



UNIVERSITÀ DI PISA

LINGUISTICA COMPUTAZIONALE II

SIMONETTA MONTEMAGNI

Anno accademico 2019/20
CdS INFORMATICA UMANISTICA
Codice 513LL
CFU 6

| | | | | |
|--|-----------------------|-----------------|-----------|--|
| Moduli LINGUISTICA COMPUTAZIONALE II | Settore/i L-LIN/01 | Tipo LEZIONI | Ore 36 | Docente/i SIMONETTA MONTEMAGNI GIULIA VENTURI |
|--|-----------------------|-----------------|-----------|--|

Obiettivi di apprendimento

Conoscenze

Il corso si propone di introdurre lo studente a settori chiave della Linguistica Computazionale caratterizzati da un forte impatto applicativo. In particolare, si articola attorno a due macro-temi, l'annotazione linguistica multi-livello del testo e l'estrazione di conoscenza linguistica da basi documentali annotate, che sono affrontati da una duplice prospettiva, teorica e applicativa.

Capacità

Al termine del corso lo studente saprà utilizzare in modo critico e consapevole strumenti di annotazione linguistica automatica e di estrazione di conoscenza linguistica, identificare le problematiche legate al trattamento di varietà non-standard della lingua e ipotizzare possibili soluzioni.

Prerequisiti (conoscenze iniziali)

Nozioni di base di linguistica computazionale, di linguistica generale e di linguistica italiana.

Indicazioni metodologiche

Durante il corso si alterneranno lezioni frontali, con l'ausilio di slides powerpoint che vengono messe a disposizione degli studenti, ed esercitazioni di laboratorio, sia individuali sia di gruppo (svolte con PC delle aule informatiche e/o PC personali), in cui gli studenti sono invitati a confrontarsi con l'applicazione di strumenti software di annotazione linguistica del testo e di estrazione di conoscenza disponibili come demo online e ad analizzarne criticamente i risultati ottenuti in relazione a diverse varietà d'uso della lingua.

Programma (contenuti dell'insegnamento)

I contenuti del corso sono suddivisi in due macro-temi, per ciascuno dei quali segue una lista dei principali argomenti trattati:

- **Annotazione linguistica**
 - annotazione linguistica come processo incrementale; strumenti software per l'annotazione linguistica del testo; schemi di annotazione per l'annotazione morfo-sintattica e sintattica, con particolare attenzione allo schema delle "Universal Dependencies"; costruzione di corpora annotati e valutazione dell'annotazione; adattamento al dominio o altre varietà d'uso della lingua (es. storiche) di strumenti di annotazione;
- **Estrazione di conoscenza linguistica**
 - ricostruzione del profilo linguistico di collezioni di testi; monitoraggio linguistico di diverse tipologie testuali e/o varietà d'uso della lingua; uso dei risultati del monitoraggio linguistico all'interno di diversi scenari applicativi, ad esempio per la classificazione di generi testuali o per l'identificazione della lingua materna di produzioni L2; analisi della leggibilità del testo.

Bibliografia e materiale didattico

Bibliografia essenziale del corso, che potrà subire variazioni e/o integrazioni sulla base del progetto che verrà definito per l'esame finale

Annotazione linguistica del testo: letture generali

- Nivre, J. (2005) *Two Notions of Parsing*. In Arppe, A., Carlson, L., Lindén, K., Piitulainen, J., Suominen, M., Vainio, M., Westerlund,



UNIVERSITÀ DI PISA

H. and Yli-Jyrä, A. (eds.) *Inquiries into Words, Constraints and Contexts*. Festschrift in the Honour of Kimmo Koskenniemi on his 60th Birthday. CSLI Publications, 106-115.

- Nivre, J. (2006) *Two Strategies for Text Parsing*. In Suominen, M., Arppe, A., Airola, A., Heinämäki, O., Miestamo, M., Määttä, U., Niemi, J., Pitkänen, K. K. and Sinnemäki, K. (eds.) *A Man of Measure: Festschrift in Honour of Fred Karlsson on his 60th Birthday*. Turku: The Linguistic Association of Finland.
- Alessandro Lenci, Simonetta Montemagni, Vito Pirrelli, 2009, Annotazione sintattica di corpora: aspetti metodologici, in Cecilia Andorno, Stefano Rastelli (a cura di), *Corpora di italiano L2: tecnologie, metodi, spunti teorici*, Perugia, Guerra Edizioni, pp. 25-46.
- Alessandro Lenci, Simonetta Montemagni, Vito Pirrelli 2005, *Testo e computer*, Carocci, Roma – Capitolo 8 Annotazione linguistica del testo

Annotazione morfosintattica

- Venturi G. (2009). *Rassegna comparativa degli schemi di annotazione morfosintattica per la lingua italiana*, Technical report TRIPLE - RTT/1, February 2009.
- Slav Petrov, Dipanjan Das, and Ryan McDonald. 2012. *A universal part-of-speech tagset*. In *Proceedings of LREC 2012*.
- Kevin Gimpel, Nathan Schneider, Brendan O'Connor, Dipanjan Das, Daniel Mills, Jacob Eisenstein, Michael Heilman, Dani Yogatama, Jeffrey Flanigan, and Noah A. Smith. 2011. *Part-of-Speech Tagging for Twitter: Annotation, Features, and Experiments*. In *Proceedings of ACL 2011*. Markus Dickinson and Marwa Ragheb (2009). *Dependency Annotation for Learner Corpora*. *Proceedings of the Eighth Workshop on Treebanks and Linguistic Theories (TLT-8)*. Milan, Italy.
- Christopher D. Manning. 2011. *Part-of-Speech Tagging from 97% to 100%: Is It Time for Some Linguistics?* In Alexander Gelbukh (ed.), *Computational Linguistics and Intelligent Text Processing, 12th International Conference, CICLing 2011, Proceedings, Part I*. *Lecture Notes in Computer Science 6608*, pp. 171--189. Springer.

Annotazione sintattica

- Joakim Nivre. 2015. *Towards a Universal Grammar for Natural Language Processing*. In A. Gelbukh (Ed.), *Proceedings of CICLing 2015, Part I*, LNCS 9041, pp. 3–16, Springer International Publishing Switzerland.
- Sito Universal Dependencies (UD) project
 - <http://http://universalddependencies.org/>
- Bosco C., Montemagni S., Simi M. (2013). *Converting Italian Treebanks: Towards an Italian Stanford Dependency Treebank*. In *Proceedings of the 7th Linguistic Annotation Workshop & Interoperability with Discourse (LAW VII & ID at ACL-2013)*, Sofia, Bulgaria, August 8-9, pp. 61-69.
- Dell'Orletta F., Venturi G. (2016) "ULISSE: una strategia di adattamento al dominio per l'annotazione sintattica automatica". In E. M. Ponti e M. Baudassi (a cura di) "Computer parler soigner: tra linguistica e intelligenza artificiale", *Atti del convegno 15-17 dicembre 2014*, Pavia University Press, pp. 55-79.

Monitoraggio linguistico e sue applicazioni

- Montemagni S. (2013) "Tecnologie linguistico-computazionali e monitoraggio della lingua italiana". In *Studi Italiani di Linguistica Teorica e Applicata (SILTA) Anno XLII, Numero 1*, pp. 145-172,

Un articolo a scelta tra i seguenti:

- Dell'Orletta F., Montemagni S., Venturi G. (2013), "Linguistic Profiling of Texts Across Textual Genre and Readability Level. An Exploratory Study on Italian Fictional Prose". In *Proceedings of the Recent Advances in Natural Language Processing Conference (RANLP-2013)*, 7-11 September, Hissar, Bulgaria, pp. 189-197
- Dell'Orletta F., Montemagni S. e Venturi G. (2016) "Esplorazioni computazionali nello spazio dell'interlingua: verso una nuova metodologia di indagine". In R. Bombi e V. Orioles (a cura di), *Atti del XLVIII Congresso Internazionale di Studi della Società di Linguistica Italiana (SLI 2014)*, 25-27 settembre Udine.
- Barbagli A., Lucisano P., Dell'Orletta F., Montemagni S., Venturi G. (2015) "Il ruolo delle tecnologie del linguaggio nel monitoraggio dell'evoluzione delle abilità di scrittura: primi risultati". In *Italian Journal of Computational Linguistics (IJCoL)*, vol. 1, n. 1, pp. 99-117.

Analisi della leggibilità del testo

- *Recent Advances in Automatic Readability Assessment and Text Simplification*. Special issue of the *International Journal of Applied Linguistics*, 2014, 165:2, John Benjamins Publishing Company
 - "Computational Assessment of Text Readability: A Survey of Current and Future Research", Kevyn Collins-Thompson
 - "Assessing document and sentence readability in less resourced languages and across textual genres", Dell'Orletta F., Montemagni S., Venturi G. (2014)
 - Siddharthan A., (2014) *A survey of research on text simplification*, *ITL - International Journal of Applied Linguistics*, Volume 165, Issue 2, 2014, pp. 259-298

Indicazioni per non frequentanti

Contattare le docenti per concordare il programma d'esame.

Modalità d'esame



UNIVERSITÀ DI PISA

L'esame consisterà nell'illustrazione, sotto forma di relazione scritta, dei risultati di un progetto di annotazione linguistica di testi rappresentativi di una specifica varietà d'uso della lingua italiana e in un colloquio volto a discutere i risultati del progetto e a verificare l'acquisizione dei concetti introdotti nel corso e nei materiali didattici indicati.

Note

Il corso di Linguistica Computazionale II inizierà il **26 febbraio 2020**.

Ultimo aggiornamento 14/02/2020 17:08