



UNIVERSITÀ
DEGLI STUDI DI MILANO-BICOCCA

SYLLABUS DEL CORSO

Information Retrieval

2425-2-F1801Q110

Obiettivi

L'obiettivo del corso è fornire un'introduzione ai concetti fondamentali, ai modelli formali, e alle tecniche per la realizzazione di sistemi per il reperimento automatico di documenti testuali in forma digitale (sistemi di "Information Retrieval", detti Motori di Ricerca o Motori di Ricerca su Web quando i documenti da reperire sono costituiti da pagine Web). Dopo una introduzione all'analisi automatica di testi e alla loro rappresentazione (tecniche base di NLP), si definirà il problema del reperimento automatico di informazioni, che presuppone la stima della rilevanza dei documenti rispetto alle necessità informative dell'utente espresse in una query. Al termine del corso lo studente sarà in grado di comprendere tecniche relative all'analisi e alla rappresentazione di testi in linguaggio naturale, nonché il funzionamento di un motore di ricerca. Lo studente sarà inoltre in grado di utilizzare software "open source" per la definizione di applicazioni di Information Retrieval. Il laboratorio sarà finalizzato alla realizzazione di un'applicazione.

Contenuti sintetici

Il corso introdurrà dapprima il problema della rappresentazione di testi per un loro trattamento automatico, e le tecniche utilizzate in molte applicazioni di NLP per il pre-processing di testi e per una loro rappresentazione formale (incluse tecniche neurali). Si presenteranno poi le tecniche principali per la progettazione e la realizzazione di motori di ricerca, con accenni a tecniche per la definizione di sistemi per la raccomandazione di informazioni.

Verranno introdotti i principali modelli per la determinazione della stima di rilevanza di un documento rispetto alle necessità informative dell'utente, dal modello vettoriale ai più recenti modelli neurali.

Verranno inoltre presentate alcune tecniche per la personalizzazione della ricerca.

Il corso introdurrà anche il problema della collezione, l'analisi e reperimento di contenuto generato dagli utenti sui Social Media, e il tema della valutazione dell'efficacia dei motori di ricerca.

Programma esteso

1. Introduzione al text processing e al Natural Language Processing (NLP)
2. Introduzione al Text Mining e ad alcune applicazioni correlate al NLP.
3. Pre-Processing, indicizzazione e rappresentazione formale di testi (bag of words, word embeddings, statistical language models, neural language models - large language models)
4. Modelli di sistemi di Information Retrieval: i modelli base (Booleano, Vettoriale, modelli Probabilistici). Modelli avanzati (modelli neurali). Accenni a motori di ricerca per documenti multimediali.
5. I motori di ricerca su Web: crawling, link analysis e altri fattori per la stima della rilevanza di pagine Web.
6. La valutazione dei motori di ricerca.
7. Argomenti avanzati
8. Introduzione a software open source per la definizione di motori di ricerca

Prerequisiti

Nozioni di base di Statistica e di Algebra Lineare.

Modalità didattica

Il corso verrà tenuto in lingua inglese e prevede lezioni ed esercitazioni in laboratorio. Si organizzeranno seminari tenuti da esperti a livello internazionale.

Materiale didattico

Christopher D. Manning, Prabhakar Raghavan and Hinrich Schütze, Introduction to Information Retrieval, Cambridge University Press, 2008.

Periodo di erogazione dell'insegnamento

Primo semestre

Modalità di verifica del profitto e valutazione

Prova scritta individuale costituita da esercizi e domande aperte sui contenuti del corso. Realizzazione di un progetto di laboratorio che è possibile svolgere in gruppo (sino a tre studenti).

La prova scritta ha come obiettivo la valutazione del livello di comprensione degli aspetti teorici e tecnici di base dell'insegnamento erogato.

L'obiettivo del progetto di gruppo, attraverso l'utilizzo di software open source, è lo sviluppo di soluzioni tecnologiche a problemi affrontati a lezione. In particolare, si considerano ambiti applicativi reali che necessitano della definizione di sistemi i cui fondamenti sono stati presentati a lezione.

Orario di ricevimento

Previo appuntamento con la docente.

Sustainable Development Goals
