Úvod do počítačového zpracování řeči

Luděk Bártek

Fakulta informatiky
Masarykova univerzita

podzim 2018

Obsah

1. Rozpoznávání řeči
   - Rozpoznávání izolovaných slov
   - Rozpoznávání plynulé promluvy

Cíle rozpoznávání řeči

- Cíle rozpoznávání řeči:
  - Interpretace příkazů uživatele – hlasové ovládání různých zařízení.
    - telefon
    - navigace
    - ...
  - Převod mluveného slova na text – přepis mluveného slova
    - záznamy soudních přelíčení
    - přenos řeči při velmi nízké přenosové rychlosti
    - ...
- Druhy rozpoznávání řeči:
  - rozpoznávání izolovaných slov
  - rozpoznávání plynulé promluvy.

Rozpoznávání řeči
Obecný postup

- Postup při rozpoznávání řeči:
  1. Získání posloupnosti vektorů příznaků.
     - vhodnou metodou zpracování signálu
  2. Klasifikace posloupnosti příznaků.
     - DTW
     - HMM
     - DNN
     - ...

Rozpoznávání izolovaných slov

Úvod

- Cíl – rozpoznání částí promluvy ohraničených z obou stran pauzou.
- Uživatel může zadávat pouze jednotlivé povely nebo musí po vyřčení slova udělat pauzu.
- Odpadá problém se stanovením rozhraní dvou slov/povelů. Povel může být víceslovný, ale pro tyto účely představuje jedno slovo.
- Obvykle jde o systémy závislé na uživateli
  - nutnost tréninku.
- Mívají omezenou kapacitu slovníku
  - slovník – seznam rozpoznávaných slov.
- Používají obvykle vektor příznaků.
  - Vektor hodnot získaných analýzou signálu (spektrum, kepstrum, LPA, energie, intenzita, autokorelace, . . .)
  - Získán některou z metod krátkodobé analýzy.

Vektory příznaků a jejich porovnávání

- Vektor příznaků
- Vektorový prostor nad tělesem F je množina V společně s dvěma operacemi sčítání vektorů a násobení skalárem, které splňují následující axiomy:
  - (V, +) je komutativní grupa
  - Násobení skalárem ($FxV \rightarrow V$) je asociativní a(b**v**) = ab(**v**)
  - 1**v**=v, kde 1 je jednotkový prvek tělesa
  - a dále platí distributivní zákon:
    - a(**v**+**w**) = a**v** + a**w**
    - (a+b)**v** = a**v** +b**v**
- Metrický prostor: Množina M se zobrazením d (metrikou), pro které platí:
  - $d(x, y) \geq 0$
  - $d(x, y) = 0 \Leftrightarrow x = y$
  - $d(x, y) = d(y, x)$
  - $d(x, z) \leq d(x, y) + d(y, z)$
- Příklad metriky je např. Euklidovská vzdálenost.

Klasifikátory

- Klasifikátory využívající porovnání slov metodou DTW (Dynamic Time Warping)
  - umožňují porovnání podobnosti dvou dynamických jevů, které probíhají různými rychlostmi.
- Klasifikátory založené na statistických metodách
  - modelování pomocí skrytých Markovových modelů.
- Klasifikátory založené na umělých neuronových sítích
  - Deep Neural Networks – použito např. v rozpoznávači CMU Sphinx
  - ...
- Hierarchické klasifikátory
  - Pracují hierarchicky:
    1. Akustická analýza signálu.
    2. Rozdělení signálu promluvy na segmenty.
    3. Fonetické dekódování jednotlivých segmentů.
    4. Rozpoznání slova (povelu) probíhá ve druhé vyšší úrovni na základě posloupnosti klasifikovaných segmentů.
  - Podobný princip se využívá pro rozpoznávání plynulé řeči.

Metoda DTW (Borcení časové osy)

- Používá se pro porovnání dvou úseků promluv (slov).
  - Úseky jsou vyjádřeny posloupností vektorů příznaků
    - úsek promluvy rozdělen do mikrosegmentů
    - klasifikovány souborem krátkodobých charakteristik
- Postup:
  1. Pro rozpoznávané posloupnosti vytvoříme soubor referenčních posloupností akustických vektorů.
  2. Vytvoříme posloupnost akustických vektorů pro rozpoznávané slovo.
  3. Metodou DTW porovnáme rozpoznávanou posloupnost s referenčními a vybereme tu, s největší shodou.

Metoda DTW
Pokračování

- Algoritmus hledá parametrizaci f,g takovou, že i=f(k),j=g(k), k=1, ..., K, minimalizuje výraz:

$$D(A,B) = \sum_{k=1}^{K} d(a(f(k)), b(g(k)))$$

  - d je vzdálenost mezi akustickými vektory (např. Euklidovská metrika)
  - Euklidovská metrika

$$d(a,b) = \sqrt{(\sum_{i=1}^{n}(a_i - b_i)^2)}$$

Metoda DTW (2.)

- Omezující podmínky:
  - 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 např. k nevhodné korespondenci mezi příliš krátkým segmentem vzorku A a příliš dlouhým segmentem vzorku B.
  - Omezení na hraniční body:
    - $f(1) = 1, f(K) = I$
    - $g(1) = 1, g(K) = J$

Metoda DTW (3.)

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

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

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

DTW – praktická realizace klasifikátoru slov

Blokové schéma

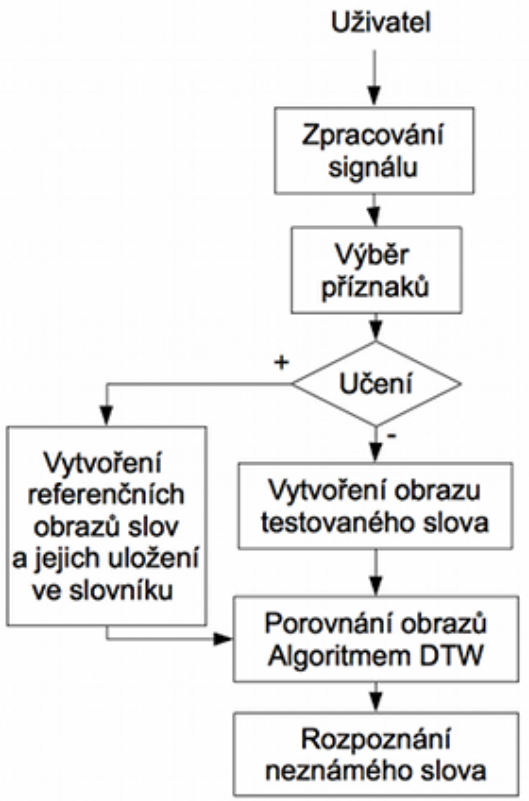

Obrázek: Blokové schéma algoritmu DTW

DTW – praktická realizace klasifikátoru slov

Trénování

- Obecný postup:
  1. Řečník resp. skupina řečníků vysloví postupně každé trénované slovo požadovaného slovníku. Buď jednou nebo opakovaně
  2. Vstupní slova jsou zdigitalizována, nejčastěji do formátu PCM.
  3. Dále jsou převedena zvolenou metodou krátkodobé analýzy na posloupnost vektorů příznaků.
  4. Detekce hranic slov
     - může být náročné na provedení např. kvůli rušivému pozadí.
     - Nekorektní detekce hranic slov zhoršuje úspěšnost rozpoznávání
     - Metody odstraňující i jen částečně vliv pozadí zvyšují výpočetní náročnost.
  5. Vytvoření referenčních obrazů slov.

DTW – Metody vytváření referenčních obrazů slov

- Přímé využití obrazů trénovací množiny jako referenčních obrazů slov
  - namluvená slova od jednoho nebo více řečníků jsou použita jako referenční vzory
  - 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 nebo dynamického průměrování
  - lineární průměrování:
    - provedeme lineární časovou normalizaci všech akustických obrazů trénovací množiny
    - výsledné referenční složky obrazu určíme jako průměr odpovídajících složek obrazů pro dané slovo
  - dynamické průměrování:
    - vzorový obraz se vytváří použitím algoritmu DTW

DTW – Metody vytváření referenčních obrazů slov
pokračování

- Vytváření vzorových obrazů shlukováním
  - Rozdělíme vzorové obrazy pro dané slovo 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 (viz Levinson, Rabiner , Sondhi – Interactive Clustering Techniques for Selecting Speaker-Independed Reference Templates for Isolated Word Recognition, IEEE Transactions on ASSP, 27, 1979, č 2)
    - automaticky – algoritmy založené na MacQueenově algoritmu (viz např. Komunikace s počítačem mluvenou řečí).

DTW – praktická realizace klasifikátoru slov

Rozpoznávání (klasifikace)

- Během klasifikace probíhá zpracování řečového signálu stejně jako při učení:
  - pokud jsou referenční obrazy normalizovány je nutné normalizovat i rozpoznávaná slova.
- Pravidla využívaná při klasifikaci:
  - minimální vzdálenost
  - varianty pravidla nejbližšího souseda

Redukce výpočetních a paměťových nároků při použití DTW

- Nevýhody DTW:
  - Vysoké paměťové a výpočetní nároky – mohou znesnadňovat klasifikaci v reálném čase i při relativně malém slovníku.
- Metody řešení:
  - hrubá síla – využití drahých paralelních procesorů případně zákaznických obvodů
  - vhodné zakódování parametrů jednotlivých mikrosegmentů referenčních i testovacích obrazů
  - redukce počtu mikrosegmentů akustického obrazu slova – využívají se oblasti spektrální stacionarity řečového signálu
  - snížení výpočetní náročnosti při hledání nejbližšího souseda ve slovníku
    - vhodná volba prohledávacích postupů.

Redukce výpočetních a paměťových nároků při použití DTW 2.

- Redukce oblasti prohledávání funkce DTW
  - pomocí heuristik do operací porovnávání obrazů.
- Vhodné zakódování parametrů mikrosegmentů
  - využívá vektorovou kvantizaci a kódovou knihu
  - kódová kniha
    - abeceda konečného počtu kvantizovaných vzorků:
    - každý vektor ve vzorku lze nahradit jeho pořadovým číslem
    - při předem definované kódové knize lze dopředu spočítat matici vzájemných vzdáleností mezi kvantizačními vzory.
- Využití oblastí spektrální stacionarity řečového signálu
  - využívá se přítomnost oblastí spektrální stacionarity
  - metoda spektrální stopy:
    - spektrální stopa – spojnice koncových bodů vektorů příznaků
    - aproximace – např. lineárními úseky.

Redukce výpočetních a paměťových nároků při použití DTW 3.

- Zavedení účinných způsobů vyhledávání nejbližšího souseda.
  - Viz metody prohledávání metrických prostorů.
    - Nutno ověřit, že vzdálenost použitá v algoritmu DTW je metrika.
- Redukce výpočetních nároků pomocí heuristik při porovnávání:
  - Vícestupňový rozhodovací postup:
    1. Porovnáváme promluvu proti celému slovníku pomocí pouze několika příznaků.
    2. Výstupem je soubor perspektivních kandidátů (řádově jednotky desítek), ve kterém se vyhledává pomocí klasického DTW.
  - Práh zamítnutí:
    - Po každém kroku porovnáváme spočítanou vzdálenost.
    - Překročíme-li experimentálně získanou hodnotu prahu obraz je zamítnut.

Metoda HMM (Hidden Markov Model)

Úvod

- 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 chápat statisticky.
- Kvantizací akustických vektorů (vytvořením kódové knihy) lze dosáhnout konečnosti všech parametrů odpovídajícího modelu.

Princip použití HMM pro rozpoznávání

- Jsou generovány dvě vzájemně svázané časové posloupnosti náhodných proměnných:
  - Podpůrný Markovův řetězec – posloupnost konečného počtu stavů.
  - Řetězec konečného počtu spektrálních vzorů.
- Náhodné funkce ohodnocující pravděpodobnostmi vztah vzorů k jednotlivým stavům.
- Pro rozpoznávání řeči nejčastější využívané levo-pravé Markovovy modely.
  - Vhodné pro modelovaní procesů spjatých se vzrůstajícím časem.

Markovův proces

- Markovův proces G se skrytým Markovovým modelem je pětice $G = (Q, V, N, M, \pi)$
  - $Q = \{q_1, ...q_k\}$ – množina stavů
  - $V = \{v_1, ..., v_m\}$ – množina výstupních symbolů
  - $N = (n_{i,j})$ – matice přechodu
    - určuje pravděpodobnost přechodu ze stavu q_i v čase t do stavu q_j v čase t_1
  - $M = (m_{i,j})$ – 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 i. stav je počáteční)
- Trojice $\lambda = (N, M, \pi)$ – soubor parametrů HMM; vytváří model řečového segmentu (slova, ...)
  - např. Vintsjukův model pro slovo:
    - počet stavů 40 — 50 – odvozeno od průměrného počtu mikrosegmentů ve slově (délka mikrosegmentu 10 ms)

Určení pravděpodobnosti promluvy

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

Určení pravděpodobnosti
Pokračování

- Výpočet odpředu:
  - α_i – pravděpodobnost přechodu do stavu q_i při generování posloupnosti $\{o_1, ..., o_t\}$ ($\alpha_i = P(o_1, o_2..o_t, q_i(t)|\lambda)$
  - Rekurzivní výpočet:
    1. inicializace
    $$\alpha_1(i) = \pi_i m_i(o_1)$$
    pro $1 \leq i \leq N$
    2. rekurze pro t=1,2, ... T-1
    $$\alpha_{t+1}(j) = [\sum_{i=1}^{N} \alpha_t(i) n_{i,j}] m_j(o_{t+1})$$
    pro $1 \leq j \leq N$, $m(o_t)$ je ekvivalentní zápisu $m_i(l)$, pokud $o_t = v_l$
    3. Výsledná pravděpodobnost:
    $$P(O|\lambda) = \sum_{i=1}^{N} \alpha_T(i)$$

Alternativní způsob výpočtu $P(O|\lambda)$

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

Trénování parametrů modelu $\lambda = (N, M, \pi)$

- Nutno stanovit postup při trénování parametrů modelu
  - maximalizace pravděpodobnosti $P(O|\lambda)$
  - neexistuje analytická metoda k zajištění globálního maxima
  - používají se iterativní algoritmy zajišťující aspoň lokální maximalitu
- Nejpoužívanější postup – Bauman-Welchův algoritmus.
- Problém při trénování modelu:
  - vliv konečné trénovací množiny – čím menší je trénovací množina a čím vetší matice M, tím vetší pravděpodobnost, že některé prvky matice budou nastaveny na 0 – problém chybějících (neadekvátních) dat

Rozhodovací pravidlo – rozpoznávání slova

- Princip maximální věrohodnosti:
  - Pro neznámé slovo O určíme hodnoty $P(O|\lambda)$ pro všechny modely λ.
  - Jako výsledek vybereme třídu s maximální hodnotou.

Implementace

- Modelování povelů:
  - nejčastější se používají modely se 4-7 stavy
  - lze využít SW nástroje pro tvorbu HMM:
    - HTK – Hidden Markov Model ToolKit (http://htk.eng.cam.ac.uk/)
- Modelování fonémů:
  - obvykle 4-7 stavů
  - model slova – zřetězení modelů fonémů
  - problémy s výpočtem v reálném čase
  - speciální algoritmy na vyhledávání

Příklady struktur HMM pro fonémy

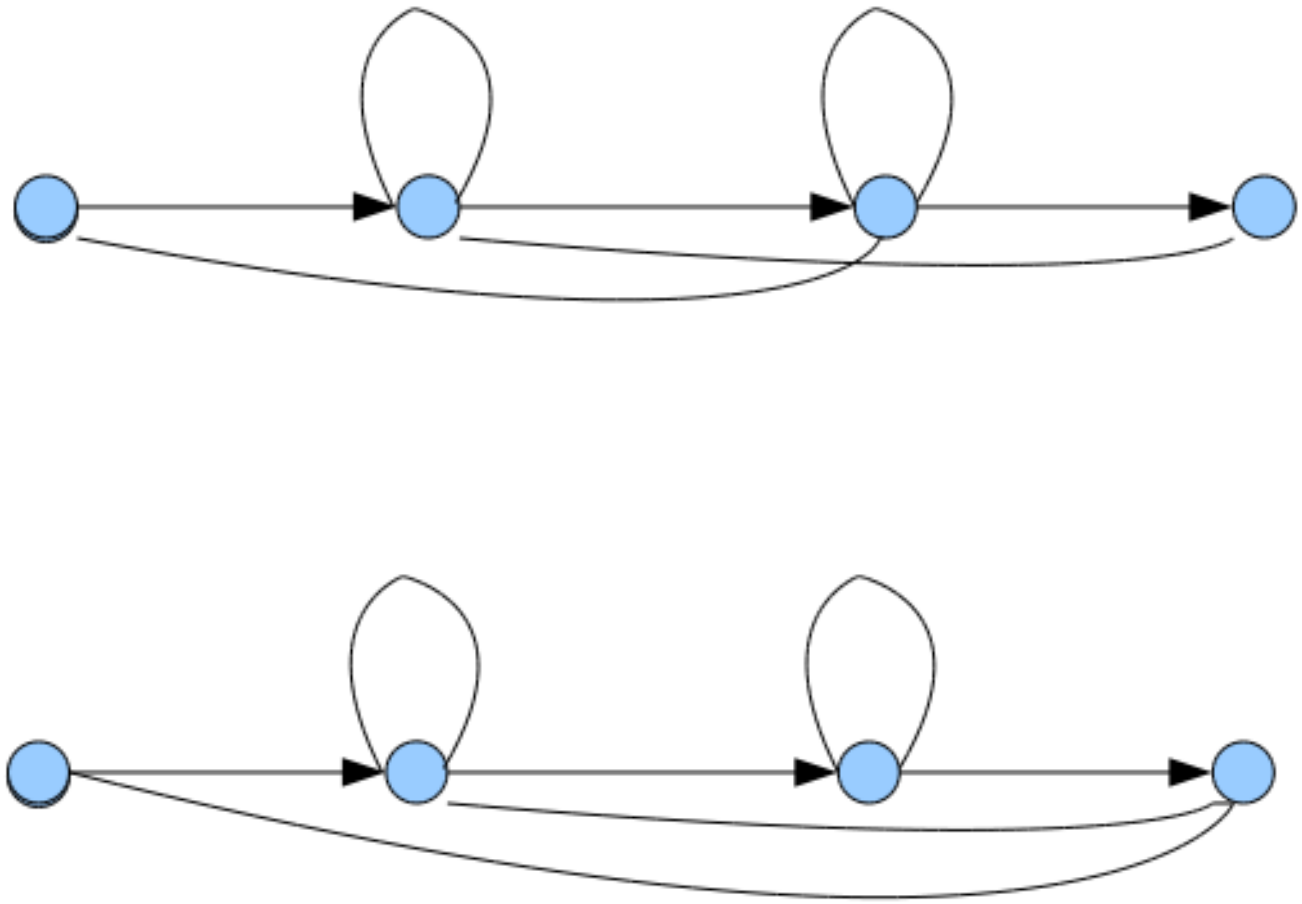

Příklady struktur HMM pro fonémy

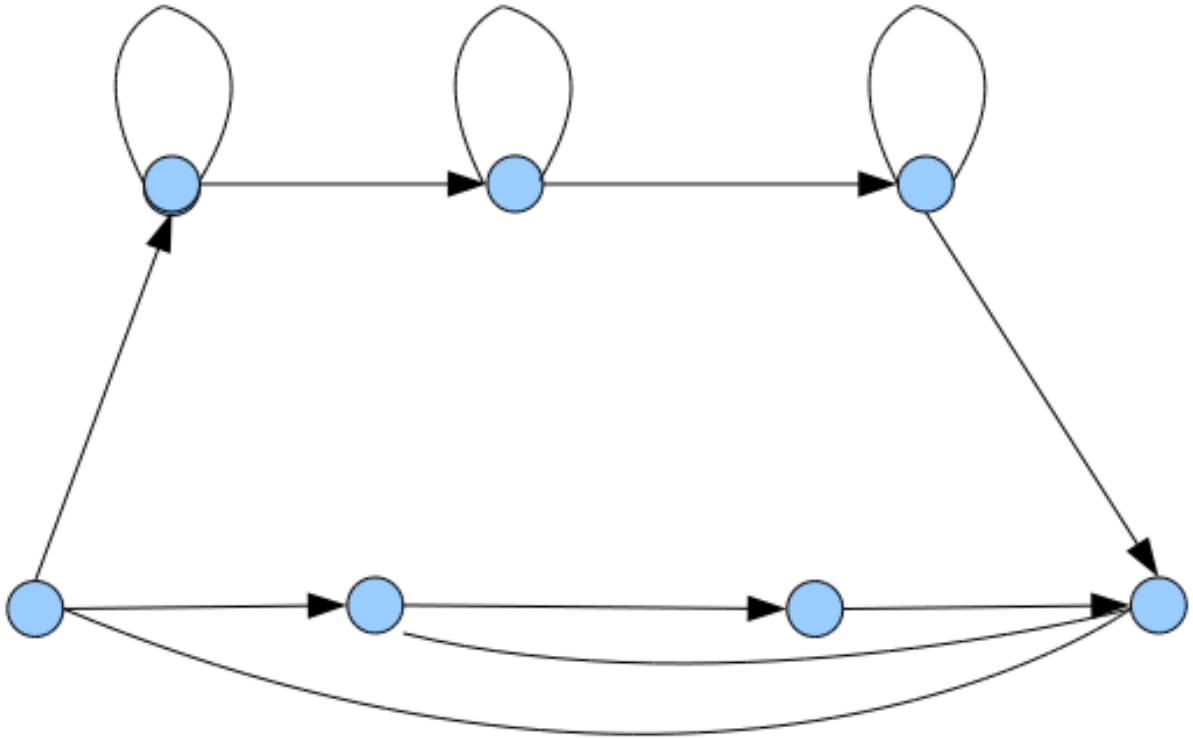

Obtíže při rozpoznávání izolovaných slov

- Určení začátku a konce promluvy:
  - šum kontra sykavky
  - detekce nahodilého zvukového vzruchu (klepnutí, ...) kontra okluzívy, které obsahují pauzy
  - možná přítomnost infrazvuků.

Ukázka plozívy

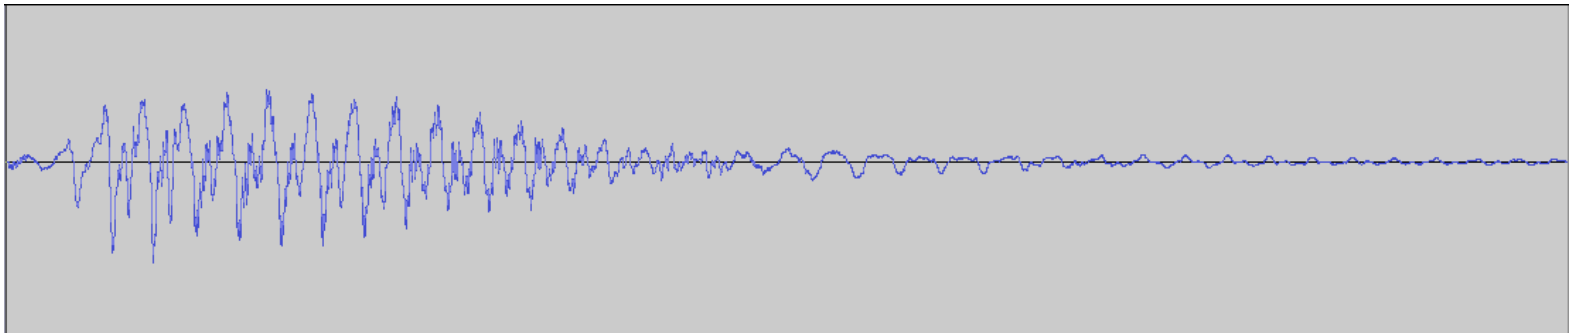

Obrázek: Hláska P

Deep Neural Network

- Vícevrstvá umělá neuronová síť s jednou vstupní vrstvou, jednou výstupní vrstvou a mnoha skrytými vrstvami
  - orientovaný graf, kde uzly jsou „neurony“, hrany představují „dendrity“ (vstupní hrany) a „axon“ (výstupní hrana)
  - dendrity a axony sousedních neuronů se propojují pomocí „synapsí“
  - vzruch proudící z neuronu do sousedního musí projít přes synapsi, která představuje odpor, který musí vzruch překonat
  - intenzita signálu jdoucího z vrstvy *l-1* do vrstvy *l*:

$$v^l = f(W^l v^{l-1} + b^l)$$

    - $v^l \in R^{N_l}$ – vzruch na vrstvě l
    - $W^l \in R^{N_l \times N_{l-1}}$ – váha synapse mezi vrstvou l a l-1
    - b^l – ovlivnění neuronů na l. vrstvě okolím
    - N_l – počet neuronů na N. vrstvě
    - $f(x)$ – aktivační funkce

Dopředný výpočet DNN

```
procedure ForvardComputation(O) //O - soubor vekto
V[O] = O
for l=1 ; l<L ; l++ // L - počet vrstev
  Z[l] = W[l]*V[l-1] + B[l]
  V[l] = f(Z[l])
Z[L] = W[L]*V[L-1] + B[L]
if došlo k regresi
  V[L] = Z[L]
jinak
  V[L]=softmax(Z[L])
return V[L]
```

$$softmax(Z[L]) = \frac{e^{Z[L]}}{\sum_{k=1}^{K} e^{z_k}}, \text{ pro L = 1,...,K.}$$

Rozpoznávání

- Algoritmus
  1. Na vstupní vrstu se přivede vektor příznaků.
  2. Na výstupní vrstvě je rozpoznaná hodnota.
- Implementace např. CMU Sphinx

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”
    1. 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:$P(W^*|O) = max(P(W|O)) = max(P(W) * \frac{P(O|W)}{P(O)})$
- 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 % v závislosti na:
  - 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=vla
```

References