



UNIVERSITÀ DI PISA

DISTRIBUTED DATA ANALYSIS AND MINING

ROBERTO TRASARTI

Academic year 2018/19
Course DATA SCIENCE AND BUSINESS INFORMATICS
Code 687AA
Credits 6

Modules	Area	Type	Hours	Teacher(s)
DISTRIBUTED DATA ANALYSIS AND MINING	INF/01	LEZIONI	48	ROBERTO TRASARTI

Prerequisiti (conoscenze iniziali)

- Data Mining I e II
- Programmazione Python di base

Programma (contenuti dell'insegnamento)

Il Data Mining sui Big data è oggi un'area di ricerca molto attiva. L'applicazione delle attuali metodologie analitiche e strumenti software su un singolo personal computer non può gestire in modo efficiente dataset di grandi dimensioni. Le piattaforme di calcolo distribuito sono una soluzione scalabile per il big data mining, attraverso la scomposizione del problema in operazioni più piccole che possono essere eseguite parallelamente su singoli processori / macchine. Il corso propone l'insegnamento di concetti base del paradigma di calcolo distribuito tramite MapReduce dal punto di vista teorico e pratico, in particolare ci si focalizzerà su Hadoop per lo sviluppo di competenze nell'uso di strumenti di calcolo ad alte prestazioni per il data engineering, l'analisi di dati e l'utilizzo di tecniche di data mining. Gli studenti impareranno come i classici algoritmi di data mining possono essere applicati sui Big Data usando Hadoop (Spark). Set di dati reali (e open source) verranno utilizzati per presentare esempi e per consentire agli studenti di costruire i propri progetti. Una metà delle lezioni consisterà in esercitazioni (laboratorio) e una metà delle lezioni sarà teorica.

Prima lezione: 20 Settembre - 9:00 - 11:00 - Fibonacci X1

Pagina web del corso

<http://didawiki.di.unipi.it/doku.php/mds/ddam/start>

Ultimo aggiornamento 03/09/2018 13:12