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

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

znalosti struktury jazyka jsou propojeny **hierarchicky**

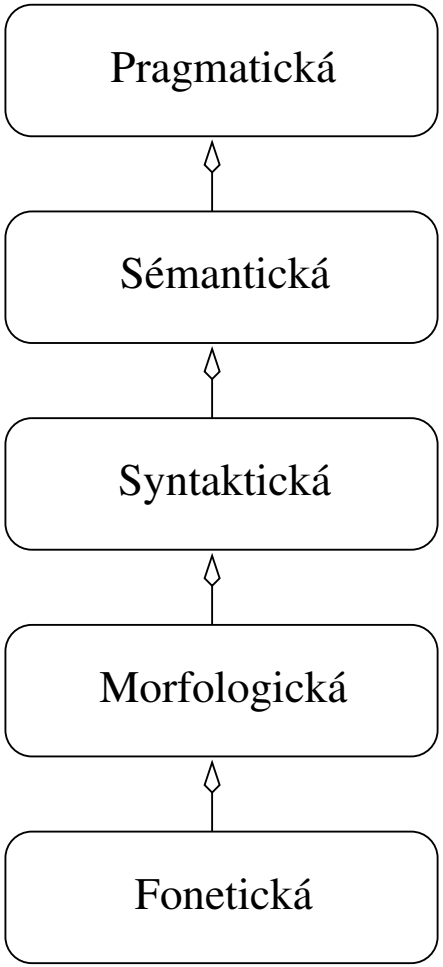

jazykové **roviny**:

- **fonetická**
- **morfologická**
- **syntaktická**
- **sémantická**
- **pragmatická**

- kontextová
- znalost základní ontologie
- jazykové metaznalosti

Roviny analýzy jazyka – příklad

rovina analýzy	**příklad**
pragmatická	$\neg Na_živu(Krtek_1, T_3)$ $Unavený(Krtek_1, T_3)$
sémantická	$\neg Na_živu(Krtek, Teď)$ $Unavený(Krtek, Teď)$
syntaktická	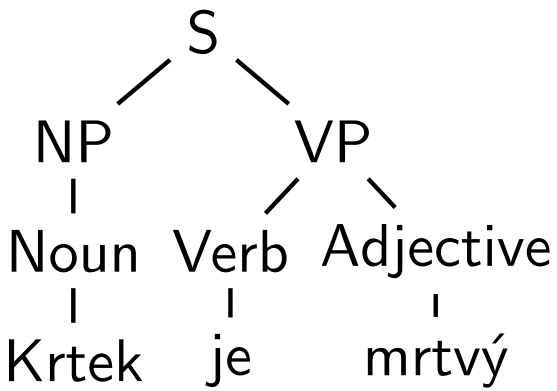
morfologická	Krtek–Noun1MS, je–Verb3MP, mrtvý–Adjective1MS
fonetická	[k r t e k j e m r t v i:]
povrchová	"Krtek je mrtvý."

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

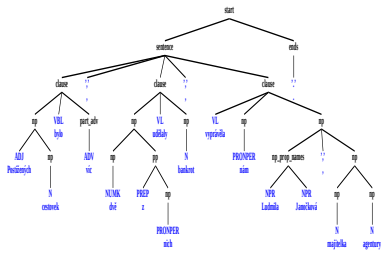

- sémantická – význam výrazů přirozeného jazyka a jejich kombinací
  hodně závisí na zvolené **sémantické reprezentaci**
  logická analýza věty – strukturní část sémantické analýzy
- pragmatická – zkoumá vztah mezi výrazy přirozeného jazyka a **kontextem**
  často se do ní řadí znalost **komunikační 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?

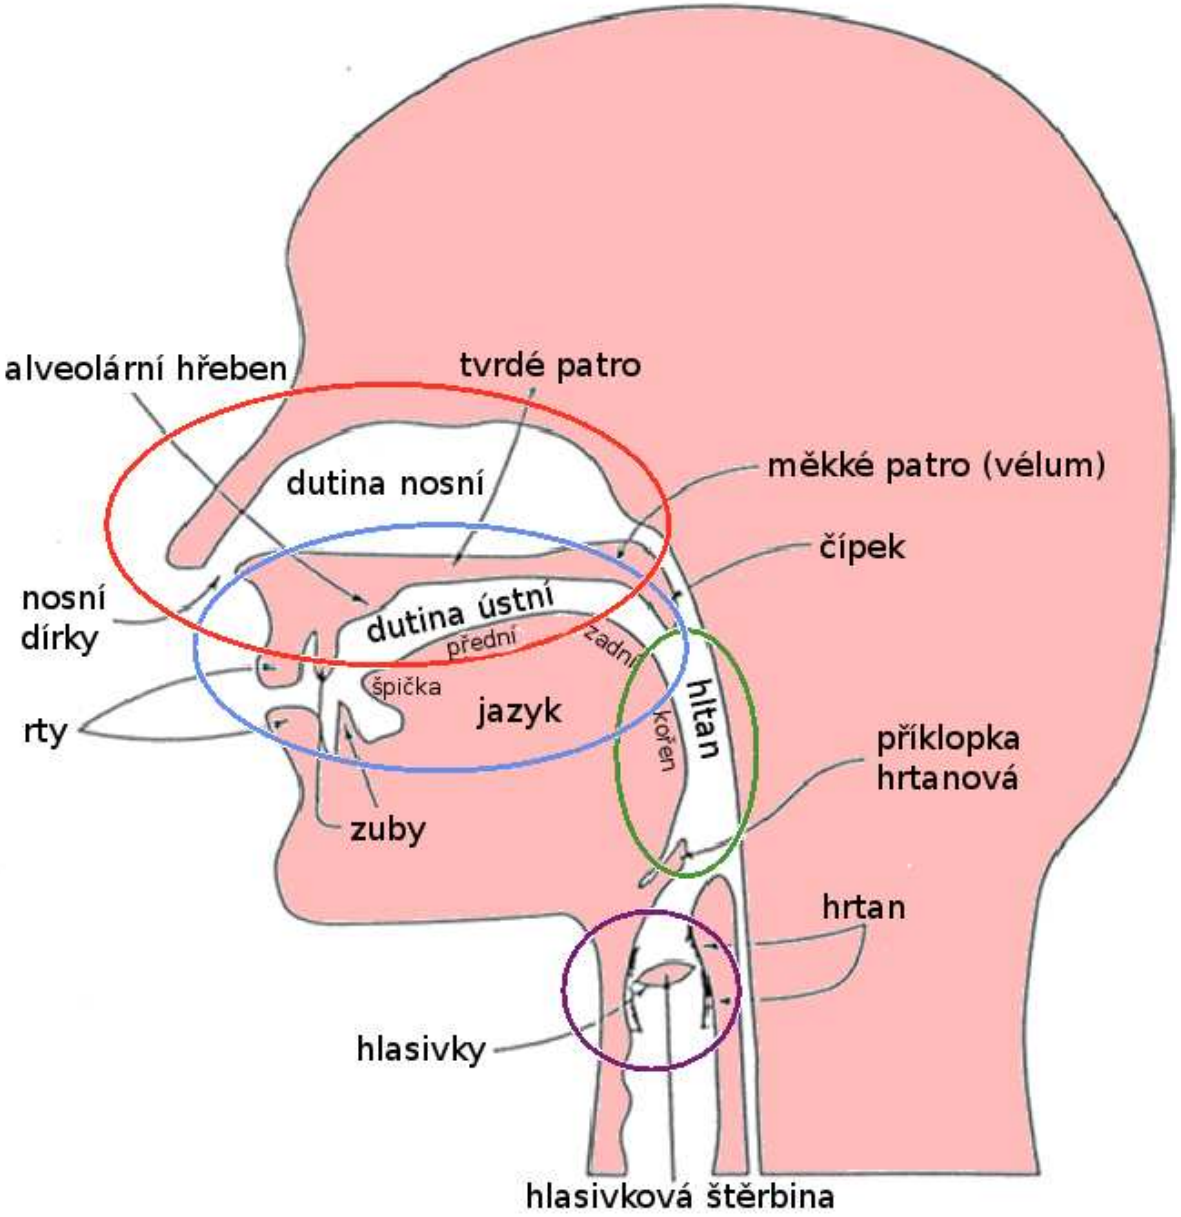

Členění řečového proudu

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 ($\neq$ české *oronymum*!)

> It's not easy to recognize speech.
> It's not easy to wreck a nice beach.

Fonetické jednotky

- foném (*phoneme*)
  - základní jednotka **zvukového systému** jazyka
  - foném je *abstraktní věc*, konkretizuje se pomocí *fónů* (viz dále)
  - např. v **češtině** – 37 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
  - **alofón** určitého fonému = jeden z množiny fónů tohoto fonému

    např. `nosit`, `banka`

Fonetická transkripce

- jeden z nejpoužívanějších **nástrojů fonetiky**
- **převod** řečového proudu do oddělených, 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
    - `vypít [v] / vpustit [f]`
    - '`k`' → '`c`' v latinském `canis`, '`ch`' v italském `Chianti`
    - '`č`' → '`ch`' v anglickém `cheat`, '`ci`' v italském `ciao`
  - jeden zvuk → různá písmena
    příp. jeden foném může být zaznamenán více písmeny
    - `chovat [x] / shánět [x]`
    - '`f`': → '`f`' v českém `fyzika`
      → '`gh`' v anglickém `laugh`
      → '`ph`' v řeckém `philosophia`

Příklady dat pro českou transkripci pro MBROLA

- pravidla pro přepis do fonémů

```
CLASS SA    [aáeéěiíoóuúůyý]   # samohlásky
CLASS ZPS   [bdd'gvzžhCČ]      # znělé párové souhlásky
CLASS NPS   [ptť'kfsšHcč]      # neznělé párové souhlásky
[[ dě ]] → d' e
[[ b ]] (_|NPS|ZPS_) → p
[[ p ]] ZPS → b
```

- vstup pro MBROLu – 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 mnoho revizí (poslední 1996)
- speciální znak pro vyjádření každého **fónu**
- mezinárodně **standardní zápis** – jsou k dispozici tabulky a fonty
- *Unicode* – speciální IPA znaky v rozsahu U+0250–02AD

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*

	labiála		labio-dentála		dentála		alveolára		palatála		velára		glotála	
ploziva	p	b					t	d			k	g		
frikativa			f	v	θ	ð	s	z	ʃ	ʒ			h	
afrikáta									tʃ	dʒ				
nazála		m						n				ŋ		
aproximanta laterální retroflexní								l r						
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, redden, 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

ʒ (genre), visual, measure, decision, massage

h hat, who, ahead, perhaps

tʃ China, cheap, ritual, teaching, beach, punch

dʒ jump, pidgeon, 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**

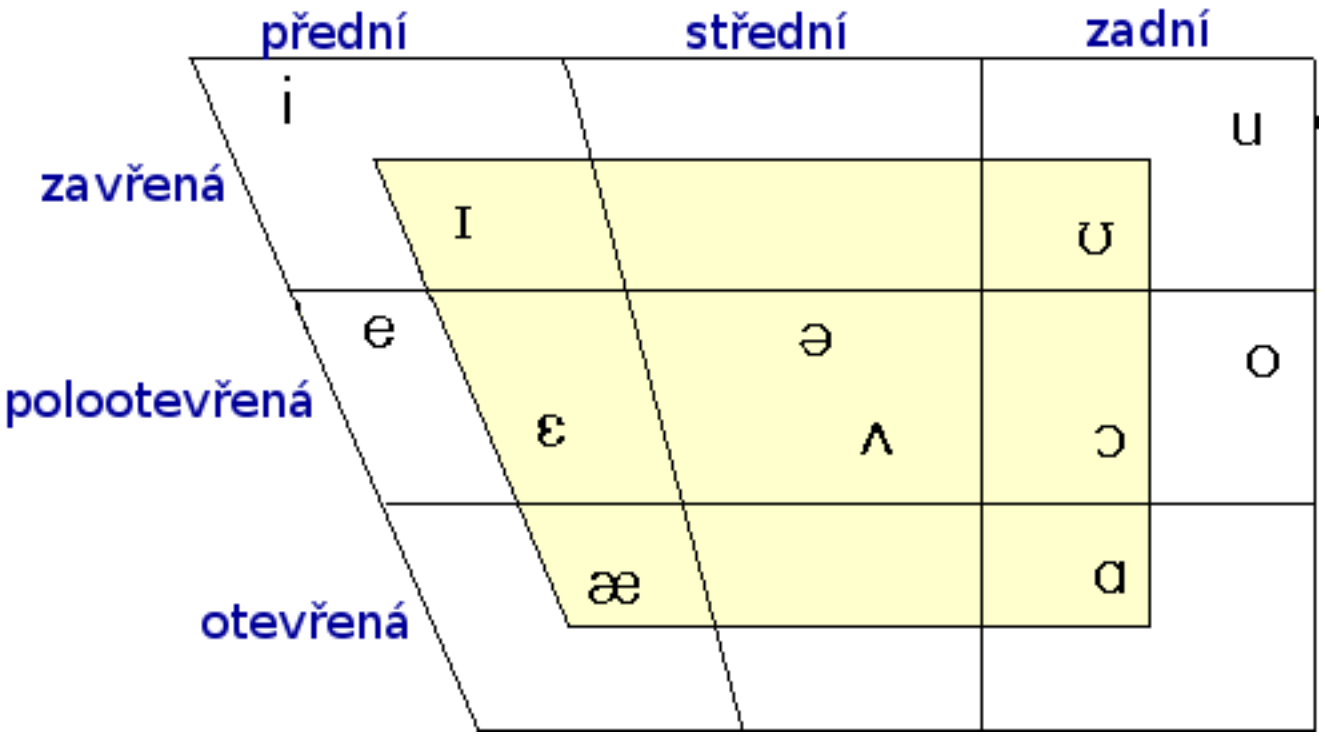

IPA – samohlásky ve slovech

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
u	food, boot, pool, through, who, sewer
ʊ	hood, book, pull, put, would
o	hole, boat, sew, know, so
ɔ	bought, law, wrong, stalk
ɑ	pot, "la", stocking, father, rob
ə	above, around, sofa, police
ʌ	bus, rush, under, other

IPA – dvojhlásky

v **americké angličtině**

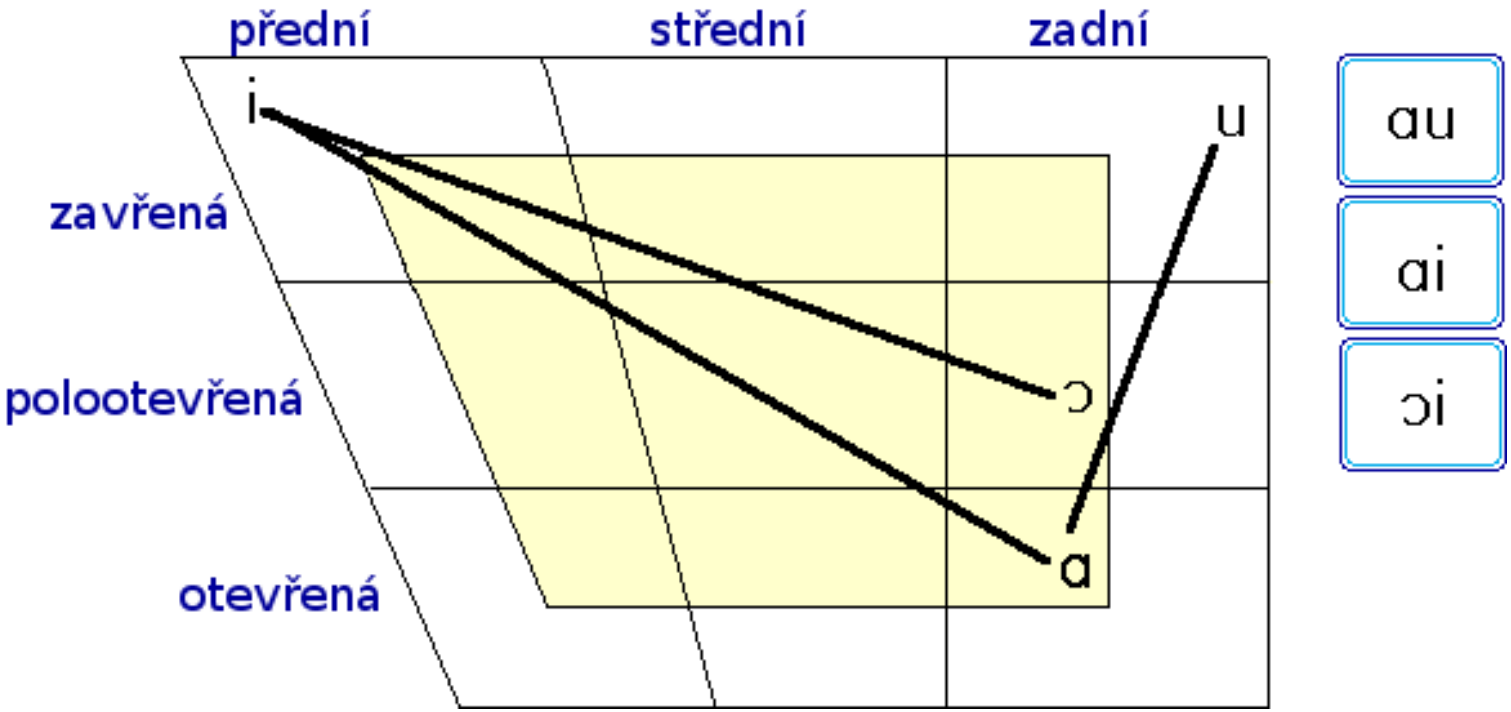

ai find, high, aisle, quiet, ride
au house, crown, around, flower, how
ɔi boy, enjoy, Freud, avoid, join

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

- české
  - **Epos** – z 90. let, Karlova univerzita a ČAV, nejlepší český open source
  - **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
- zahraniční
  - **Festival** – z Edinburghu, GPL, hodně jazyků, projekt Festival Czech
  - **MBROLA** – difónová syntéza MBR-PSOLA, řeší DSP část
    Mikuláš Piňos, DP 2000 – česká DB pro MBROLu, `text2phone` v Perlu
  - mnohé další – **HADIFIX**, **SVOX**, **Bell Labs**, **AT&T**, ...