

Úvod do počítačové lingvistiky

Aleš Horák

E-mail: hales@fi.muni.cz

http://nlp.fi.muni.cz/poc_lingv/

Obsah:

- Organizace předmětu IB030
- Počítačová lingvistika
- Situace na FI MU

Organizace předmětu IB030

Hodnocení předmětu:

- závěrečná písemka (max 80 bodů)
 - jeden řádný a dva opravné termíny
- průběžný úkol (max 20 bodů)
- navíc možnost 1 bodu za netriviální vylepšení slajdů
- hodnocení – součet bodů za písemku i úkol (max 100 bodů)
- rozdíly zk, k, z – různé limity

např.:

A	80 – 100
B	73 – 79
C	65 – 72
D	58 – 64
E	50 – 57
F	0 – 49

K	45 – 100
Z	40 – 100

Organizace předmětu IB030

Hodnocení předmětu:

- závěrečná písemka (max 80 bodů)
 - jeden řádný a dva opravné termíny
- průběžný úkol (max 20 bodů)
- navíc možnost 1 bodu za netriviální vylepšení slajdů
- hodnocení – součet bodů za písemku i úkol (max 100 bodů)
- rozdíly zk, k, z – různé limity

např.:

A	80 – 100
B	73 – 79
C	65 – 72
D	58 – 64
E	50 – 57
F	0 – 49

K	45 – 100
Z	40 – 100

Organizace předmětu IB030

Hodnocení předmětu:

- závěrečná písemka (max 80 bodů)
 - jeden řádný a dva opravné termíny
- průběžný úkol (max 20 bodů)
- navíc možnost 1 bodu za netriviální vylepšení slajdů
- hodnocení – součet bodů za písemku i úkol (max 100 bodů)
- rozdíly zk, k, z – různé limity

např.:

A	80 – 100
B	73 – 79
C	65 – 72
D	58 – 64
E	50 – 57
F	0 – 49

K	45 – 100
Z	40 – 100

Organizace předmětu IB030

Hodnocení předmětu:

- závěrečná písemka (max 80 bodů)
 - jeden řádný a dva opravné termíny
- průběžný úkol (max 20 bodů)
- navíc možnost 1 bodu za netriviální vylepšení slajdů
- hodnocení – součet bodů za písemku i úkol (max 100 bodů)
- rozdíly zk, k, z – různé limity

např.:

A	80 – 100
B	73 – 79
C	65 – 72
D	58 – 64
E	50 – 57
F	0 – 49

K	45 – 100
Z	40 – 100

Organizace předmětu IB030

Hodnocení předmětu:

- závěrečná písemka (max 80 bodů)
 - jeden řádný a dva opravné termíny
- průběžný úkol (max 20 bodů)
- navíc možnost 1 bodu za netriviální vylepšení slajdů
- hodnocení – součet bodů za písemku i úkol (max 100 bodů)
- rozdíly zk, k, z – různé limity

např.:

A	80 – 100
B	73 – 79
C	65 – 72
D	58 – 64
E	50 – 57
F	0 – 49

K	45 – 100
Z	40 – 100

Organizace předmětu IB030

Hodnocení předmětu:

- závěrečná písemka (max 80 bodů)
 - jeden řádný a dva opravné termíny
- průběžný úkol (max 20 bodů)
- navíc možnost 1 bodu za netriviální vylepšení slajdů
- hodnocení – součet bodů za písemku i úkol (max 100 bodů)
- rozdíly zk, k, z – různé limity

např.:

A	80 – 100
B	73 – 79
C	65 – 72
D	58 – 64
E	50 – 57
F	0 – 49

K	45 – 100
Z	40 – 100

Základní informace

- přednáška je nepovinná
- cvičení – občas doporučené malé úkoly
- jeden hodnocený úkol (viz další slajdy)
- web předmětu – http://nlp.fi.muni.cz/poc_lingv/
- slajdy – průběžně doplňovány na webu předmětu
- kontakt na přednášejícího – Aleš Horák <hales@fi.muni.cz>
(Subject: IB030 ...)

Základní informace

- přednáška je nepovinná
- cvičení – občas doporučené malé úkoly
- jeden hodnocený úkol (viz další slajdy)
- web předmětu – http://nlp.fi.muni.cz/poc_lingv/
- slajdy – průběžně doplňovány na webu předmětu
- kontakt na přednášejícího – Aleš Horák <hales@fi.muni.cz>
(Subject: IB030 ...)

Základní informace

- přednáška je nepovinná
- cvičení – občas doporučené malé úkoly
- jeden hodnocený úkol (viz další slajdy)
- web předmětu – http://nlp.fi.muni.cz/poc_lingv/
- slajdy – průběžně doplňovány na webu předmětu
- kontakt na přednášejícího – Aleš Horák <hales@fi.muni.cz>
(Subject: IB030 ...)

Základní informace

- přednáška je nepovinná
- cvičení – občas doporučené malé úkoly
- jeden hodnocený úkol (viz další slajdy)
- web předmětu – http://nlp.fi.muni.cz/poc_lingv/
- slajdy – průběžně doplňovány na webu předmětu
- kontakt na přednášejícího – Aleš Horák <hales@fi.muni.cz>
(Subject: IB030 ...)

Základní informace

- přednáška je nepovinná
- cvičení – občas doporučené malé úkoly
- jeden hodnocený úkol (viz další slajdy)
- web předmětu – http://nlp.fi.muni.cz/poc_lingv/
- slajdy – průběžně doplňovány na webu předmětu
- kontakt na přednášejícího – Aleš Horák <hales@fi.muni.cz>
(Subject: IB030 ...)

Základní informace

- přednáška je nepovinná
- cvičení – občas doporučené malé úkoly
- jeden hodnocený úkol (viz další slajdy)
- web předmětu – http://nlp.fi.muni.cz/poc_lingv/
- slajdy – průběžně doplňovány na webu předmětu
- kontakt na přednášejícího – Aleš Horák <hales@fi.muni.cz>
(Subject: IB030 ...)

Samostatný hodnocený úkol – programátorský

- dva **typy** – *programátorský* × *lingvistický*
- **programátorský úkol** – **upravit** některou z dostupných jazykových knihoven pro češtinu:
 - NLTK – Natural Language Toolkit <http://www.nltk.org>
 - C&C Tools <http://svn.ask.it.usyd.edu.au/trac/candc/wiki>
 - Field Linguist's Toolbox <http://www.sil.org/computing/toolbox/>
 - FreeLing <http://nlp.lsi.upc.edu/freeling/>
 - Stanford University Natural Language Software <http://nlp.stanford.edu/software/>
 - IBM LanguageWare Resource Workbench <http://alphaworks.ibm.com/tech/lrw>
- k **odevzdání** je zapotřebí:
 - naprogramovaný vybraný algoritmus na češtině
 - dokumentace programu s ukázkami a návodem na instalaci/spuštění na serveru aurora.fi.muni.cz a *vyhodnocím úspěšnosti* algoritmu na ne zcela triviálních českých datech
 - vše odeslat v komprimovaném archivu e-mailem přednášejícímu (**Subject: IB030 – odevzdani ukolu**) do 17. května 2015
- **hodnocení** bude od 0 do 20 bodů podle:
 - složitosti vybraného algoritmus
 - kvality zpracování algoritmu i dokumentace

Samostatný hodnocený úkol – programátorský

- dva **typy** – *programátorský* × *lingvistický*
- **programátorský úkol** – **upravit** některou z dostupných jazykových knihoven pro **češtinu**:
 - **NLTK – Natural Language Toolkit** <http://www.nltk.org>
 - **C&C Tools** <http://svn.ask.it.usyd.edu.au/trac/candc/wiki>
 - **Field Linguist's Toolbox** <http://www.sil.org/computing/toolbox/>
 - **FreeLing** <http://nlp.lsi.upc.edu/freeling/>
 - **Stanford University Natural Language Software**
<http://nlp.stanford.edu/software/>
 - **IBM LanguageWare Resource Workbench**
<http://alphaworks.ibm.com/tech/lrw>
- k **odevzdání** je zapotřebí:
 - naprogramovaný vybraný algoritmus na češtině
 - dokumentace programu s ukázkami a návodem na instalaci/spuštění na serveru aurora.fi.muni.cz a *vyhodnocím úspěšnosti* algoritmu na ne zcela triviálních českých datech
 - vše odeslat v komprimovaném archivu e-mailem přednášejícímu (**Subject: IB030 – odevzdání ukolu**) do **17. května 2015**
- **hodnocení** bude od 0 do 20 bodů podle:
 - složitosti vybraného algoritmus
 - kvality zpracování algoritmu i dokumentace

Samostatný hodnocený úkol – programátorský

- dva **typy** – *programátorský* × *lingvistický*
- **programátorský úkol** – **upravit** některou z dostupných jazykových knihoven pro **češtinu**:
 - **NLTK – Natural Language Toolkit** <http://www.nltk.org>
 - **C&C Tools** <http://svn.ask.it.usyd.edu.au/trac/candc/wiki>
 - **Field Linguist's Toolbox** <http://www.sil.org/computing/toolbox/>
 - **FreeLing** <http://nlp.lsi.upc.edu/freeling/>
 - **Stanford University Natural Language Software**
<http://nlp.stanford.edu/software/>
 - **IBM LanguageWare Resource Workbench**
<http://alphaworks.ibm.com/tech/lrw>
- k **odevzdání** je zapotřebí:
 - naprogramovaný vybraný algoritmus na češtině
 - dokumentace programu s ukázkami a návodem na instalaci/spuštění na serveru aurora.fi.muni.cz a *vyhodnocím úspěšnosti* algoritmu na ne zcela triviálních českých datech
 - vše odeslat v komprimovaném archivu e-mailem přednášejícímu (**Subject: IB030 – odevzdani ukolu**) do **17. května 2015**
- **hodnocení** bude od 0 do 20 bodů podle:
 - složitosti vybraného algoritmus
 - kvality zpracování algoritmu i dokumentace

Samostatný hodnocený úkol – programátorský

- dva **typy** – *programátorský* × *lingvistický*
- **programátorský úkol** – **upravit** některou z dostupných jazykových knihoven pro **češtinu**:
 - **NLTK – Natural Language Toolkit** <http://www.nltk.org>
 - **C&C Tools** <http://svn.ask.it.usyd.edu.au/trac/candc/wiki>
 - **Field Linguist's Toolbox** <http://www.sil.org/computing/toolbox/>
 - **FreeLing** <http://nlp.lsi.upc.edu/freeling/>
 - **Stanford University Natural Language Software**
<http://nlp.stanford.edu/software/>
 - **IBM LanguageWare Resource Workbench**
<http://alphaworks.ibm.com/tech/lrw>
- k **odevzdání** je zapotřebí:
 - naprogramovaný vybraný algoritmus na češtině
 - dokumentace programu s ukázkami a návodem na instalaci/spuštění na serveru aurora.fi.muni.cz a *vyhodnocím úspěšnosti* algoritmu na ne zcela triviálních českých datech
 - vše odeslat v komprimovaném archivu e-mailem přednášejícímu (**Subject: IB030 – odevzdani ukolu**) do **17. května 2015**
- **hodnocení** bude od 0 do 20 bodů podle:
 - složitosti vybraného algoritmus
 - kvality zpracování algoritmu i dokumentace

Samostatný hodnocený úkol – lingvistický

- **lingvistický úkol** – **značkování** významu frází a slov.
např. v roce 2013:

- čeština, 300 otázek a odpovědí podle textů z Wikipedie

Jak se nazývá strom, jehož zrna jsou využívána k výrobě čokolády?

Theobroma cacao

Čokoláda se vyrábí z kvašených, pražených a mletých zrněk tropického kakaového stromu *Theobroma cacao*.

<http://cs.wikipedia.org/wiki/%C4%8Cokol%C3%A1da>

- k **odevzdání** je zapotřebí:
 - oznámit včas výběr úkolu a získat svoji sadu slov
 - odeslat výsledek v aplikaci nebo v ZIPu e-mailem přednášejícímu
(**Subject: IB030 – odevzdani ukolu**) do **3. května 2015**
- **hodnocení** bude od 0 do 20 bodů podle:
 - kvality zpracování značkování všech vět

Samostatný hodnocený úkol – lingvistický

- **lingvistický úkol** – **značkování** významu frází a slov.
např. v roce 2013:

- čeština, 300 otázek a odpovědí podle textů z Wikipedie

Jak se nazývá strom, jehož zrna jsou využívána k výrobě čokolády?

Theobroma cacao

Čokoláda se vyrábí z kvašených, pražených a mletých zrněk tropického kakaového stromu *Theobroma cacao*.

<http://cs.wikipedia.org/wiki/%C4%8Cokol%C3%A1da>

- k **odevzdání** je zapotřebí:
 - oznámit včas výběr úkolu a získat svoji sadu slov
 - odeslat výsledek v aplikaci nebo v ZIPu e-mailem přednášejícímu
(**Subject: IB030 – odevzdani ukolu**) do **3. května 2015**
- **hodnocení** bude od 0 do 20 bodů podle:
 - kvality zpracování značkování všech vět

Samostatný hodnocený úkol – lingvistický

- **lingvistický úkol** – **značkování** významu frází a slov.
např. v roce 2013:

- čeština, 300 otázek a odpovědí podle textů z Wikipedie

Jak se nazývá strom, jehož zrna jsou využívána k výrobě čokolády?

Theobroma cacao

Čokoláda se vyrábí z kvašených, pražených a mletých zrněk tropického kakaového stromu *Theobroma cacao*.

<http://cs.wikipedia.org/wiki/%C4%8Cokol%C3%A1da>

- k **odevzdání** je zapotřebí:
 - oznámit včas výběr úkolu a získat svoji sadu slov
 - odeslat výsledek v aplikaci nebo v ZIPu e-mailem přednášejícímu
(**Subject: IB030 – odevzdani ukolu**) do **3. května 2015**
- **hodnocení** bude od 0 do 20 bodů podle:
 - kvality zpracování značkování všech vět

Literatura



Pala, Karel: [Počítačové zpracování přirozeného jazyka](#), Brno FI MU, 2000. 190 s.

[The Oxford handbook of computational linguistics](#), ed. by Ruslan Mitkov. Oxford University Press, 2003, 784 s.

Allen, James: [Natural language understanding](#), Redwood : Benjamin/Cummings Publishing, 1995, 654 s.

Chomsky, Noam: [Syntaktické struktury](#), Praha : Academia, 1966. 209 s.

Materna, Pavel - Štěpán, Jan: [Filozofická logika: nová cesta?](#), Olomouc (Univerzita Palackého), 2000. 127 s.

[slajdy na webu předmětu](#)

Literatura



Pala, Karel: [Počítačové zpracování přirozeného jazyka](#), Brno FI MU, 2000. 190 s.



[The Oxford handbook of computational linguistics](#), ed. by Ruslan Mitkov. Oxford University Press, 2003, 784 s.

Allen, James: [Natural language understanding](#), Redwood : Benjamin/Cummings Publishing, 1995, 654 s.

Chomsky, Noam: [Syntaktické struktury](#), Praha : Academia, 1966. 209 s.


Materna, Pavel - Štěpán, Jan: [Filozofická logika: nová cesta?](#), Olomouc (Univerzita Palackého), 2000. 127 s.

[slajdy](#) na webu předmětu

Literatura



Pala, Karel: [Počítačové zpracování přirozeného jazyka](#), Brno FI MU, 2000. 190 s.



[The Oxford handbook of computational linguistics](#), ed. by Ruslan Mitkov. Oxford University Press, 2003, 784 s.

Allen, James: [Natural language understanding](#), Redwood : Benjamin/Cummings Publishing, 1995, 654 s.

Chomsky, Noam: [Syntaktické struktury](#), Praha : Academia, 1966. 209 s.

Materna, Pavel - Štěpán, Jan: [Filozofická logika: nová cesta?](#), Olomouc (Univerzita Palackého), 2000. 127 s.


[slajdy](#) na webu předmětu



Literatura



Pala, Karel: [Počítačové zpracování přirozeného jazyka](#), Brno FI MU, 2000. 190 s.



[The Oxford handbook of computational linguistics](#), ed. by Ruslan Mitkov. Oxford University Press, 2003, 784 s.

Allen, James: [Natural language understanding](#), Redwood : Benjamin/Cummings Publishing, 1995, 654 s.

Chomsky, Noam: [Syntaktické struktury](#), Praha : Academia, 1966. 209 s.

Materna, Pavel - Štěpán, Jan: [Filozofická logika: nová cesta?](#), Olomouc (Univerzita Palackého), 2000. 127 s.


[slajdy na webu předmětu](#)



Literatura



Pala, Karel: [Počítačové zpracování přirozeného jazyka](#), Brno FI MU, 2000. 190 s.



[The Oxford handbook of computational linguistics](#), ed. by Ruslan Mitkov. Oxford University Press, 2003, 784 s.

Allen, James: [Natural language understanding](#), Redwood : Benjamin/Cummings Publishing, 1995, 654 s.

Chomsky, Noam: [Syntaktické struktury](#), Praha : Academia, 1966. 209 s.

Materna, Pavel - Štěpán, Jan: [Filozofická logika: nová cesta?](#), Olomouc (Univerzita Palackého), 2000. 127 s.




[slajdy na webu předmětu](#)

Literatura



Pala, Karel: [Počítačové zpracování přirozeného jazyka](#), Brno FI MU, 2000. 190 s.



[The Oxford handbook of computational linguistics](#), ed. by Ruslan Mitkov. Oxford University Press, 2003, 784 s.

Allen, James: [Natural language understanding](#), Redwood : Benjamin/Cummings Publishing, 1995, 654 s.

Chomsky, Noam: [Syntaktické struktury](#), Praha : Academia, 1966. 209 s.

Materna, Pavel - Štěpán, Jan: [Filozofická logika: nová cesta?](#), Olomouc (Univerzita Palackého), 2000. 127 s.

[slajdy](#) na webu předmětu



Náplň předmětu

- počítačové zpracování přirozeného jazyka (*Natural Language Processing, NLP*)
- roviny jazyka
- reprezentace morfologických a syntaktických struktur
- analýza a syntéza: morfologická, syntaktická, sémantická
- formy reprezentace znalostí o lexikálních jednotkách
- porozumění jazyku: reprezentace významu věty, inference a reprezentace znalostí

Náplň předmětu

- počítačové zpracování přirozeného jazyka (*Natural Language Processing, NLP*)
- roviny jazyka
 - reprezentace morfologických a syntaktických struktur
 - analýza a syntéza: morfologická, syntaktická, sémantická
 - formy reprezentace znalostí o lexikálních jednotkách
 - porozumění jazyku: reprezentace významu věty, inference a reprezentace znalostí

Náplň předmětu

- počítačové zpracování přirozeného jazyka (*Natural Language Processing, NLP*)
- roviny jazyka
- reprezentace morfologických a syntaktických struktur
- analýza a syntéza: morfologická, syntaktická, sémantická
- formy reprezentace znalostí o lexikálních jednotkách
- porozumění jazyku: reprezentace významu věty, inference a reprezentace znalostí

Náplň předmětu

- počítačové zpracování přirozeného jazyka (*Natural Language Processing, NLP*)
- roviny jazyka
- reprezentace morfologických a syntaktických struktur
- analýza a syntéza: morfologická, syntaktická, sémantická
- formy reprezentace znalostí o lexikálních jednotkách
- porozumění jazyku: reprezentace významu věty, inference a reprezentace znalostí

Náplň předmětu

- počítačové zpracování přirozeného jazyka (*Natural Language Processing, NLP*)
- roviny jazyka
- reprezentace morfologických a syntaktických struktur
- analýza a syntéza: morfologická, syntaktická, sémantická
- formy reprezentace znalostí o lexikálních jednotkách
- porozumění jazyku: reprezentace významu věty, inference a reprezentace znalostí

Náplň předmětu

- počítačové zpracování přirozeného jazyka (*Natural Language Processing, NLP*)
- roviny jazyka
- reprezentace morfologických a syntaktických struktur
- analýza a syntéza: morfologická, syntaktická, sémantická
- formy reprezentace znalostí o lexikálních jednotkách
- porozumění jazyku: reprezentace významu věty, inference a reprezentace znalostí

Obsah

- 1 Organizace předmětu IB030
 - Základní informace
 - Literatura
 - Náplň předmětu
- 2 **Počítačová lingvistika**
 - **Historie počítačové lingvistiky**
 - **Cíle počítačové lingvistiky**
- 3 Situace na FI MU
 - Přednášky se vztahem k NLP
 - NLP Centre – Centrum ZPJ
 - NLP projekty a SW

Co je “počítačová lingvistika”

Lingvistika:

- **jazykověda** (*lingua* = lat. *jazyk*)
- věda o jazycích, jejich třídění, stavbě, zvukové i psané podobě
- zkoumá strukturu jazyka – slovtvorba, kombinace slov do vět, význam věty, ...

Počítačová lingvistika:

- od 60. let, *Computational linguistics*, často **NLP** (*Natural Language Processing*)
- spojení **umělé inteligence** (informatiky) a **lingvistiky** – jako jedna z **kognitivních věd**
- zkoumá problémy **analýzy** či **generování** textů nebo mluveného slova, které vyžadují určitou (ne absolutní) míru porozumění přirozenému jazyku strojem.
- tvoří **jazykové modely** – pojmy **algoritmus**, **datová struktura**, **(formální) gramatika**, ...

Co je “počítačová lingvistika”

Lingvistika:

- **jazykověda** (*lingua* = lat. *jazyk*)
- věda o jazycích, jejich třídění, stavbě, zvukové i psané podobě
- zkoumá strukturu jazyka – slovtvorba, kombinace slov do vět, význam věty, ...

Počítačová lingvistika:

- od 60. let, *Computational linguistics*, často **NLP** (*Natural Language Processing*)
- spojení **umělé inteligence** (informatiky) a **lingvistiky** – jako jedna z **kognitivních věd**
- zkoumá problémy **analýzy** či **generování** textů nebo mluveného slova, které vyžadují určitou (ne absolutní) míru porozumění přirozenému jazyku strojem.
- tvoří **jazykové modely** – pojmy **algoritmus**, **datová struktura**, **(formální) gramatika**, ...

Co je “počítačová lingvistika”

Lingvistika:

- **jazykověda** (*lingua* = lat. *jazyk*)
- věda o jazycích, jejich třídění, stavbě, zvukové i psané podobě
- zkoumá strukturu jazyka – slovtvorba, kombinace slov do vět, význam věty, ...

Počítačová lingvistika:

- od 60. let, *Computational linguistics*, často **NLP** (*Natural Language Processing*)
- spojení **umělé inteligence** (informatiky) a **lingvistiky** – jako jedna z **kognitivních věd**
- zkoumá problémy **analýzy** či **generování** textů nebo mluveného slova, které vyžadují určitou (ne absolutní) míru porozumění přirozenému jazyku strojem.
- tvoří **jazykové modely** – pojmy **algoritmus**, **datová struktura**, **(formální) gramatika**, ...

Co je “počítačová lingvistika”

Lingvistika:

- **jazykověda** (*lingua* = lat. *jazyk*)
- věda o jazycích, jejich třídění, stavbě, zvukové i psané podobě
- zkoumá strukturu jazyka – slovtvorba, kombinace slov do vět, význam věty, ...

Počítačová lingvistika:

- od 60. let, *Computational linguistics*, často **NLP** (*Natural Language Processing*)
- spojení **umělé inteligence** (informatiky) a **lingvistiky** – jako jedna z **kognitivních věd**
- zkoumá problémy **analýzy** či **generování** textů nebo mluveného slova, které vyžadují určitou (ne absolutní) míru porozumění přirozenému jazyku strojem.
- tvoří **jazykové modely** – pojmy **algoritmus**, **datová struktura**, **(formální) gramatika**, ...

Co je “počítačová lingvistika”

Lingvistika:

- **jazykověda** (*lingua* = lat. *jazyk*)
- věda o jazycích, jejich třídění, stavbě, zvukové i psané podobě
- zkoumá strukturu jazyka – slovtvorba, kombinace slov do vět, význam věty, ...

Počítačová lingvistika:

- od 60. let, *Computational linguistics*, často **NLP** (*Natural Language Processing*)
- spojení **umělé inteligence** (informatiky) a **lingvistiky** – jako jedna z **kognitivních věd**
- zkoumá problémy **analýzy** či **generování** textů nebo mluveného slova, které vyžadují určitou (ne absolutní) míru porozumění přirozenému jazyku strojem.
- tvoří **jazykové modely** – pojmy **algoritmus**, **datová struktura**, **(formální) gramatika**, ...

Co je “počítačová lingvistika”

Lingvistika:

- **jazykověda** (*lingua* = lat. *jazyk*)
- věda o jazycích, jejich třídění, stavbě, zvukové i psané podobě
- zkoumá strukturu jazyka – slovtvorba, kombinace slov do vět, význam věty, ...

Počítačová lingvistika:

- od 60. let, *Computational linguistics*, často **NLP** (*Natural Language Processing*)
- spojení **umělé inteligence** (informatiky) a **lingvistiky** – jako jedna z **kognitivních věd**
- zkoumá problémy **analýzy** či **generování** textů nebo mluveného slova, které vyžadují určitou (ne absolutní) míru porozumění přirozenému jazyku strojem.
- tvoří **jazykové modely** – pojmy **algoritmus**, **datová struktura**, **(formální) gramatika**, ...

Co je “počítačová lingvistika”

Lingvistika:


- **jazykověda** (*lingua* = lat. *jazyk*)
- věda o jazycích, jejich třídění, stavbě, zvukové i psané podobě
- zkoumá strukturu jazyka – slovtvorba, kombinace slov do vět, význam věty, ...

Počítačová lingvistika:

- od 60. let, *Computational linguistics*, často **NLP** (*Natural Language Processing*)
- spojení **umělé inteligence** (informatiky) a **lingvistiky** – jako jedna z **kognitivních věd**
- zkoumá problémy **analýzy** či **generování** textů nebo mluveného slova, které vyžadují určitou (ne absolutní) míru porozumění přirozenému jazyku strojem.
- tvoří **jazykové modely** – pojmy **algoritmus**, **datová struktura**, **(formální) gramatika**, ...


Turingův test

- z roku 1950, založen na tzv. **imitační hře**
- úkol – **program komunikující jako člověk**
- zahrnuje:
 - zpracování přirozeného jazyka (NLP)
 - reprezentaci znalostí (KRepresentation)
 - vyvozování znalostí (KReasoning)
 - strojové učení
 - (počítačové vidění)
 - (robotiku)
- od 1991 – **Loebnerova cena** (*Loebner Prize*) → každý rok \$4.000 za “nejlidštější” program, nabízí \$100.000 a zlatá medaile za složení celého Turingova testu



Turingův test

- z roku 1950, založen na tzv. **imitační hře**
- úkol – **program komunikující jako člověk**
- zahrnuje:
 - zpracování přirozeného jazyka (NLP)
 - reprezentaci znalostí (KRepresentation)
 - vyvozování znalostí (KReasoning)
 - strojové učení
 - (počítačové vidění)
 - (robotiku)
- od 1991 – **Loebnerova cena** (*Loebner Prize*) → každý rok \$4.000 za “nejlidštější” program, nabízí \$100.000 a zlatá medaile za složení celého Turingova testu




Turingův test

- z roku 1950, založen na tzv. **imitační hře**
- úkol – **program komunikující jako člověk**
- zahrnuje:
 - zpracování přirozeného jazyka (NLP)
 - reprezentaci znalostí (KRepresentation)
 - vyvozování znalostí (KReasoning)
 - strojové učení
 - (počítačové vidění)
 - (robotiku)
- od 1991 – **Loebnerova cena** (*Loebner Prize*) → každý rok \$4.000 za “nejlidštější” program, nabízí \$100.000 a zlatá medaile za složení celého Turingova testu



Turingův test

- z roku 1950, založen na tzv. **imitační hře**
- úkol – **program komunikující jako člověk**
- zahrnuje:
 - zpracování přirozeného jazyka (NLP)
 - reprezentaci znalostí (KRepresentation)
 - vyvozování znalostí (KReasoning)
 - strojové učení
 - (počítačové vidění)
 - (robotiku)
- od 1991 – **Loebnerova cena** (*Loebner Prize*) → každý rok \$4.000 za “nejlidštější” program, nabízí \$100.000 a zlatá medaile za složení celého Turingova testu



Eliza, Parry, ...

- **Eliza** – Joseph Weizenbaum, MIT, 1964–66
- program napodobující chování psychoterapeuta:

young woman: *Men are all alike.*
eliza: *In what way?*
young woman: *They're always bugging us about something.*
eliza: *Can you think of a specific example?*
young woman: *Well, my boyfriend made me come here.*
eliza: *Your boyfriend made you come here?*
young woman: *He says I'm depressed much of the time.*
eliza: *I am sorry to hear you are depressed.*
young woman: *It's true. I'm unhappy.*

- **Parry** (Kenneth Colby, 70. léta), protějšek Elizy – počítačová simulace pacienta postiženého paranoiou
- oba využívají spíš “**triky**” než analýzu
- praktický význam – tzv. **expertní systémy**

Eliza, Parry, ...

- **Eliza** – Joseph Weizenbaum, MIT, 1964–66
- program napodobující chování psychoterapeuta:

young woman: *Men are all alike.*
eliza: *In what way?*
young woman: *They're always bugging us about something.*
eliza: *Can you think of a specific example?*
young woman: *Well, my boyfriend made me come here.*
eliza: *Your boyfriend made you come here?*
young woman: *He says I'm depressed much of the time.*
eliza: *I am sorry to hear you are depressed.*
young woman: *It's true. I'm unhappy.*

- **Parry** (Kenneth Colby, 70. léta), protějšek Elizy – počítačová simulace pacienta postiženého paranoiou
- oba využívají spíš “**triky**” než analýzu
- praktický význam – tzv. **expertní systémy**

Eliza, Parry, ...

- **Eliza** – Joseph Weizenbaum, MIT, 1964–66
- program napodobující chování psychoterapeuta:

young woman: *Men are all alike.*
eliza: *In what way?*
young woman: *They're always bugging us about something.*
eliza: *Can you think of a specific example?*
young woman: *Well, my boyfriend made me come here.*
eliza: *Your boyfriend made you come here?*
young woman: *He says I'm depressed much of the time.*
eliza: *I am sorry to hear you are depressed.*
young woman: *It's true. I'm unhappy.*

- **Parry** (Kenneth Colby, 70. léta), protějšek Elizy – počítačová simulace pacienta postiženého paranoiou
- oba využívají spíš “**triky**” než analýzu
- praktický význam – tzv. **expertní systémy**

Eliza, Parry, ...

- **Eliza** – Joseph Weizenbaum, MIT, 1964–66
- program napodobující chování psychoterapeuta:

young woman: *Men are all alike.*
eliza: *In what way?*
young woman: *They're always bugging us about something.*
eliza: *Can you think of a specific example?*
young woman: *Well, my boyfriend made me come here.*
eliza: *Your boyfriend made you come here?*
young woman: *He says I'm depressed much of the time.*
eliza: *I am sorry to hear you are depressed.*
young woman: *It's true. I'm unhappy.*

- **Parry** (Kenneth Colby, 70. léta), protějšek Elizy – počítačová simulace pacienta postiženého paranoiou
- oba využívají spíš “**triky**” než analýzu
- praktický význam – tzv. **expertní systémy**

Eliza, Parry, ...

- **Eliza** – Joseph Weizenbaum, MIT, 1964–66
- program napodobující chování psychoterapeuta:

young woman: *Men are all alike.*
eliza: *In what way?*
young woman: *They're always bugging us about something.*
eliza: *Can you think of a specific example?*
young woman: *Well, my boyfriend made me come here.*
eliza: *Your boyfriend made you come here?*
young woman: *He says I'm depressed much of the time.*
eliza: *I am sorry to hear you are depressed.*
young woman: *It's true. I'm unhappy.*

- **Parry** (Kenneth Colby, 70. léta), protějšek Elizy – počítačová simulace pacienta postiženého paranoiou
- oba využívají spíš “**triky**” než analýzu
- praktický význam – tzv. **expertní systémy**

IBM Watson – DeepQA

- stroj označovaný jako **Watson – DeepQA** vyvinutý za účelem porazit lidské šampiony ve hře **Jeopardy (Riskuj)**
navazuje tím na stroj **DeepBlue**, který v roce 1997 porazil Kasparova v šachu
- po 5 letech vývoje se to Watsonovi podařilo 16.února 2011
- princip:
 - vytvoření databáze tvrzení z internetových dat
 - analýza částí otázky, členění otázek podle typu
 - vysoce **paralelní hledání odpovědi** s určením **míry jistoty**
 - vyladěný algoritmus pro kombinaci stovek výsledků do výsledného rozhodovacího skóre
 - viz [Jak a proč Watson vyhrál Jeopardy!](#)
- **nejedná se o umělou inteligenci** podle Turingova testu
- praktický význam – **inteligentní zpracování obrovského množství textů pro hledání odpovědi**

IBM Watson – DeepQA

- stroj označovaný jako **Watson – DeepQA** vyvinutý za účelem porazit lidské šampiony ve hře **Jeopardy (Riskuj)**
navazuje tím na stroj **DeepBlue**, který v roce 1997 porazil Kasparova v šachu
- po 5 letech vývoje se to Watsonovi podařilo 16.února 2011
- princip:
 - vytvoření databáze tvrzení z internetových dat
 - analýza částí otázky, členění otázek podle typu
 - vysoce paralelní hledání odpovědi s určením míry jistoty
 - vyladěný algoritmus pro kombinaci stovek výsledků do výsledného rozhodovacího skóre
 - viz [Jak a proč Watson vyhrál Jeopardy!](#)
- nejedná se o umělou inteligenci podle Turingova testu
- praktický význam – **inteligentní** zpracování obrovského množství textů pro **hledání odpovědi**

IBM Watson – DeepQA

- stroj označovaný jako **Watson – DeepQA** vyvinutý za účelem porazit lidské šampiony ve hře **Jeopardy (Riskuj)**
navazuje tím na stroj **DeepBlue**, který v roce 1997 porazil Kasparova v šachu
- po 5 letech vývoje se to Watsonovi podařilo 16.února 2011
- princip:
 - vytvoření **databáze tvrzení** z internetových dat
 - analýza částí otázky, členění otázek podle **typu**
 - vysoce **paralelní hledání** odpovědi s určením **míry jistoty**
 - vyladěný algoritmus pro **kombinaci** stovek výsledků do výsledného rozhodovacího skóre
 - viz [Jak a proč Watson vyhrál Jeopardy!](#)
- **nejedná se o umělou inteligenci** podle Turingova testu
- praktický význam – **inteligentní** zpracování obrovského množství textů pro **hledání odpovědi**

IBM Watson – DeepQA

- stroj označovaný jako **Watson – DeepQA** vyvinutý za účelem porazit lidské šampiony ve hře **Jeopardy (Riskuj)**
navazuje tím na stroj **DeepBlue**, který v roce 1997 porazil Kasparova v šachu
- po 5 letech vývoje se to Watsonovi podařilo 16.února 2011
- princip:
 - vytvoření **databáze tvrzení** z internetových dat
 - analýza částí otázky, členění otázek podle **typu**
 - vysoce **paralelní hledání** odpovědi s určením **míry jistoty**
 - vyladěný algoritmus pro **kombinaci** stovek výsledků do výsledného rozhodovacího skóre
 - viz [Jak a proč Watson vyhrál Jeopardy!](#)
- **nejedná se o umělou inteligenci** podle Turingova testu
- praktický význam – **inteligentní** zpracování obrovského množství textů pro **hledání odpovědi**

IBM Watson – DeepQA

- stroj označovaný jako **Watson – DeepQA** vyvinutý za účelem porazit lidské šampiony ve hře **Jeopardy (Riskuj)**
navazuje tím na stroj **DeepBlue**, který v roce 1997 porazil Kasparova v šachu
- po 5 letech vývoje se to Watsonovi podařilo 16.února 2011
- princip:
 - vytvoření **databáze tvrzení** z internetových dat
 - analýza částí otázky, členění otázek podle **typu**
 - vysoce **paralelní hledání** odpovědi s určením **míry jistoty**
 - vyladěný algoritmus pro **kombinaci** stovek výsledků do výsledného rozhodovacího skóre
 - viz [Jak a proč Watson vyhrál Jeopardy!](#)
- **nejedná se o umělou inteligenci** podle Turingova testu
- praktický význam – **inteligentní** zpracování obrovského množství textů pro **hledání odpovědi**

IBM Watson – DeepQA

- stroj označovaný jako **Watson – DeepQA** vyvinutý za účelem porazit lidské šampiony ve hře **Jeopardy (Riskuj)**
navazuje tím na stroj **DeepBlue**, který v roce 1997 porazil Kasparova v šachu
- po 5 letech vývoje se to Watsonovi podařilo 16.února 2011
- princip:
 - vytvoření **databáze tvrzení** z internetových dat
 - analýza částí otázky, členění otázek podle **typu**
 - vysoce **paralelní hledání** odpovědi s určením **míry jistoty**
 - vyladěný algoritmus pro **kombinaci** stovek výsledků do výsledného rozhodovacího skóre
 - viz [Jak a proč Watson vyhrál Jeopardy!](#)
- **nejedná se o umělou inteligenci** podle Turingova testu
- praktický význam – **inteligentní** zpracování obrovského množství textů pro **hledání odpovědi**

IBM Watson – DeepQA

- stroj označovaný jako **Watson – DeepQA** vyvinutý za účelem porazit lidské šampiony ve hře **Jeopardy (Riskuj)**
navazuje tím na stroj **DeepBlue**, který v roce 1997 porazil Kasparova v šachu
- po 5 letech vývoje se to Watsonovi podařilo 16.února 2011
- princip:
 - vytvoření **databáze tvrzení** z internetových dat
 - analýza částí otázky, členění otázek podle **typu**
 - vysoce **paralelní hledání** odpovědi s určením **míry jistoty**
 - vyladěný algoritmus pro **kombinaci** stovek výsledků do výsledného rozhodovacího skóre
 - viz Jak a proč Watson vyhrál Jeopardy!
- **nejedná se o umělou inteligenci** podle Turingova testu
- praktický význam – **inteligentní zpracování** obrovského množství textů pro **hledání odpovědi**

IBM Watson – DeepQA

- stroj označovaný jako **Watson – DeepQA** vyvinutý za účelem porazit lidské šampiony ve hře **Jeopardy (Riskuj)**
navazuje tím na stroj **DeepBlue**, který v roce 1997 porazil Kasparova v šachu
- po 5 letech vývoje se to Watsonovi podařilo 16.února 2011
- princip:
 - vytvoření **databáze tvrzení** z internetových dat
 - analýza částí otázky, členění otázek podle **typu**
 - vysoce **paralelní hledání** odpovědi s určením **míry jistoty**
 - vyladěný algoritmus pro **kombinaci** stovek výsledků do výsledného rozhodovacího skóre
 - viz Jak a proč Watson vyhrál Jeopardy!
- **nejedná se o umělou inteligenci** podle Turingova testu
- praktický význam – **inteligentní zpracování obrovského množství textů pro hledání odpovědi**

IBM Watson – DeepQA

- stroj označovaný jako **Watson – DeepQA** vyvinutý za účelem porazit lidské šampiony ve hře **Jeopardy (Riskuj)**
navazuje tím na stroj **DeepBlue**, který v roce 1997 porazil Kasparova v šachu
- po 5 letech vývoje se to Watsonovi podařilo 16.února 2011
- princip:
 - vytvoření **databáze tvrzení** z internetových dat
 - analýza částí otázky, členění otázek podle **typu**
 - vysoce **paralelní hledání** odpovědi s určením **míry jistoty**
 - vyladěný algoritmus pro **kombinaci** stovek výsledků do výsledného rozhodovacího skóre
 - viz Jak a proč Watson vyhrál Jeopardy!
- **nejedná se o umělou inteligenci** podle Turingova testu
- praktický význam – **inteligentní** zpracování obrovského množství textů pro **hledání odpovědi**

Historie počítačové lingvistiky

- 1957 – rusko-anglický překlad
- Chomsky (60. léta) – generativní gramatika, vrozenost jazyka, ...
- strojový překlad není ani dnes dokonalý – potřebuje porozumět obsahu textu (Paretův zákon – pravidlo 80/20)
- problémy – víceznačnost, množství významů slov, různé způsoby užití slov k vyjádření významu, “Commonsense” a lidské uvažování
- Robert Wilensky: NLP je “AI-complete”
- 80. a 90. léta – rozvoj formalismů pro syntaktickou analýzu PJ (LFG, LTAG, HPSG)
- současně – zkoumání kvality statistických metod s rozsáhlými daty → srovnatelné výsledky!
- 90. léta až 200x – tvorba zdrojů vyšší úrovně (syntakticko-sémantické lexikony, wordnety, ...)
- stále není na obzoru splnění Turingova testu

Historie počítačové lingvistiky

- 1957 – rusko-anglický překlad
- Chomsky (60. léta) – generativní gramatika, vrozenost jazyka, ...
- strojový překlad není ani dnes dokonalý – potřebuje porozumět obsahu textu (Paretův zákon – pravidlo 80/20)
- problémy – víceznačnost, množství významů slov, různé způsoby užití slov k vyjádření významu, “Commonsense” a lidské uvažování
- Robert Wilensky: NLP je “AI-complete”
- 80. a 90. léta – rozvoj formalismů pro syntaktickou analýzu PJ (LFG, LTAG, HPSG)
- současně – zkoumání kvality statistických metod s rozsáhlými daty → srovnatelné výsledky!
- 90. léta až 200x – tvorba zdrojů vyšší úrovně (syntakticko-sémantické lexikony, wordnety, ...)
- stále není na obzoru splnění Turingova testu

Historie počítačové lingvistiky

- 1957 – rusko-anglický překlad
- Chomsky (60. léta) – generativní gramatika, vrozenost jazyka, . . .
- strojový překlad není ani dnes dokonalý – potřebuje porozumět obsahu textu (Paretův zákon – pravidlo 80/20)
- problémy – víceznačnost, množství významů slov, různé způsoby užití slov k vyjádření významu, “Commonsense” a lidské uvažování
- Robert Wilensky: NLP je “AI-complete”
- 80. a 90. léta – rozvoj formalismů pro syntaktickou analýzu PJ (LFG, LTAG, HPSG)
- současně – zkoumání kvality statistických metod s rozsáhlými daty → srovnatelné výsledky!
- 90. léta až 200x – tvorba zdrojů vyšší úrovně (syntakticko-sémantické lexikony, wordnety, . . .)
- stále není na obzoru splnění Turingova testu

Historie počítačové lingvistiky

- 1957 – rusko-anglický překlad
- Chomsky (60. léta) – generativní gramatika, vrozenost jazyka, ...
- strojový překlad není ani dnes dokonalý – potřebuje porozumět obsahu textu (Paretův zákon – pravidlo 80/20)
- problémy – víceznačnost, množství významů slov, různé způsoby užití slov k vyjádření významu, “Commonsense” a lidské uvažování
- Robert Wilensky: NLP je “AI-complete”
- 80. a 90. léta – rozvoj formalismů pro syntaktickou analýzu PJ (LFG, LTAG, HPSG)
- současně – zkoumání kvality statistických metod s rozsáhlými daty → srovnatelné výsledky!
- 90. léta až 200x – tvorba zdrojů vyšší úrovně (syntakticko-sémantické lexikony, wordnety, ...)
- stále není na obzoru splnění Turingova testu

Historie počítačové lingvistiky

- 1957 – rusko-anglický překlad
- Chomsky (60. léta) – generativní gramatika, vrozenost jazyka, ...
- strojový překlad není ani dnes dokonalý – potřebuje porozumět obsahu textu (Paretův zákon – pravidlo 80/20)
- problémy – víceznačnost, množství významů slov, různé způsoby užití slov k vyjádření významu, “Commonsense” a lidské uvažování
- Robert Wilensky: NLP je “AI-complete”
- 80. a 90. léta – rozvoj formalismů pro syntaktickou analýzu PJ (LFG, LTAG, HPSG)
- současně – zkoumání kvality statistických metod s rozsáhlými daty → srovnatelné výsledky!
- 90. léta až 200x – tvorba zdrojů vyšší úrovně (syntakticko-sémantické lexikony, wordnety, ...)
- stále není na obzoru splnění Turingova testu

Historie počítačové lingvistiky

- 1957 – rusko-anglický překlad
- Chomsky (60. léta) – generativní gramatika, vrozenost jazyka, ...
- strojový překlad není ani dnes dokonalý – potřebuje porozumět obsahu textu (Paretův zákon – pravidlo 80/20)
- problémy – víceznačnost, množství významů slov, různé způsoby užití slov k vyjádření významu, “Commonsense” a lidské uvažování
- Robert Wilensky: NLP je “AI-complete”
- 80. a 90. léta – rozvoj formalismů pro syntaktickou analýzu PJ (LFG, LTAG, HPSG)
- současně – zkoumání kvality statistických metod s rozsáhlými daty → srovnatelné výsledky!
- 90. léta až 200x – tvorba zdrojů vyšší úrovně (syntakticko-sémantické lexikony, wordnety, ...)
- stále není na obzoru splnění Turingova testu

Historie počítačové lingvistiky

- 1957 – rusko-anglický překlad
- Chomsky (60. léta) – generativní gramatika, vrozenost jazyka, ...
- strojový překlad není ani dnes dokonalý – potřebuje porozumět obsahu textu (Paretův zákon – pravidlo 80/20)
- problémy – víceznačnost, množství významů slov, různé způsoby užití slov k vyjádření významu, “Commonsense” a lidské uvažování
- Robert Wilensky: NLP je “AI-complete”
- 80. a 90. léta – rozvoj formalismů pro syntaktickou analýzu PJ (LFG, LTAG, HPSG)
- současně – zkoumání kvality statistických metod s rozsáhlými daty → srovnatelné výsledky!
- 90. léta až 200x – tvorba zdrojů vyšší úrovně (syntakticko-sémantické lexikony, wordnety, ...)
- stále není na obzoru splnění Turingova testu

Historie počítačové lingvistiky

- 1957 – rusko-anglický překlad
- Chomsky (60. léta) – generativní gramatika, vrozenost jazyka, ...
- strojový překlad není ani dnes dokonalý – potřebuje porozumět obsahu textu (Paretův zákon – pravidlo 80/20)
- problémy – víceznačnost, množství významů slov, různé způsoby užití slov k vyjádření významu, “Commonsense” a lidské uvažování
- Robert Wilensky: NLP je “AI-complete”
- 80. a 90. léta – rozvoj formalismů pro syntaktickou analýzu PJ (LFG, LTAG, HPSG)
- současně – zkoumání kvality statistických metod s rozsáhlými daty → srovnatelné výsledky!
- 90. léta až 200x – tvorba zdrojů vyšší úrovně (syntakticko-sémantické lexikony, wordnety, ...)
- stále není na obzoru splnění Turingova testu

Historie počítačové lingvistiky

- 1957 – rusko-anglický překlad
- Chomsky (60. léta) – generativní gramatika, vrozenost jazyka, . . .
- strojový překlad není ani dnes dokonalý – potřebuje porozumět obsahu textu (Paretův zákon – pravidlo 80/20)
- problémy – víceznačnost, množství významů slov, různé způsoby užití slov k vyjádření významu, “Commonsense” a lidské uvažování
- Robert Wilensky: NLP je “AI-complete”
- 80. a 90. léta – rozvoj formalismů pro syntaktickou analýzu PJ (LFG, LTAG, HPSG)
- současně – zkoumání kvality statistických metod s rozsáhlými daty → srovnatelné výsledky!
- 90. léta až 200x – tvorba zdrojů vyšší úrovně (syntakticko-sémantické lexikony, wordnety, . . .)
- stále není na obzoru splnění Turingova testu

Cíle počítačové lingvistiky

Významné úkoly v NLP:

- analýza přirozeného jazyka – morfologická, syntaktická, sémantická
- generování přirozeného jazyka
- syntéza a rozpoznávání řeči
- strojový překlad (*Machine translation*)
- odpovídání na otázky (*Question answering*)
- získávání informací (*Information retrieval*)
- korektura textu (*Spell-checking, Grammar checking*)
- extrakce informací (*Information extraction*)
- výtah z textu (*Text summarization*)
- určení typu dokumentu (*Text Classification/Clustering*)

Cíle počítačové lingvistiky

Významné úkoly v NLP:

- analýza přirozeného jazyka – morfologická, syntaktická, sémantická
- generování přirozeného jazyka
- syntéza a rozpoznávání řeči
- strojový překlad (*Machine translation*)
- odpovídání na otázky (*Question answering*)
- získávání informací (*Information retrieval*)
- korektura textu (*Spell-checking, Grammar checking*)
- extrakce informací (*Information extraction*)
- výtah z textu (*Text summarization*)
- určení typu dokumentu (*Text Classification/Clustering*)

Cíle počítačové lingvistiky

Významné úkoly v NLP:

- analýza přirozeného jazyka – morfologická, syntaktická, sémantická
- generování přirozeného jazyka
- syntéza a rozpoznávání řeči
- strojový překlad (*Machine translation*)
- odpovídání na otázky (*Question answering*)
- získávání informací (*Information retrieval*)
- korektura textu (*Spell-checking, Grammar checking*)
- extrakce informací (*Information extraction*)
- výtah z textu (*Text summarization*)
- určení typu dokumentu (*Text Classification/Clustering*)

Cíle počítačové lingvistiky

Významné úkoly v NLP:

- analýza přirozeného jazyka – morfologická, syntaktická, sémantická
- generování přirozeného jazyka
- syntéza a rozpoznávání řeči
- strojový překlad (*Machine translation*)
- odpovídání na otázky (*Question answering*)
- získávání informací (*Information retrieval*)
- korektura textu (*Spell-checking, Grammar checking*)
- extrakce informací (*Information extraction*)
- výtah z textu (*Text summarization*)
- určení typu dokumentu (*Text Classification/Clustering*)

Cíle počítačové lingvistiky

Významné úkoly v NLP:

- analýza přirozeného jazyka – morfologická, syntaktická, sémantická
- generování přirozeného jazyka
- syntéza a rozpoznávání řeči
- strojový překlad (*Machine translation*)
- odpovídání na otázky (*Question answering*)
- získávání informací (*Information retrieval*)
- korektura textu (*Spell-checking, Grammar checking*)
- extrakce informací (*Information extraction*)
- výtah z textu (*Text summarization*)
- určení typu dokumentu (*Text Classification/Clustering*)

Cíle počítačové lingvistiky

Významné úkoly v NLP:

- analýza přirozeného jazyka – morfologická, syntaktická, sémantická
- generování přirozeného jazyka
- syntéza a rozpoznávání řeči
- strojový překlad (*Machine translation*)
- odpovídání na otázky (*Question answering*)
- získávání informací (*Information retrieval*)
- korektura textu (*Spell-checking, Grammar checking*)
- extrakce informací (*Information extraction*)
- výtah z textu (*Text summarization*)
- určení typu dokumentu (*Text Classification/Clustering*)

Cíle počítačové lingvistiky

Významné úkoly v NLP:

- analýza přirozeného jazyka – morfologická, syntaktická, sémantická
- generování přirozeného jazyka
- syntéza a rozpoznávání řeči
- strojový překlad (*Machine translation*)
- odpovídání na otázky (*Question answering*)
- získávání informací (*Information retrieval*)
- korektura textu (*Spell-checking, Grammar checking*)
- extrakce informací (*Information extraction*)
- výtah z textu (*Text summarization*)
- určení typu dokumentu (*Text Classification/Clustering*)

Cíle počítačové lingvistiky

Významné úkoly v NLP:

- analýza přirozeného jazyka – morfologická, syntaktická, sémantická
- generování přirozeného jazyka
- syntéza a rozpoznávání řeči
- strojový překlad (*Machine translation*)
- odpovídání na otázky (*Question answering*)
- získávání informací (*Information retrieval*)
- korektura textu (*Spell-checking, Grammar checking*)
- extrakce informací (*Information extraction*)
- výtah z textu (*Text summarization*)
- určení typu dokumentu (*Text Classification/Clustering*)

Cíle počítačové lingvistiky

Významné úkoly v NLP:

- analýza přirozeného jazyka – morfologická, syntaktická, sémantická
- generování přirozeného jazyka
- syntéza a rozpoznávání řeči
- strojový překlad (*Machine translation*)
- odpovídání na otázky (*Question answering*)
- získávání informací (*Information retrieval*)
- korektura textu (*Spell-checking, Grammar checking*)
- extrakce informací (*Information extraction*)
- výtah z textu (*Text summarization*)
- určení typu dokumentu (*Text Classification/Clustering*)

Cíle počítačové lingvistiky

Významné úkoly v NLP:

- analýza přirozeného jazyka – morfologická, syntaktická, sémantická
- generování přirozeného jazyka
- syntéza a rozpoznávání řeči
- strojový překlad (*Machine translation*)
- odpovídání na otázky (*Question answering*)
- získávání informací (*Information retrieval*)
- korektura textu (*Spell-checking, Grammar checking*)
- extrakce informací (*Information extraction*)
- výtah z textu (*Text summarization*)
- určení typu dokumentu (*Text Classification/Clustering*)

Obsah

- 1 Organizace předmětu IB030
 - Základní informace
 - Literatura
 - Náplň předmětu
- 2 Počítačová lingvistika
 - Historie počítačové lingvistiky
 - Cíle počítačové lingvistiky
- 3 Situace na FI MU
 - Přednášky se vztahem k NLP
 - NLP Centre – Centrum ZPJ
 - NLP projekty a SW

Přednášky se vztahem k NLP na FI MU

- obor **Umělá inteligence a zpracování přirozeného jazyka**
- vybrané Bc přednášky:

IB030	Úvod do počítačové lingvistiky	Horák
IB047	Úvod do korpusové lingvistiky a počítačové lexikografie	Rychlý, Pala
IV029	Logická analýza přirozeného jazyka	Materna, Duží
PB016	Úvod do umělé inteligence	Horák
PB095	Úvod do počítačového zpracování řeči	Bártek
PV056	Strojové učení a dobývání znalostí	Popelínský
PV173	Seminář zpracování přirozeného jazyka	Horák, Rychlý

Přednášky se vztahem k NLP na FI MU

- obor **Umělá inteligence a zpracování přirozeného jazyka**
- vybrané Bc přednášky:

IB030	Úvod do počítačové lingvistiky	Horák
IB047	Úvod do korpusové lingvistiky a počítačové lexikografie	Rychlý, Pala
IV029	Logická analýza přirozeného jazyka	Materna, Duží
PB016	Úvod do umělé inteligence	Horák
PB095	Úvod do počítačového zpracování řeči	Bártek
PV056	Strojové učení a dobývání znalostí	Popelínský
PV173	Seminář zpracování přirozeného jazyka	Horák, Rychlý

NLP Centre – Centrum ZPJ na FI MU

- sdružení lidí (studentů Bc., Mgr. a PGS i zaměstnanců) z **oblasti NLP**
- webový server nlp.fi.muni.cz
- fyzicky – 2 “skleníky” ve 2. patře budovy B:
 - 2 místnosti NLP – **laboratoře zpracování přirozeného jazyka** (doc. Pala)
 - část B203 pro LSD – **laboratoř vyhledávání a dialogu** (doc. Kopeček, prof. Zezula)
- vlastní laboratorní servery a stanice s OS Linux
- řeší několik velkých **grantových projektů**, pořádá **mezinárodní konference** (TSD, GWC, Lexicom, ...)
- práce studentů:
 - “malé projekty,” které se využijí v rámci “velkých projektů”
 - bakalářské, diplomové i disertační práce
 - někdy i zaměstnanecký poměr
- **PV173 Seminář Laboratoře zpracování přirozeného jazyka** – pravidelná společná výměna informací

NLP Centre – Centrum ZPJ na FI MU

- sdružení lidí (studentů Bc., Mgr. a PGS i zaměstnanců) z **oblasti NLP**
- webový server **nlp.fi.muni.cz**
- fyzicky – 2 “skleníky” ve 2. patře budovy B:
 - 2 místnosti NLP – **laboratoře zpracování přirozeného jazyka** (doc. Pala)
 - část B203 pro LSD – **laboratoř vyhledávání a dialogu** (doc. Kopeček, prof. Zezula)
- vlastní laboratorní servery a stanice s OS Linux
- řeší několik velkých **grantových projektů**, pořádá **mezinárodní konference** (TSD, GWC, Lexicom, ...)
- práce studentů:
 - “malé projekty,” které se využijí v rámci “velkých projektů”
 - bakalářské, diplomové i disertační práce
 - někdy i zaměstnanecký poměr
- **PV173 Seminář Laboratoře zpracování přirozeného jazyka** – pravidelná společná výměna informací

NLP Centre – Centrum ZPJ na FI MU

- sdružení lidí (studentů Bc., Mgr. a PGS i zaměstnanců) z **oblasti NLP**
- webový server **nlp.fi.muni.cz**
- fyzicky – 2 “skleníky” ve 2. patře budovy B:
 - 2 místnosti NLP – **laboratoře zpracování přirozeného jazyka** (doc. Pala)
 - část B203 pro LSD – **laboratoř vyhledávání a dialogu** (doc. Kopeček, prof. Zezula)
- vlastní laboratorní servery a stanice s OS Linux
- řeší několik velkých **grantových projektů**, pořádá **mezinárodní konference** (TSD, GWC, Lexicom, ...)
- práce studentů:
 - “malé projekty,” které se využijí v rámci “velkých projektů”
 - bakalářské, diplomové i disertační práce
 - někdy i zaměstnanecký poměr
- **PV173 Seminář Laboratoře zpracování přirozeného jazyka** – pravidelná společná výměna informací

NLP Centre – Centrum ZPJ na FI MU

- sdružení lidí (studentů Bc., Mgr. a PGS i zaměstnanců) z **oblasti NLP**
- webový server **nlp.fi.muni.cz**
- fyzicky – 2 “skleníky” ve 2. patře budovy B:
 - 2 místnosti NLP – **laboratoře zpracování přirozeného jazyka** (doc. Pala)
 - část B203 pro LSD – **laboratoř vyhledávání a dialogu** (doc. Kopeček, prof. Zezula)
- vlastní laboratorní servery a stanice s OS Linux
- řeší několik velkých **grantových projektů**, pořádá **mezinárodní konference** (TSD, GWC, Lexicom, ...)
- práce studentů:
 - “malé projekty,” které se využijí v rámci “velkých projektů”
 - bakalářské, diplomové i disertační práce
 - někdy i zaměstnanecký poměr
- **PV173 Seminář Laboratoře zpracování přirozeného jazyka** – pravidelná společná výměna informací

NLP Centre – Centrum ZPJ na FI MU

- sdružení lidí (studentů Bc., Mgr. a PGS i zaměstnanců) z **oblasti NLP**
- webový server **nlp.fi.muni.cz**
- fyzicky – 2 “skleníky” ve 2. patře budovy B:
 - 2 místnosti NLP – **laboratoře zpracování přirozeného jazyka** (doc. Pala)
 - část B203 pro LSD – **laboratoř vyhledávání a dialogu** (doc. Kopeček, prof. Zezula)
- vlastní laboratorní servery a stanice s OS Linux
- řeší několik velkých **grantových projektů**, pořádá **mezinárodní konference** (TSD, GWC, Lexicom, ...)
- práce studentů:
 - “malé projekty,” které se využijí v rámci “velkých projektů”
 - bakalářské, diplomové i disertační práce
 - někdy i zaměstnanecký poměr
- **PV173 Seminář Laboratoře zpracování přirozeného jazyka** – pravidelná společná výměna informací

NLP Centre – Centrum ZPJ na FI MU

- sdružení lidí (studentů Bc., Mgr. a PGS i zaměstnanců) z **oblasti NLP**
- webový server **nlp.fi.muni.cz**
- fyzicky – 2 “skleníky” ve 2. patře budovy B:
 - 2 místnosti NLP – **laboratoře zpracování přirozeného jazyka** (doc. Pala)
 - část B203 pro LSD – **laboratoř vyhledávání a dialogu** (doc. Kopeček, prof. Zezula)
- vlastní laboratorní servery a stanice s OS Linux
- řeší několik velkých **grantových projektů**, pořádá **mezinárodní konference** (TSD, GWC, Lexicom, ...)
- práce studentů:
 - “malé projekty,” které se využijí v rámci “velkých projektů”
 - bakalářské, diplomové i disertační práce
 - někdy i zaměstnanecký poměr
- **PV173 Seminář Laboratoře zpracování přirozeného jazyka** – pravidelná společná výměna informací

NLP Centre – Centrum ZPJ na FI MU

- sdružení lidí (studentů Bc., Mgr. a PGS i zaměstnanců) z **oblasti NLP**
- webový server **nlp.fi.muni.cz**
- fyzicky – 2 “skleníky” ve 2. patře budovy B:
 - 2 místnosti NLP – **laboratoře zpracování přirozeného jazyka** (doc. Pala)
 - část B203 pro LSD – **laboratoř vyhledávání a dialogu** (doc. Kopeček, prof. Zezula)
- vlastní laboratorní servery a stanice s OS Linux
- řeší několik velkých **grantových projektů**, pořádá **mezinárodní konference** (TSD, GWC, Lexicom, ...)
- práce studentů:
 - “malé projekty,” které se využijí v rámci “velkých projektů”
 - bakalářské, diplomové i disertační práce
 - někdy i zaměstnanecký poměr
- **PV173 Seminář Laboratoře zpracování přirozeného jazyka** – pravidelná společná výměna informací

NLP Centre – Centrum ZPJ na FI MU

- sdružení lidí (studentů Bc., Mgr. a PGS i zaměstnanců) z **oblasti NLP**
- webový server **nlp.fi.muni.cz**
- fyzicky – 2 “skleníky” ve 2. patře budovy B:
 - 2 místnosti NLP – **laboratoře zpracování přirozeného jazyka** (doc. Pala)
 - část B203 pro LSD – **laboratoř vyhledávání a dialogu** (doc. Kopeček, prof. Zezula)
- vlastní laboratorní servery a stanice s OS Linux
- řeší několik velkých **grantových projektů**, pořádá **mezinárodní konference** (TSD, GWC, Lexicom, ...)
- práce studentů:
 - “malé projekty,” které se využijí v rámci “velkých projektů”
 - bakalářské, diplomové i disertační práce
 - někdy i zaměstnanecký poměr
- **PV173 Seminář Laboratoře zpracování přirozeného jazyka** – pravidelná společná výměna informací

NLP Centre – Centrum ZPJ na FI MU

- sdružení lidí (studentů Bc., Mgr. a PGS i zaměstnanců) z **oblasti NLP**
- webový server **nlp.fi.muni.cz**
- fyzicky – 2 “skleníky” ve 2. patře budovy B:
 - 2 místnosti NLP – **laboratoře zpracování přirozeného jazyka** (doc. Pala)
 - část B203 pro LSD – **laboratoř vyhledávání a dialogu** (doc. Kopeček, prof. Zezula)
- vlastní laboratorní servery a stanice s OS Linux
- řeší několik velkých **grantových projektů**, pořádá **mezinárodní konference** (TSD, GWC, Lexicom, ...)
- práce studentů:
 - “malé projekty,” které se využijí v rámci “velkých projektů”
 - bakalářské, diplomové i disertační práce
 - někdy i zaměstnanecký poměr
- **PV173 Seminář Laboratoře zpracování přirozeného jazyka** – pravidelná společná výměna informací

NLP projekty a SW na FI MU

Vybrané projekty:

- **ajka**, **majka**, **desamb** – morfologický analyzátor, tagger
- **synt**, **set**, **zuzana** – syntaktické (a logický) analyzátoři
- **X.plain** – hra na hádání slov, člověk × počítač
- **Watsonson** – hra na hledání parafrází
- **DEB** – platforma pro XML databáze/slovníky
- **(DEB)VisDic** – editor wordnetů
- **VerbaLex** – slovník slovesných valencí
- **bonito**, **manatee**, **Word Sketches** – korpusový manažer
- **Visual Browser** – grafické znázornění (sémantických) sítí
- **GDW** (Grammar Development Workbench) – GUI pro vývoj gramatiky
- **demosthenes**, **text2phone (mbrola)** – syntetizátory řeči
- korpusy, slovníky, encyklopedie, ...

NLP projekty a SW na FI MU

Vybrané projekty:

- **ajka**, **majka**, **desamb** – morfologický analyzátor, tagger
- **synt**, **set**, **zuzana** – syntaktické (a logický) analyzátoři
- **X.plain** – hra na hádání slov, člověk × počítač
- **Watsonson** – hra na hledání parafrází
- **DEB** – platforma pro XML databáze/slovníky
- **(DEB)VisDic** – editor wordnetů
- **VerbaLex** – slovník slovesných valencí
- **bonito**, **manatee**, **Word Sketches** – korpusový manažer
- **Visual Browser** – grafické znázornění (sémantických) sítí
- **GDW** (Grammar Development Workbench) – GUI pro vývoj gramatiky
- **demosthenes**, **text2phone (mbrola)** – syntetizátory řeči
- korpusy, slovníky, encyklopedie, ...

NLP projekty a SW na FI MU

Vybrané projekty:

- **ajka**, **majka**, **desamb** – morfologický analyzátor, tagger
- **synt**, **set**, **zuzana** – syntaktické (a logický) analyzátoři
- **X.plain** – hra na hádání slov, člověk × počítač
- **Watsonson** – hra na hledání parafrází
- **DEB** – platforma pro XML databáze/slovníky
- **(DEB)VisDic** – editor wordnetů
- **VerbaLex** – slovník slovesných valencí
- **bonito**, **manatee**, **Word Sketches** – korpusový manažer
- **Visual Browser** – grafické znázornění (sémantických) sítí
- **GDW** (Grammar Development Workbench) – GUI pro vývoj gramatiky
- **demosthenes**, **text2phone** (**mbrola**) – syntetizátory řeči
- korpusy, slovníky, encyklopedie, ...

NLP projekty a SW na FI MU

Vybrané projekty:

- **ajka**, **majka**, **desamb** – morfologický analyzátor, tagger
- **synt**, **set**, **zuzana** – syntaktické (a logický) analyzátoři
- **X.plain** – hra na hádání slov, člověk × počítač
- **Watsonson** – hra na hledání parafrází
- **DEB** – platforma pro XML databáze/slovníky
- **(DEB)VisDic** – editor wordnetů
- **VerbaLex** – slovník slovesných valencí
- **bonito**, **manatee**, **Word Sketches** – korpusový manažer
- **Visual Browser** – grafické znázornění (sémantických) sítí
- **GDW** (Grammar Development Workbench) – GUI pro vývoj gramatiky
- **demosthenes**, **text2phone (mbrola)** – syntetizátory řeči
- korpusy, slovníky, encyklopedie, ...

NLP projekty a SW na FI MU

Vybrané projekty:

- **ajka**, **majka**, **desamb** – morfologický analyzátor, tagger
- **synt**, **set**, **zuzana** – syntaktické (a logický) analyzátoři
- **X.plain** – hra na hádání slov, člověk × počítač
- **Watsonson** – hra na hledání parafrází
- **DEB** – platforma pro XML databáze/slovníky
- (DEB)**VisDic** – editor wordnetů
- **VerbaLex** – slovník slovesných valencí
- **bonito**, **manatee**, **Word Sketches** – korpusový manažer
- **Visual Browser** – grafické znázornění (sémantických) sítí
- **GDW** (Grammar Development Workbench) – GUI pro vývoj gramatiky
- **demosthenes**, **text2phone** (**mbrola**) – syntetizátory řeči
- korpusy, slovníky, encyklopedie, ...

NLP projekty a SW na FI MU

Vybrané projekty:

- **ajka**, **majka**, **desamb** – morfologický analyzátor, tagger
- **synt**, **set**, **zuzana** – syntaktické (a logický) analyzátoři
- **X.plain** – hra na hádání slov, člověk × počítač
- **Watsonson** – hra na hledání parafrází
- **DEB** – platforma pro XML databáze/slovníky
- **(DEB)VisDic** – editor wordnetů
- **VerbaLex** – slovník slovesných valencí
- **bonito**, **manatee**, **Word Sketches** – korpusový manažer
- **Visual Browser** – grafické znázornění (sémantických) sítí
- **GDW** (Grammar Development Workbench) – GUI pro vývoj gramatiky
- **demosthenes**, **text2phone (mbrola)** – syntetizátory řeči
- korpusy, slovníky, encyklopedie, ...

NLP projekty a SW na FI MU

Vybrané projekty:

- **ajka**, **majka**, **desamb** – morfologický analyzátor, tagger
- **synt**, **set**, **zuzana** – syntaktické (a logický) analyzátoři
- **X.plain** – hra na hádání slov, člověk × počítač
- **Watsonson** – hra na hledání parafrází
- **DEB** – platforma pro XML databáze/slovníky
- **(DEB)VisDic** – editor wordnetů
- **VerbaLex** – slovník slovesných valencí
- **bonito**, **manatee**, **Word Sketches** – korpusový manažer
- **Visual Browser** – grafické znázornění (sémantických) sítí
- **GDW** (Grammar Development Workbench) – GUI pro vývoj gramatiky
- **demosthenes**, **text2phone (mbrola)** – syntetizátory řeči
- korpusy, slovníky, encyklopedie, ...

NLP projekty a SW na FI MU

Vybrané projekty:

- **ajka**, **majka**, **desamb** – morfologický analyzátor, tagger
- **synt**, **set**, **zuzana** – syntaktické (a logický) analyzátoři
- **X.plain** – hra na hádání slov, člověk × počítač
- **Watsonson** – hra na hledání parafrází
- **DEB** – platforma pro XML databáze/slovníky
- **(DEB)VisDic** – editor wordnetů
- **VerbaLex** – slovník slovesných valencí
- **bonito**, **manatee**, **Word Sketches** – korpusový manažer
- **Visual Browser** – grafické znázornění (sémantických) sítí
- **GDW** (Grammar Development Workbench) – GUI pro vývoj gramatiky
- **demosthenes**, **text2phone (mbrola)** – syntetizátory řeči
- korpusy, slovníky, encyklopedie, ...

NLP projekty a SW na FI MU

Vybrané projekty:

- **ajka**, **majka**, **desamb** – morfologický analyzátor, tagger
- **synt**, **set**, **zuzana** – syntaktické (a logický) analyzátoři
- **X.plain** – hra na hádání slov, člověk × počítač
- **Watsonson** – hra na hledání parafrází
- **DEB** – platforma pro XML databáze/slovníky
- **(DEB)VisDic** – editor wordnetů
- **VerbaLex** – slovník slovesných valencí
- **bonito**, **manatee**, **Word Sketches** – korpusový manažer
- **Visual Browser** – grafické znázornění (sémantických) sítí
- **GDW** (Grammar Development Workbench) – GUI pro vývoj gramatiky
- **demosthenes**, **text2phone (mbrola)** – syntetizátory řeči
- korpusy, slovníky, encyklopedie, ...

NLP projekty a SW na FI MU

Vybrané projekty:

- **ajka**, **majka**, **desamb** – morfologický analyzátor, tagger
- **synt**, **set**, **zuzana** – syntaktické (a logický) analyzátoři
- **X.plain** – hra na hádání slov, člověk × počítač
- **Watsonson** – hra na hledání parafrází
- **DEB** – platforma pro XML databáze/slovníky
- **(DEB)VisDic** – editor wordnetů
- **VerbaLex** – slovník slovesných valencí
- **bonito**, **manatee**, **Word Sketches** – korpusový manažer
- **Visual Browser** – grafické znázornění (sémantických) sítí
- **GDW** (Grammar Development Workbench) – GUI pro vývoj gramatiky
- **demosthenes**, **text2phone (mbrola)** – syntetizátory řeči
- korpusy, slovníky, encyklopedie, ...

NLP projekty a SW na FI MU

Vybrané projekty:

- **ajka**, **majka**, **desamb** – morfologický analyzátor, tagger
- **synt**, **set**, **zuzana** – syntaktické (a logický) analyzátoři
- **X.plain** – hra na hádání slov, člověk × počítač
- **Watsonson** – hra na hledání parafrází
- **DEB** – platforma pro XML databáze/slovníky
- **(DEB)VisDic** – editor wordnetů
- **VerbaLex** – slovník slovesných valencí
- **bonito**, **manatee**, **Word Sketches** – korpusový manažer
- **Visual Browser** – grafické znázornění (sémantických) sítí
- **GDW** (Grammar Development Workbench) – GUI pro vývoj gramatiky
- **demosthenes**, **text2phone (mbrola)** – syntetizátory řeči
- korpusy, slovníky, encyklopedie, ...

NLP projekty a SW na FI MU

Vybrané projekty:

- **ajka**, **majka**, **desamb** – morfologický analyzátor, tagger
- **synt**, **set**, **zuzana** – syntaktické (a logický) analyzátoři
- **X.plain** – hra na hádání slov, člověk × počítač
- **Watsonson** – hra na hledání parafrází
- **DEB** – platforma pro XML databáze/slovníky
- **(DEB)VisDic** – editor wordnetů
- **VerbaLex** – slovník slovesných valencí
- **bonito**, **manatee**, **Word Sketches** – korpusový manažer
- **Visual Browser** – grafické znázornění (sémantických) sítí
- **GDW** (Grammar Development Workbench) – GUI pro vývoj gramatiky
- **demosthenes**, **text2phone (mbrola)** – syntetizátory řeči
- korpusy, slovníky, encyklopedie, ...