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

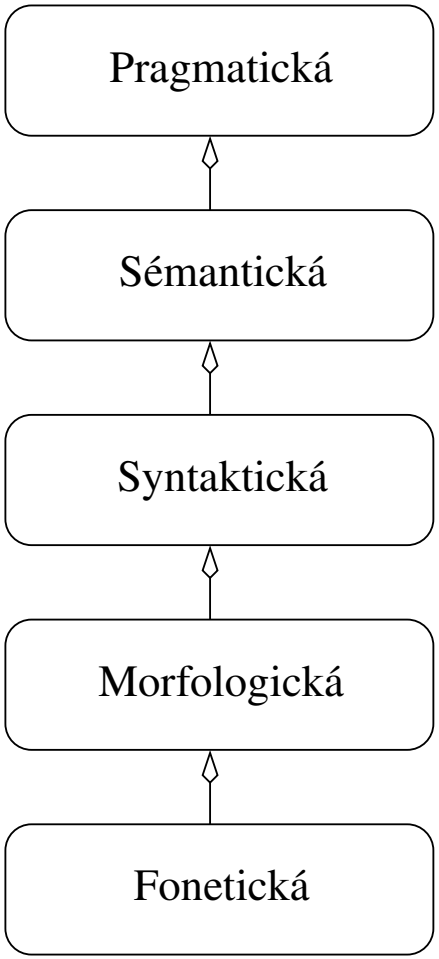

jazykové roviny:

- fonetická
- morfologická
- syntaktická
- sémantická
- pragmatická

- kontextová
- znalost základní ontologie
- jazykové metaznalosti

Roviny analýzy jazyka – příklad

rovina analýzy	**příklad**
pragmatická	$Jíst(I_2, Salát, TI_3) \wedge with(Salát, krab)$
sémantická	$Jíst(On, Salát, T_{min}) \wedge with(Salát, krab)$ $Jíst_{with}(On, Salát, krab, T_{min})$
syntaktická	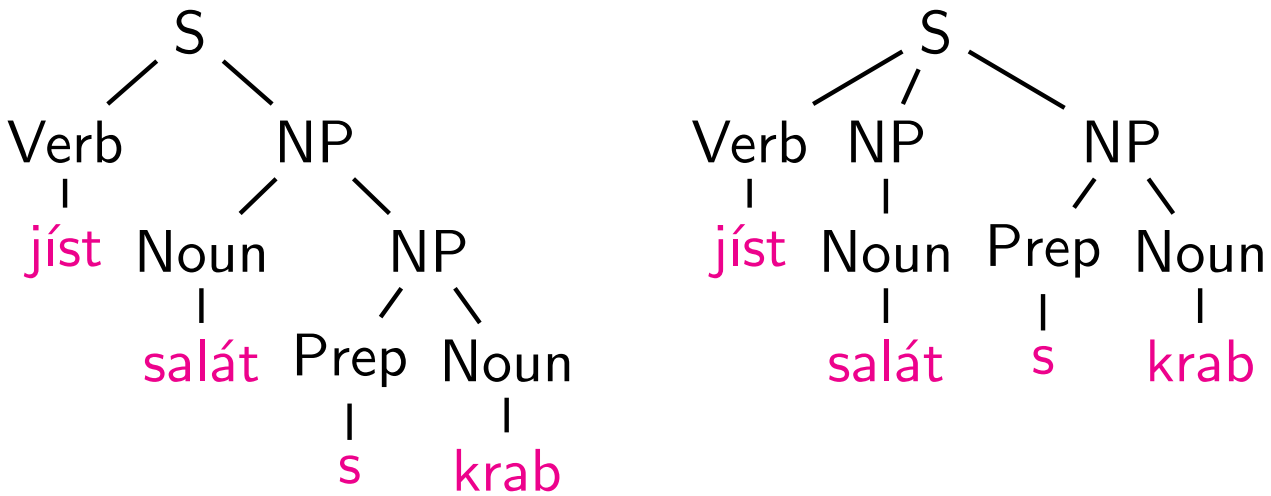
morfologická	jíst–Verb3MSP, salát–Noun4IS, s–Prep7, krab–Noun7MS
fonetická	[j e d l s a l a: t s k r a b e m]
povrchová	"Jedl salát s krabem."

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

  *k*osit/*n*osit 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-
  -ost-n-ými:

  pří – prefix (*blízko*)
  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

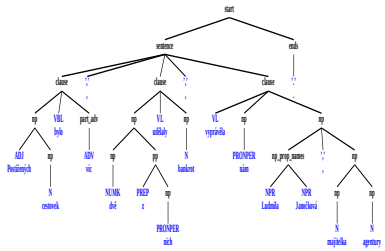

- sémantická – význam výrazů přirozeného jazyka a jejich kombinací
  hodně závisí na zvolené sémantické reprezentaci
  logická analýza věty – strukturní část sémantické analýzy
- pragmatická – zkoumá vztah mezi výrazy přirozeného jazyka a kontextem
  často se do ní řadí znalost komunikační situace, základní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

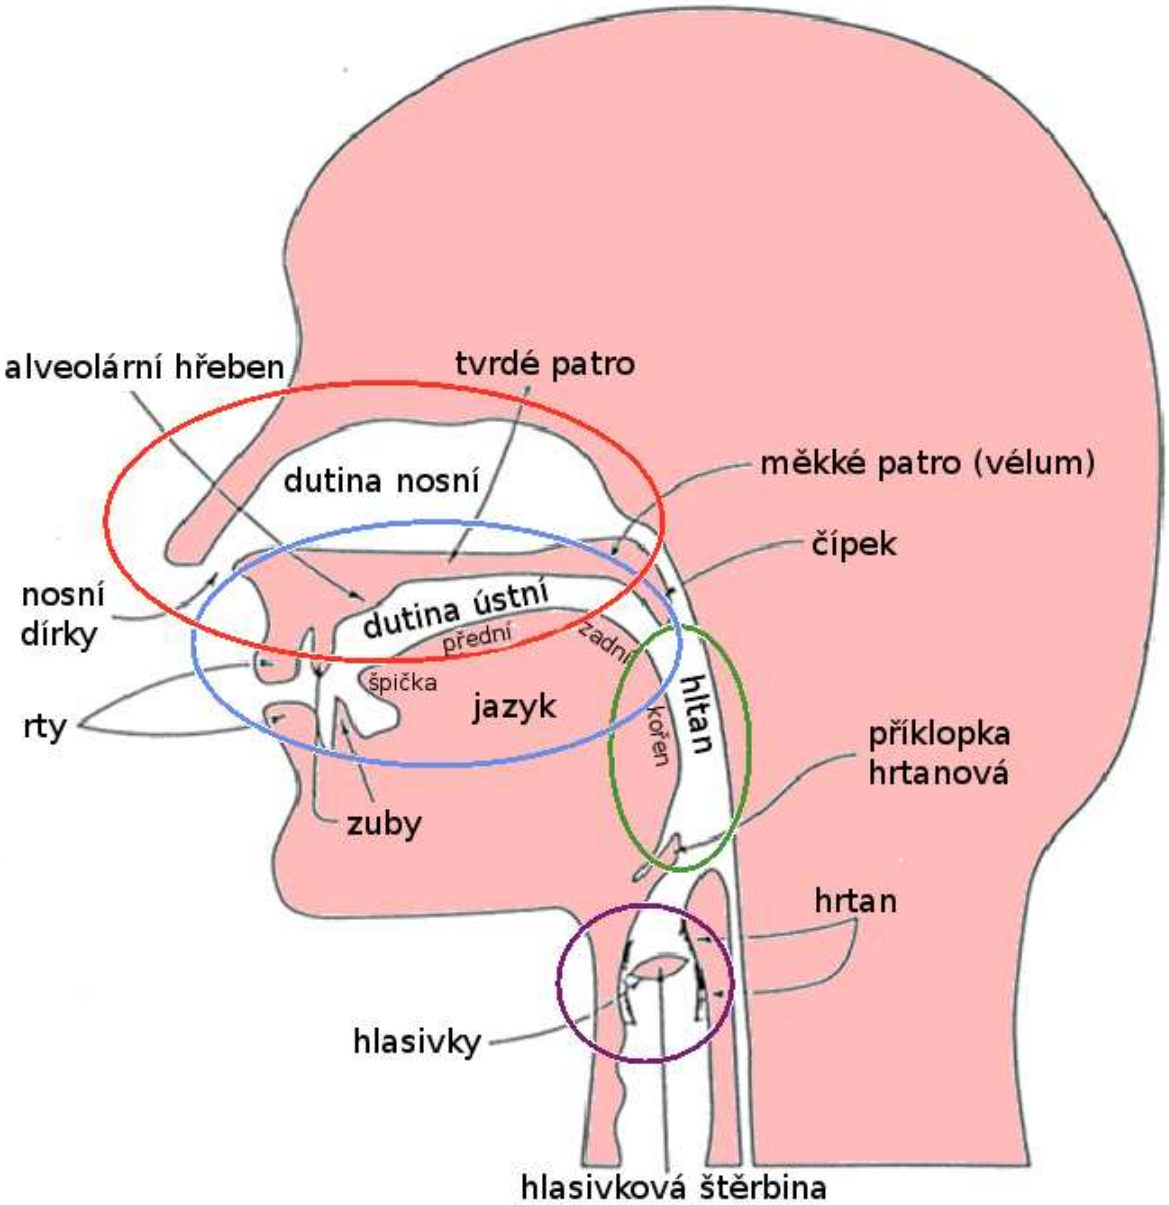

Členění řečového proudu

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 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
  - alofón 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 *Cicero*, [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*

Příklady dat pro českou transkripci pro MBROLA

- pravidla pro přepis do fonémů

```
CLASS SA    [aáeéěiíoóuúůyý]   # samohlásky
CLASS ZPS   [bdďgvzžhCČ]       # znělé párové souhlásky
CLASS NPS   [ptťkfsšHcč]       # neznělé párové souhlásky
[[ dě ]] → ď 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

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*

	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								l						
retroflexní								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

vokalický čtyřúhelník

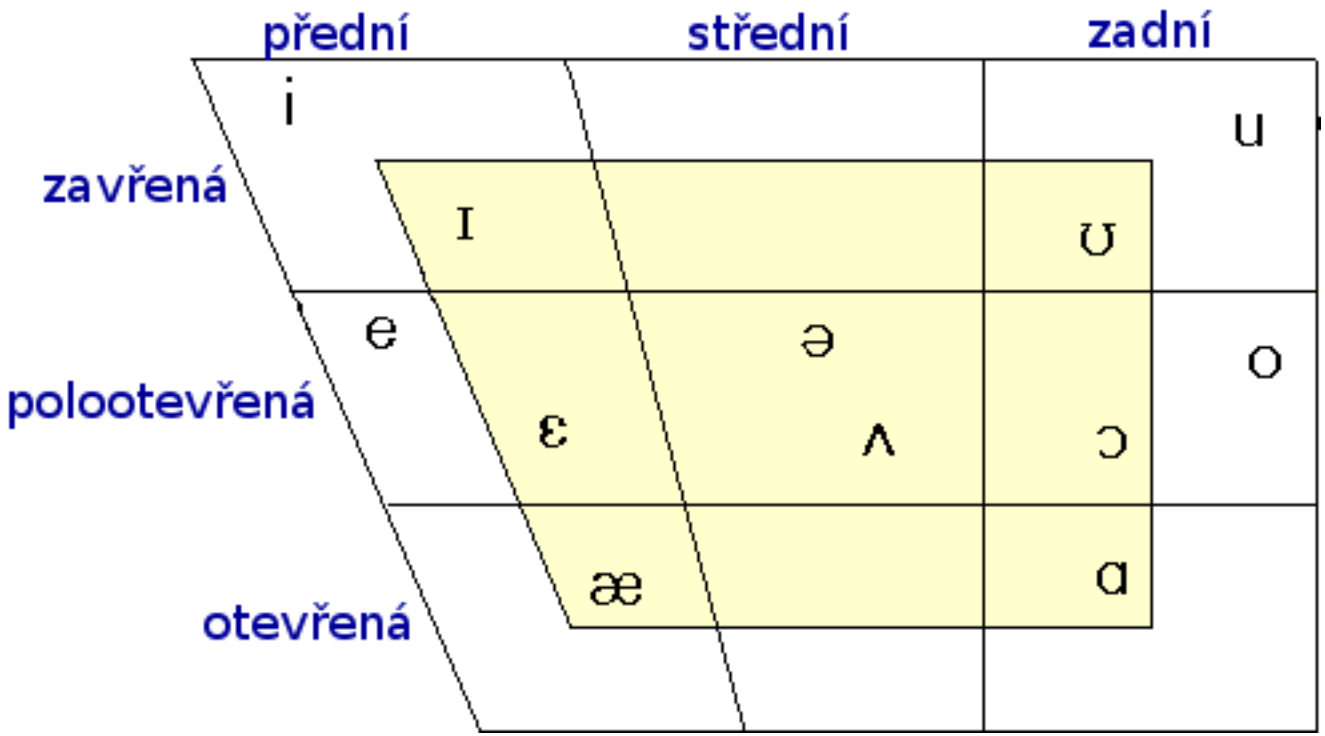

IPA – samohlásky ve slovech

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
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

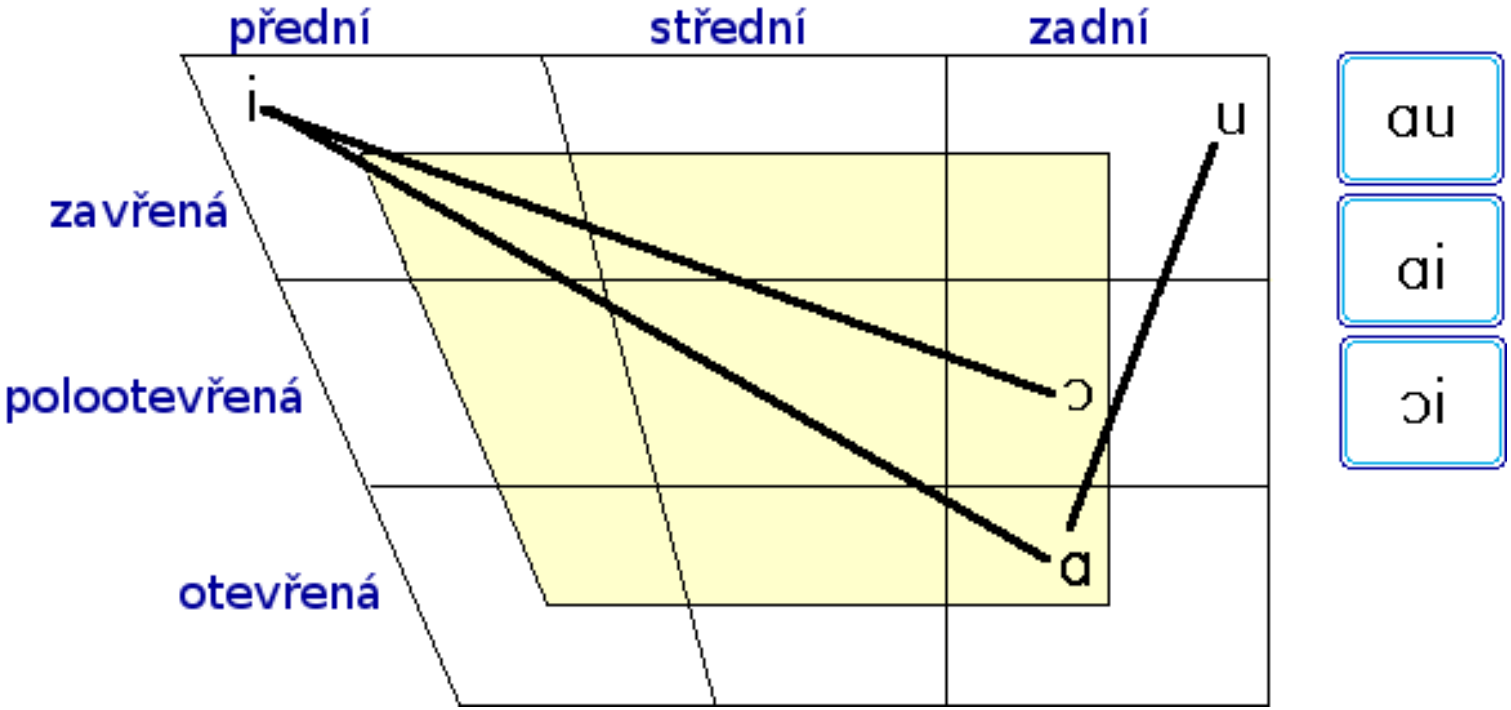

ai	find, high, aisle, quiet, ride
au	house, crown, around, flower, how
ɔi	boy, enjoy, Freud, avoid, join

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 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