



UNIVERSITÀ
DEGLI STUDI DI MILANO-BICOCCA

SYLLABUS DEL CORSO

Natural Language Processing

2324-2-FDS01Q011

Obiettivi

Il corso si propone di introdurre gli elementi fondazionali e i più recenti modelli computazionali avanzati relativi al processamento del linguaggio naturale. Lo studente, al termine dell'attività formativa, avrà acquisito conoscenze e competenze relative ad algoritmi, strumenti e modelli per l'elaborazione e l'analisi del linguaggio naturale, al fine di sfruttare i più recenti sistemi di processamento presenti allo stato dell'arte.

Contenuti sintetici

Elementi fondazionali di rappresentazione del linguaggio naturale
Semantica delle parole
Large Language Models
Applicazioni di NLP

Programma esteso

1. Fundamentals

- Rationalist and Empiricist Approaches to Language
- The Ambiguity of Language: Why NLP Is Difficult
- Linguistic Essentials
 - Words, Tokens, Lemmas, Stems
 - Parts of Speech and Morphology
 - Phrase Structure
- Dirty Hands-on Text

- 1.4.1 Lexical resources
- 1.4.2 Word counts
- 1.4.3 Zipf's laws
- 1.4.4 Collocations
- 1.4.5 Concordances

2. Vector Semantics

- Frequentist Representation of Text (TF, TF-IDF, etc..)
- Word Embeddings
 - Word2Vec
 - FastText
 - Glove
- Visualization of Embeddings:
 - Principal Components Analysis
 - T-distributed stochastic neighbor embedding
 - Uniform Manifold Approximation and Projection

3. Transformers and Large Language Models

- Attention Mechanisms: Self and Multi Head Attention
- Positional Embeddings
- Transformers as Language Models
- Pretraining Large Language Models
- Prompting and Instruct Tuning
- Interpretability and Explainability of Language Models

4. NLP Applications

- Text and Token Classification
- Chatbots and Dialog Systems
- Word Sense Disambiguation
- Topic Modeling
- Machine Translation

Prerequisiti

Utile, ma non obbligatorio: apprendimento automatico, programmazione in python

Modalità didattica

Lezioni ed esercitazioni in aula.

Il corso verrà erogato in lingua inglese.

Materiale didattico

Cristopher MANNING and Hinrich SCHÜTZE. Foundations of Statistical Natural Language Processing. MIT Press.
Dan JURAFSKY and James H. MARTIN. Speech and Language Processing. Prentice Hall.

Periodo di erogazione dell'insegnamento

Secondo semestre

Modalità di verifica del profitto e valutazione

Progetto ed Esame Orale. Sono assenti prove in itinere intermedie.

Il progetto consisterà nello sviluppo di uno strumento di natural language processing basato su metodi e modelli presentati a lezione. Il progetto prevede una valutazione espressa in un range 0-24.

L'orale prevede 4 domande di teoria tra gli argomenti del corso elencati nel programma dettagliato. Per ciascuna domanda verrà data una valutazione compresa pari a -2, per una risposta errata o mancata risposta, e +2 punti per una risposta corretta.

Orario di ricevimento

Su appuntamento da concordare via email con il docente.

Sustainable Development Goals
