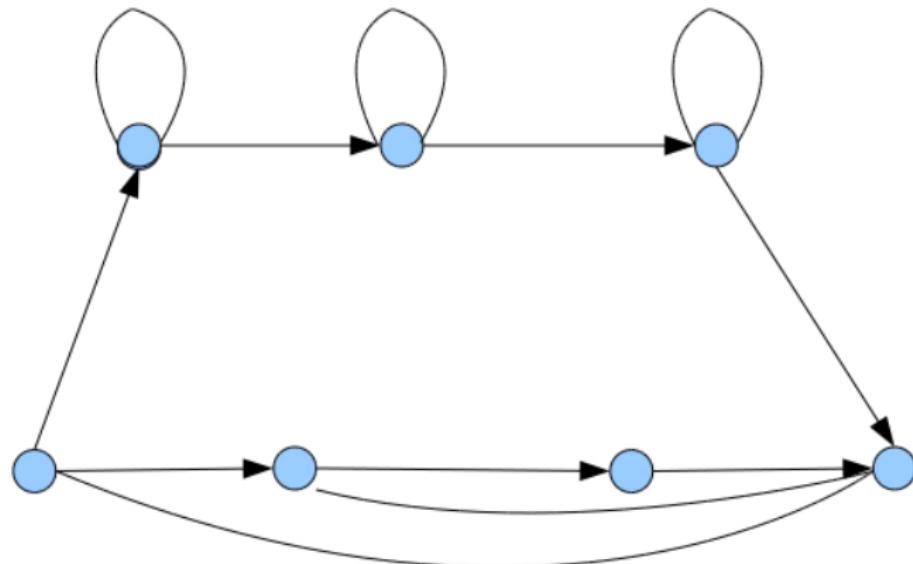
Příklady struktur pro fonémy

Dialogové
systémy

Luděk Bártek

Rozpoznávání
řeči

Rozpoznávání
izolovaných slov
Rozpoznávání
plynulé řeči



Rozpoznávání plynulé řeči

- Hlavní rozdíly oproti rozpoznávání slov:
 - nelze vytvořit databázi vzorů
 - nutno brát zřetel na prozodické faktory
 - nutno určovat hranice mezi slovy
 - vypořádání se s výplníkovými zvuky a chybami řeči.
- Řešení – statistický přístup:
 - jazykový model
 - model uživatele.
- Příklad: HMM vrátí stejnou pravděpodobnost např. pro slova „máma“ a „nána“ – nejspíše se použije máma – je častější.

Rozpoznávání plynulé řeči

Jazykové modely

Dialogové
systémy

Luděk Bártek

Rozpoznávání
řeči

Rozpoznávání
izolovaných slov

Rozpoznávání
plynulé řeči

■ Máme:

- posloupnost slov (promluva) $W = (w_1, \dots, w_n)$
- posloupnost akustických vektorů $O = (o_1, \dots, o_t)$.
- Chceme nalézt W^* (množinu všech promluv), která maximalizuje $P(W|O)$.
- Dle Bayesova pravidla platí:

$$P(W^*|O) = \max P(W|O) = \max \frac{P(W) * P(O|W)}{P(O)}$$

Rozpoznávání plynulé řeči

Jazykové modely – pokračování

Dialogové
systémy

Luděk Bártek

Rozpoznávání
řeči

Rozpoznávání
izolovaných slov

Rozpoznávání
plynulé řeči

- Pro nalezení maxima potřebujeme znát:
 - model řečníka – $P(O|W)$
 - jazykový model – $P(W)$.
- Model řečníka lze nahradit pravděpodobností generování W odpovídajícím Markovovým modelem.
- Trigramový model:
 - Experimentálně ověřeno, že platí:

$$P(w_n | w_1 \dots w_{n-1}) \cong P(w_n | w_{n-2} w_{n-1})$$

Rozpoznávání plynulé řeči

Rozpoznávání tématu

Dialogové
systémy

Luděk Bártek

Rozpoznávání
řeči

Rozpoznávání
izolovaných slov
Rozpoznávání
plynulé řeči

- Úspěšnost rozpoznávání řeči se pohybuje cca 50 % — 99 % v závislosti na úkolu, jazyku, ...
- Úspěšnost rozpoznávání lze zvýšit omezením domény rozpoznávání:
 - rozpoznání tématu
 - použitím gramatik pro rozpoznávání řeči.
- Známé téma:
 - změna stavového prostoru a pravděpodobnosti trigramů:
 - např. burzovní zprávy – rozpoznáno „honey“ nebo „money“?
 - možnost vytvoření přesnějšího jazykového modelu.

Gramatiky pro podporu rozpoznávání řeči

Dialogové
systémy

Luděk Bártek

Rozpoznávání
řeči

Rozpoznávání
izolovaných slov

Rozpoznávání
plynulé řeči

- Úspěšnost obecného rozpoznávání plynulé řeči může klesnout až na cca 50 %.
- Zvýšení lze dosáhnout omezením domény – např. specifikováním přípustných vstupů.
- Lze použít gramatiky pro podporu rozpoznávání řeči:
 - bezkontextové gramatiky
- Způsoby zápisů gramatik:
 - prostředky logického programování
 - proprietární řešení
 - otevřené standardy – JSGF, W3C SRGS, ...

Gramatiky pro podporu rozpoznávání řeči

Java Speech Grammar Specification (JSGF)

Dialogové
systémy

Luděk Bártek

Rozpoznávání
řeči

Rozpoznávání
izolovaných slov

Rozpoznávání
plynulé řeči

- Textový zápis gramatiky nezávislý na platformě a prodejci.
- Určen pro použití při rozpoznávání řeči.
- Součást Java Speech API.
- Používá styl a konvence jazyka Java.
- Aktuální verze 1.0 (říjen 1998).
- Použit např. v rozpoznávači Sphinx-4, VoiceXML interpretru VoiceGlue, ...
- Podrobněji v 2. polovině semestru při probírání tvorby dialogových rozhraní.

Gramatiky pro podporu rozpoznávání řeči

Ukázka JSGF

Dialogové
systémy

Luděk Bártek

Rozpoznávání
řeči

Rozpoznávání
izolovaných slov
Rozpoznávání
plynulé řeči

#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>;

Gramatiky pro podporu rozpoznávání řeči

W3C Speech Recognition Grammar Specification (SRGS)

Dialogové
systémy

Luděk Bártek

Rozpoznávání
řeči

Rozpoznávání
izolovaných slov
Rozpoznávání
plynulé řeči

- Standard W3C.
- Aktuální verze 1.0 (březen 2004).
- Definuje způsob zápisu pravidel a jejich odkazování.
- Dva způsoby zápisu:
 - XML
 - ABNF (Augmented BNF).
- Podrobněji v 2. polovině semestru při probírání tvorby dialogových rozhraní.

Ukázka W3C SRGS

Dialogové
systémy

Luděk Bártek

Rozpoznávání
řeči

Rozpoznávání
izolovaných slov

Rozpoznávání
plynulé řeči

```
#ABNF 1.0 UTF-8
root $pozdrav;
language cs-CZ;
mode voice;
$pozdrav = ahoj
```

```
<?xml version="1.0" encoding="utf-8"? >
<grammar root="pozdrav" xml:lang="cs-CZ" version="1.0" >
<rule id="pozdrav">
    ahoj
</rule>
</grammar>
```