

Úvod do počítačového zpracování řeči

Luděk Bártek

Fakulta informatiky
Masarykova univerzita

podzim 2023

Obsah

1 Syntéza řeči – postprocessing

2 Značkování prozódie

Prozódie

- Výstupem syntézy je monotóní hlas bez intonace a přízvuku – zní nepřirozeně
- Doplnění prozódie
 - základní prozodické prvky:
 - výška
 - hlasitost
 - doba trvání
 - nositelem je slabika
 - Větná intonace (prozódie) – závisí na typu věty:
 - otázky zjišťovací (odpověď ano/ne) – rostoucí
 - oznamovací, tázací doplňovací, rozkazovací – klesající
 - řeší se modulací F_0
 - Doplnění přízvuku/důrazu
 - modifikace F_0 a intenzity
 - lokální modifikace větné melodie

Prozódie – ukázky větné intonace

- Originální promluva (data/masse.wav)
- Oznamovací věta (data/masse-ozn.wav)
- Otázka zjišťovací (data/masse-dotaz.wav)

Výška základního tónu

- Výška základního tónu odpovídá formantu F_0 .
- Průběh F_0 na vokalickém jádru bývá nelineární.
- Změna intonace není pouhou změnou F_0
 - nutno modifikovat i vyšší formanty.
- Na základě důležitosti F_0 se jazyky dělí na:
 - tónové (čínština, vietnamština, ...)
 - čínské slovo -ma- v závislosti na průběhu F_0 může znamenat máma, konopí, kůň, nandávat
 - jazyky s melodickým přízvukem (srbskina, slovinština, litevština, norština, švédština, ...)

Další prozodické vlastnosti

- Intenzita (hlasitost):
 - fyzikální pohled – intenzita signálu v daném časovém okamžiku
 - fyziologický pohled – reakce vnitřního ucha (cortiho ústrojí) na vnímaný zvuk.
 - Tato hlediska se různí.
 - Subjektivní vnímání zvuku neodpovídá ani v prvním přiblížení fyzikální intenzitě signálu.
- Doba trvání:
 - Slabika může mít různou dobu trvání v různém kontextu.
 - Drobné odchylky mohou být i ve stejném kontextu.
 - Typická doba trvání slabiky 50 — 200 milisekund.

Další prozodické vlastnosti

- Kvalita hlasu
 - chvění hlasu (jitter)
 - nepravidelné výchylky v amplitudě F_0 (shimmer)
 - zbarvení tónu
 - ochraptělost
 - míra znělosti
 - ...
- Rychlosť řeči
 - Lze chápat jako převrácenou hodnotu průměrné délky slabiky
 - Lze měřit i jinými způsoby:
 - počtem vyslovených textových znaků za jednotku času (vyhodnocování syntetizérů řeči).

Další prozodické vlastnosti

Pokračování

- Pauza
 - tichá
 - vyplněná – obsahuje nějaký charakteristický zvuk (např. eeh)
 - ztížená detekce – hlavní formant je blízký formantům samohlásek "a", "e".
- Zaváhání
 - Přímo vypovídá o pragmatice projevu.
 - Důležitý např. pro modifikaci dialogové strategie u dialogových systémů.
 - Typický případ informace obsažené zejména v prozodické vrstvě jazyka.

Základní odvozené prozodické vlastnosti

- Rytmus (časování):
 - Prozodický prvek odvozený z dob trvání
 - slabik
 - pauz v daném časovém úseku.
- Slovní přízvuk
 - Je odvozen ze všech základních atributů.
 - Je výrazně jazykově závislý:
 - umístění přízvuku ve slově/přízvučné jednotce
 - míra použití prozodických prostředků k jeho vyjádření zejména použití hlasitosti oproti výše.
- Větný přízvuk (intonační centrum):
 - zjednodušeně jde o prozodické zvýraznění jádra výpovědi věty

Základní odvozené prozodické vlastnosti (2.)

• Intonace

- nejobecněji – časový průběh zvukového spektra hlasu
- za určující pro melodii se obvykle považuje základní hlasová frekvence – lze zobrazit grafem v závislosti na čase
 - časová závislost základní hlasové frekvence
- související terminologie:
 - melodie
 - kadence
 - intonační kadence
 - melodém
 - průběh F_0

• Emotivní zabarvení hlasu

- projevuje se:
 - rychlými změnami hlasitosti a základní frekvence
- Často přesahují hranici věty.
- Detekce je důležitá např. pro dialogové systémy – umožňuje zvolit vhodnou dialogovou strategii.

Základní odvozené prozodické vlastnosti (3.)

- Emfatický přízvuk

- Vytvářen emotivním zbarvením hlasu.
- Vyskytuje se např. ve větách pronesených v situacích s výrazným emocionálním kontextem, např.
 - To je tedy opravdu **neslýchané**.
 - Bolí to jak **čert**.

- Kontrastní přízvuk

- snaha o zdůraznění slova nebo slabiky v kontrastu s jiným slovem nebo slabikou během promluvy nebo dialogu:
 - "řekl jsem do **Šakvic** ne **Rakvic**"
 - "**byte** ne **bit**"

Základní odvozené prozodické vlastnosti (4.)

- Opakování
 - prozodický atribut silně svázaný s mluvčím.
 - Opakování bývá často variantou výplňkových částí promluvy – mluvčí si ji často ani neuvědomuje (nezaměňovat s koktáním – porucha řeči).
 - Může se jednat o formu zdůraznění – v krajním případ může být považováno za vadu řeči.
- Výplňkové části
 - kromě výplňkové funkce mohou charakterizovat
 - styl mluvčího: „Byl jsi včera na akci, **viď?**“
 - nářečí resp. slang: „**Vole**, ta včerejší spářka byla hustá, že **vole?**“

Základní odvozené prozodické vlastnosti (5.)

- Přerušení:
 - častý jev v mluvené řeči na úrovni:
 - vyšších celků (výpověď/promluva, věta, prozodická fráze, ...)
 - uvnitř slov.
 - Mívá návaznost na další prozodické prvky:
 - zaváhání
 - opakování
 - vyplněnou pauzu
 - ...
 - Zvyšuje obtížnost rozpoznávání mluvené řeči – nutno s ním počítat.
- Korekce částí promluvy:
 - Častý jev a to vzhledem k rozdílným částem.
 - Příčiny vzniku:
 - důsledek přeřeknutí,
 - upřesnění předchozí části promluvy,
 - oprava předchozí části promluvy.
 - Často následuje přerušení nebo další prozodické jevy.

Prozodické segmenty mluvené řeči

- Prozodické segmenty mluvené řeči:
 - Promluva.
 - Prozodická fráze
 - Skupina slov vytvářející jednotný intonační celek.
 - Představuje základní, z prozodického hlediska kompaktní strukturu.
 - Členění do prozodických frází ve velké míře souvisí se syntaktickou strukturou odpovídající věty.
 - Přízvukový takt
 - skupina slabik podřízená jednomu slovnímu přízvuku.
 - V češtině typicky slovo nebo slovo a jednoslabičné slovo.
 - Slabika

Standardy pro syntézu řeči

- Snaha sjednotit jazyky pro popis promluvy pro řečové syntetizéry.
- Definují značkování postihující:
 - prozódii
 - rychlosť řeči
 - F_0
 - zdůraznění části promluvy
 - pauzu
 - hlasitost
 - ...
 - mluvčího
 - pohlaví
 - věk
 - ...
 - ...
- Používané standardy:
 - SABLE
 - SSML

SABLE

- Vývoj započat v 2. polovině 90. let
- aplikace XML/SGML
- snaha o zkombinování 3 značkovacích jazyků pro syntézu řeči:
 - SSML – Speech Synthesis Markup Language (W3C, 1999)
 - STML – Spoken Text Markup Language (CSTR Edinburgh University, Lucent Technologies, 1997)
 - JSML – Java Synthesis Markup Language (Sun Microsystems, 2000)
- SABLE

SABLE

Základní značky

- SABLE – kořenová značka
- div – slouží k logickému členění dokumentu (odstavec, věta)
- prozodické:
 - EMPH – zdůraznění části promluvy
 - PITCH – výška promluvy
 - VOLUME – úroveň hlasitosti
 - RATE – rychlosť
 - BREAK – pauza
- popis hlasu:
 - SPEAKER – popisuje pohlaví a věk mluvčího
- fonetické
 - PRON – výslovnost – fonetický přepis
 - SAYAS – způsob fonetického přepisu (datum, telefon, url, poštovní adresa, ...)
 - LANGUAGE – jazyk promluvy

SABLE – ukázka

```
<SABLE>
<DIV TYPE="paragraph">
  <VOLUME LEVEL="quiet">Šepot.</VOLUME>
  <VOLUME LEVEL="medium">
    <RATE SPEED="fast">Rychlá věta.</RATE>
    <PITCH BASE="+50%">Vysoko posazená věta</PITCH>
  </VOLUME>
</DIV>
</SABLE>
```

SSML

- Vývoj započat v koncem 90. let
- součást W3C Voice Browser Activity
- Aktuální verze 1.0 (září 2004)

SSML

Základní značky

- kořenový element – speak
- strukturní elementy
 - p – odstavec
 - s – věta
- fonetické:
 - say-as – způsob fonetického přepisu (výslovnosti, datum, telefon, url, číslo, ...)
 - phoneme – fonetický přepis dané promluvy
 - sub – substituce (např. přepis zkratek, ...)
- popis hlasu:
 - voice – popis hlasu, kterým se má text přečíst (pohlaví, věk, ...)
- prozódie:
 - emphasis – zdůraznění částí promluvy
 - break – pauza
 - prosody – ovlivňuje prozodické jevy: výšku, průběh základní frekvence, rychlosť, délka trvání promluvy, hlasitost.

SSML

Ukázka

```
<?xml version="1.0"?>
<speak>
<voice gender="female">Female voice.</voice>
<voice gender="male">Male voice.</voice>
<emphasis level="soft">Soft emphasis</emphasis>
<p>Speech with 5 seconds <break time="5s"/> break.</p>
<prosody volume="+6dB">Speech at double volume.</prosody>
<prosody volume="-6dB">Speech at half volume.</prosody>
</speak>
```