

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:

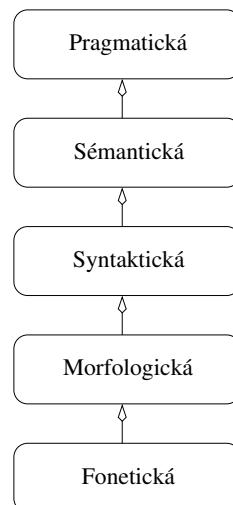
- ▶ co jsou **slova** (z jakých **znaků**, jaké slovní tvary a jejich složky)
- ▶ jak se slova (větné složky) kombinují do **vět**
- ▶ co slova označují, jaké jsou jejich **lexikální významy**
- ▶ jak se **význam věty** skládá z významů slov a slovních spojení (větných složek)

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

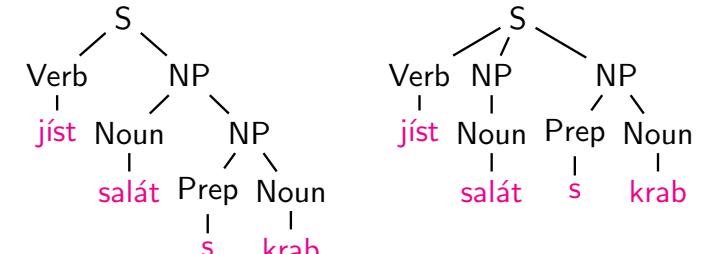
Jíst(I₂, Salát, T₁₃) ∧ with(Salát, krab)

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

- ▶ **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*)

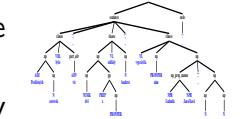
ými – gramatický afix (*instrumentál plurálu*)

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



- ▶ **sémantická** – význam výrazů přirozeného jazyka a jejich kombinací hodně závisí na zvolené **sémantické reprezentaci**

logická analýza věty – strukturní část sémantické analýzy

- ▶ **pragmatická** – zkoumá vztah mezi výrazy přirozeného jazyka a **kontextem**

často se do ní řadí znalost **komunikační situace, základní ontologie a jazykových metaznalostí**

Fonetika a fonologie

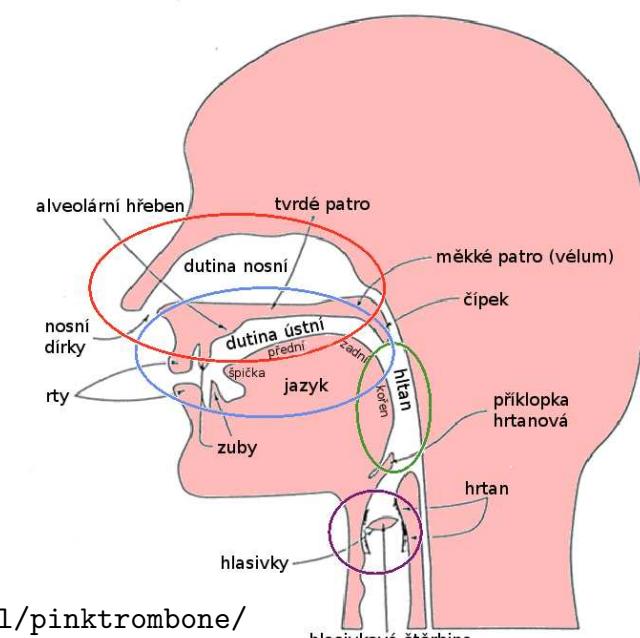
Fonologie:

- ▶ **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

Kde vznikají jazykové zvuky?



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.

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 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**
 - ▶ **aofón** určitého fonému = jeden z množiny fónů tohoto fonému např. **nosit, banka**

Příklady dat pro českou transkripcí pro MBROLA

- ▶ pravidla pro přepis do fonémů

CLASS SA	[aáééěííóóúúýý]	# samohlásky
CLASS ZPS	[bdd'gvzžhCČ]	# znělé párové souhlásky
CLASS NPS	[ptt'kfsšHcč]	# neznělé párové souhlásky

[[dě]] → d'
[[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

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/>

IPA – souhlásky

v americké angličtině – pulmonické i nepulmonické

	labio-labiálna		dentálna		alveolára		palatálna		velára		glotálna	
ploziva	p	b			t	d			k	g		
frikativa			f	v	θ	ð	s	z	ʃ	ʒ	h	
afrikáta									tʃ	dʒ		
nazálna	m						n			ŋ		
aproximant							l					
laterální							r					
retroflexní												
koartikulovaná	w								j			

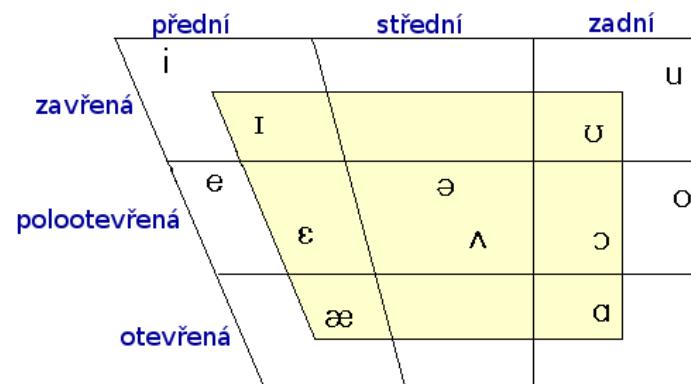
IPA – souhlásky ve slovech

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
s	ceiling, slim, psychology, Pacific, nasty, pass
z	zoo, zipper, hazard, prison, cares, breeze
ʃ	shore, sugar, nation, rash, Porche
tʃ	(genre), visual, measure, decision, massage
χ	hat, who, ahead, perhaps
h	China, cheap, ritual, teaching, beach, punch
dʒ	jump, pigeon, reject, individual, ridge, engine
l	light, look, pillow, applaud, salt, ball, girl
r	real, row, around, part, care, hear
w	wind, was, await, swim, queen
j	yes, use, beyond, beauty, punitive

IPA – samohlásky

v americké angličtině

vokalický čtyřúhelník

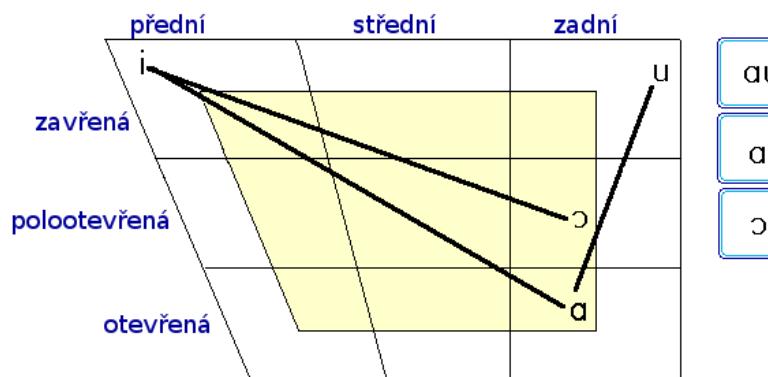


IPA – samohlásky ve slovech

i heed, beat, believe, people, scary	u food, boot, pool, through, who, sewer
ɪ hid, bit, injure, resist, finish	ʊ hood, book, pull, put, would
e hate, bait, great, they, say, neighbor	ɔ hole, boat, sew, know, so
ɛ head, bet, friend, says, guest	ɔ̄ bought, law, wrong, stalk
æ had, bat, laugh, calf, language	ɑ pot, "la", stocking, father, rob
ə above, around, sofa, police	
ʌ bus, rush, under, other	

IPA – dvojhlásky

v americké angličtině



au
ai
ɔɪ

ai	find, high, aisle, quiet, ride
au	house, crown, around, flower, how
ɔɪ	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