

Struktura jazyka

Roviny analýzy jazyka. Fonetika

Aleš Horák

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

Obsah:

- ▶ Roviny analýzy jazyka
- ▶ Fonetika a fonologie

Struktura jazyka zahrnuje informace o:

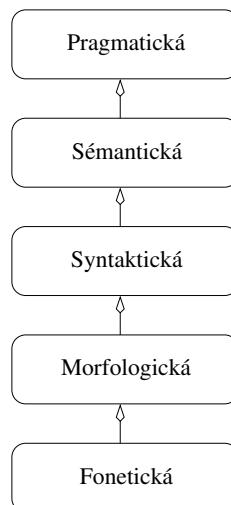
- ▶ co jsou **slova** (z jakých **znaků**, jaké slovní tvary a jejich složky)
- ▶ jak se slova (větné složky) kombinují do **vět**
- ▶ co slova označují, jaké jsou jejich **lexikální významy**
- ▶ jak se **význam věty** skládá z významů slov a slovních spojení (větných složek)

zpracování jazyka dále potřebuje:

- ▶ obecnou (encyklopedickou) **znalost světa** (ontologie)
- ▶ **inferenční mechanismus**
- ▶ **znalost komunikační situace**

Roviny analýzy jazyka

znanosti struktury jazyka jsou propojeny **hierarchicky**



jazykové **roviny**:

- ▶ **fonetická**
- ▶ **morfologická**
- ▶ **syntaktická**
- ▶ **sémantická**
- ▶ **pragmatická**
- ▶ kontextová
- ▶ znalost základní ontologie
- ▶ jazykové metaznalosti

Roviny analýzy jazyka – příklad

rovina analýzy

příklad

pragmatická

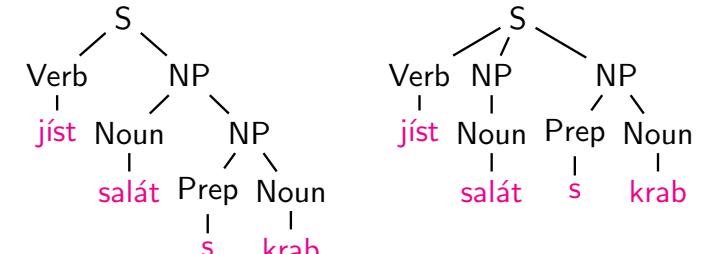
Jíst(I₂, Salát, T₁₃) ∧ with(Salát, krab)

sémantická

Jíst(On, Salát, T_{min}) ∧ with(Salát, krab)

syntaktická

Jíst_{with}(On, Salát, krab, T_{min})



morfologická

jíst–Verb3MSP, salát–Noun4IS, s–Prep7, krab–Noun7MS

fonetická

[j e d l s a l a t s k r a b e m]

povrchová

"Jedl salát s krabem."

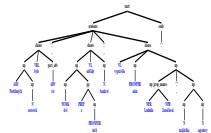
Roviny analýzy jazyka – pokrač.

- ▶ **fonetická** – postihuje vztahy mezi zvuky používanými v (mluveném) jazyce, jejich skládání do slabik a slov
- foném** – nejmenší jednotka jazyka, která může **odlišit** význam nadřazených jednotek
- kosit/nosit** fonémy **k** a **n** odlišují dvě slova
- často odpovídají **znakům** → vždy ale označují **zvuky**

NLP úkoly: např. **syntéza řeči, rozpoznávání řeči, rozpoznávání emocí v hlase**

Roviny analýzy jazyka – pokrač.

- ▶ **syntaktická** – struktura větných frází popisuje, jak vypadá **gramaticky správná věta**, většinou pomocí **pravidel gramatiky**
- syntaktický analyzátor** – nástroj, který analyzuje vstup na základě gramatiky na výstup dává různé info, např. derivační stromy



NLP úkoly: např. **generování jazyka, extrakce informací, korektury gramatiky, extrakce termínů a klíčových frází**

Roviny analýzy jazyka – pokrač.

- ▶ **morfologická** – interní struktura slov, skládání slov z menších jednotek **morfém** – nejmenší jednotka, která může **nést** význam
 - pří-lež-it-** **pří** – prefix (*blízko*)
 - ost-n-ými:** **lež** – lexikální kořen (*ležet*)
 - it** – adjektivní derivační sufix (*ten, který*)
 - ost** – substantivní derivační sufix (*ta skutečnost, že*)
 - n** – adjektivní derivační sufix (*charakteristický pro*)
 - ými** – gramatický afix (*instrumentál plurálu*)

NLP úkoly: např. **indexování textů, korektury pravopisu, analýza sentimentu, získávání informací, modelování tématu/stylu**

Roviny analýzy jazyka – pokrač.

- ▶ **sémantická** – význam výrazů přirozeného jazyka a jejich kombinací hodně závisí na zvolené **sémantické reprezentaci**
- logická analýza věty** – strukturní část sémantické analýzy

NLP úkoly: např. **strojový překlad, odpovídání na otázky, summarizace textu**

- ▶ **pragmatická** – zkoumá vztah mezi výrazy přirozeného jazyka a **kontextem** často se do ní řadí znalost **komunikační situace, základní ontologie a jazykových metaznalostí**

NLP úkoly: např. **porozumění textu, dialog člověk–stroj, zpřesněné verze úkolů z ostatních vrstev**

Fonetika a fonologie

Fonologie:

- ▶ **fonologický systém** jazykových zvuků v *určitém jazyce*
- ▶ pracuje s **gramatikou** řečových zvuků
- ▶ pomocí gramatických pravidel popisuje historické změny i současné alternace

Fonetika:

- ▶ studuje **produkci, přenos a příjem** jazykových zvuků
- ▶ má klíčový význam např. pro oblast automatického **rozpoznávání** a **syntézy řeči**
- ▶ není tradičně chápána jako součást gramatiky jazyka

Členění řečového proudu

Řečový proud:

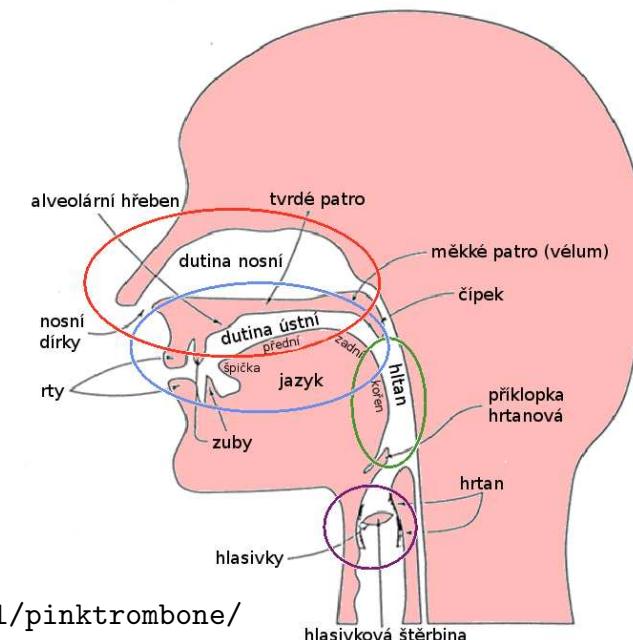
- ▶ nejsou mezery mezi slovy
- ▶ nejsou žádné izolované zvuky
- ▶ přesto všechny jazyky pracují s lingvistickými jednotkami jako separátními

oronym/orofón – fráze, které zní stejně/podobně, ale mají jiný obsah
(≠ české *oronymum!*)

It's not easy to recognize speech.

It's not easy to wreck a nice beach.

Kde vznikají jazykové zvuky?



<https://dood.al/pinktrombone/>

Fonetické jednotky

- ▶ **foném (phoneme)**
 - ▶ základní jednotka **zvukového systému** jazyka
 - ▶ foném je **abstraktní** věc, konkretizuje se pomocí **fónů** (viz dále)
 - ▶ např. v **češtině** – 37 základních fonémů:
 - a, a:, b, ts, tS, d, d', dz, dZ, e, e:, f, g, h\, x, i, i:, j, k, l, m, n, n', o, o:, p, r, r', s, S, t, t', u, u:, v, z, Z
- ▶ **fón (phone)**
 - ▶ **řečový zvuk** z hlediska jeho **fyzikálních charakteristik** (zvuková vlna určitého tvaru)
 - ▶ bez zařazení k zvukovému systému jazyka
 - ▶ jeden **foném** odpovídá **množině** fónů
 - ▶ **afolón** určitého fonému = jeden z množiny fónů tohoto fonému např. **nosit, banka**

Fonetická transkripce

- ▶ jeden z nejpoužívanějších **nástrojů fonetiky**
- ▶ **převod** řečového proudu do lingvisticky významných **symbolických jednotek**
- ▶ používá se standardních **fonetických abeced** (viz dále)
- ▶ **široká** × **úzká** (broad/narrow) transkripce = převod do **fonémů/fónů**
- ▶ důvody pro tento převod: nedostatečnost písmenného zápisu, mezijazykové/krajové variace v písmenném zápisu
 - jedno písmeno → různý zvuk
 - spodoba znělosti v češtině: *vypít* [v] / *vpustit* [f]
 - krajové variace výslovnosti: *shánět* – moravská [z h], česká [s ch]
 - 'c' → [c] v latinském *Ciceron*, [k] v *canis*, [č] v italském *ciao*
 - 'ch' → [ch] v čes. *chovat*, [č] v angl. *cheat*, [k] v it. *Chianti*
 - jeden zvuk → různá písmena (foném může být zaznamenán více písmeny)
 - [j] → 'j' v českém *jídlo*
→ 'y' v anglickém *yes*
→ 'ea' v anglickém *beautiful*
 - [f] → 'f' v českém *fyzika*
→ 'gh' v anglickém *laugh*
→ 'ph' v řeckém *philosophia*

Fonetické abecedy IPA a SAMPA

IPA:

- ▶ *International Phonetic Alphabet*
- ▶ vznikla v roce 1886 v Paříži, od té doby několik revizí (poslední 1996, drobnosti pak 2005 a 2015)
- ▶ speciální znak pro vyjádření každého fónu
- ▶ mezinárodně **standardní zápis** – jsou k dispozici tabulky a fonty
- ▶ *Unicode* – speciální IPA znaky v rozsahu U+0250–02AD
zápis např. www.i2speak.com

SAMPA:

- ▶ *Speech Assessment Methods Phonetic Alphabet*
- ▶ vznikla v projektu SAM (Speech Assessment Methods) v letech 1987–89
- ▶ **strojově čitelná** fonetická abeceda
- ▶ <http://www.phon.ucl.ac.uk/home/sampa/>

Příklady dat pro českou transkripci pro MBROLA

- ▶ pravidla pro přepis do fonémů

CLASS SA	[aáeééííóóúúýý]	# samohlásky
CLASS ZPS	[bdd'gvzžhČČ]	# znělé párové souhlásky
CLASS NPS	[ptt'kfsšHcčč]	# neznělé párové souhlásky
[[dě]]	→ d' e	
[[b]]	(_ NPS ZPS_)	→ p
[[p]]	ZPS	→ b

- ▶ vstup pro MBROLA – text "shání tě též muž"

_ 200 0 132	i: 93 0 114	S 81 0 114
z 57 0 115	t' 27 0 120	m 43 0 120
h 45	e 50 0 114	u 61
a: 137	t 31 0 120	S 110
n' 75 0 132	e: 102	#

- ▶ zvuková databáze cz2 – 37 fonémů, 1442 difónů
nutné ručně "nařezat" všechny difóny

IPA – souhlásky

v **americké angličtině** – *pulmonické i nepulmonické*

	labio-labiálna	labio-dentálna	alveolára	palatálna	velára	glotálna
ploziva	p b		t d		k g	
frikativa		f v θ ð s z ſ ſʒ			h	
afrikáta				tʃ dʒ		
nazála	m		n		ŋ	
aproximanta			l r			
laterální						
retroflexní						
koarticulovaná	w			j		

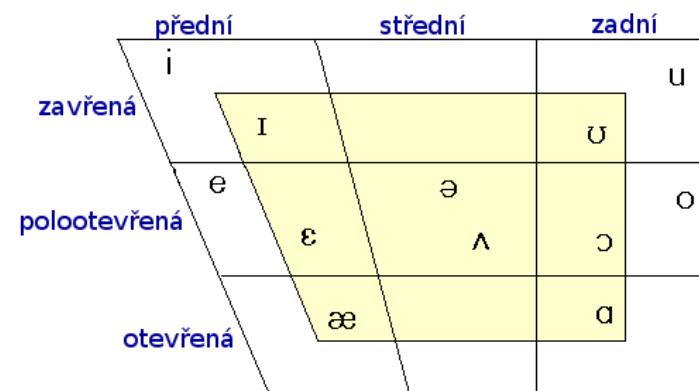
IPA – souhlásky ve slovech

p	plate, piece, spin, capital, stop, tramp
t	trip, time, winter, retire, wait, front
k	kite, climb, character, rocket, back, sink
b	bill, brush, sober, ramble, sob, bulb
d	dark, drive, redder, ponder, head, hard
g	go, grease, rigor, anger, log, iceberg
m	man, mile, remorse, ample, climb, harm
n	nice, know, enough, cunning, sign, burn
ŋ	finger, singer, drunk, rang, thing
θ	thank, three, ether, panther, path, birth
ð	then, these, feather, breathe
f	fit, fly, effort, perform, enough, Ralph
v	very, view, every, prevail, love, starve

IPA – samohlásky

v americké angličtině

vokalicky čtyřúhelník

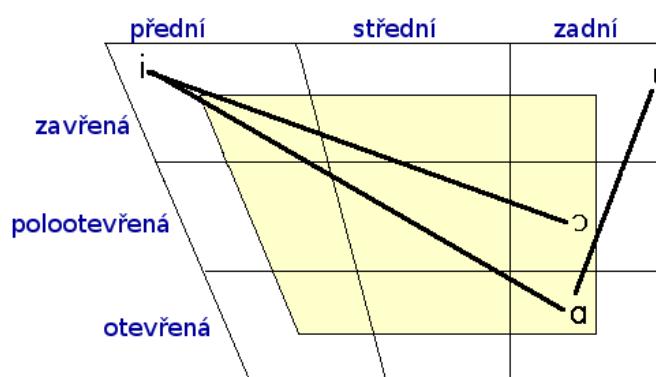


IPA – samohlásky ve slovech

i	heed, beat, believe, people, scary
ɪ	hid, bit, injure, resist, finish
e	hate, bait, great, they, say, neighbor
ɛ	head, bet, friend, says, guest
æ	had, bat, laugh, calf, language
ə	above, around, sofa, police
ʌ	bus, rush, under, other

IPA – dvojhlásky

v americké angličtině



ai find, high, aisle, quiet, ride

au house, crown, around, flower, how

ɔi boy, enjoy, Freud, avoid, join

Text-to-Speech systémy

- ▶ **syntéza řeči** – převod psaného textu na (digitální) zvuk
- ▶ TTS, *Text-to-Speech*
- ▶ dvě hlavní části
 1. **jazykový modul**, NLP modul
 - vstup = text
 - výstup = fonémy + prozodická informace označována také jako TTP, *Text-to-Phoneme*
 2. **modul zpracování signálu**, DSP (Digital Signal Processing) modul
 - vstup = výstup z NLP modulu
 - výstup = zvukový soubor

Příklady TTS systémů se vztahem k češtině

- ▶ **Epos** – z 90. let, Karlova univerzita a ČAV, nejlepší český open source
- ▶ **MBROLA** – difónová syntéza MBR-PSOLA, řeší DSP část Mikuláš Piňos, DP 2000 – česká DB pro MBROLA, text2phone v Perlu
- ▶ **Demosthenes** – FI MU Brno, laboratoř LSD slabiková syntéza, základní prozodie
- ▶ **ARTIC** (ARtificial Talker In Czech) – ZČU Plzeň, **DEMO** obsahuje i "Talking head" vizuální část
- ▶ **CS-Voice 97** – komerční, Frog Systems, pro Windows
- ▶ **Espeak** – open source, formantová syntéza, včetně češtiny
- ▶ **Festival** – z Edinburghu, GPL, hodně jazyků, projekt Festival Czech