



UNIVERSITÀ
DEGLI STUDI DI MILANO-BICOCCA

SYLLABUS DEL CORSO

Data Mining

1920-3-E4101B026

Obiettivi formativi

Il corso intende fornire una visione completa del Data Mining, dal pre processamento del dato fino alla selezione del miglior modello statistico per l'analisi e la comprensione del problema.

Alla fine del corso, lo studente sarà in grado di confrontare e selezionare il miglior metodo di Data Mining per il problema oggetto di analisi. Saprà trattare le principali problematiche relative al dato e, autonomamente, affrontare un problema reale nel miglior modo.

Contenuti sintetici

Durante il corso verranno affrontate le principali tecniche per il trattamento dei dati e spiegati sia metodi statistici di tipo supervisionato sia non supervisionato. Inoltre verranno introdotti concetti relativi al Text Mining.

Programma esteso

1. Introduzione al Data mining. Concetti introduttivi e esempi applicativi
2. Pre-processing: trattamento dei missing values.
3. Introduzione alla classificazione con esempi e concetti introduttivi. Metodi di classificazione: regressione logistica, discriminante lineare, discriminante quadratico e k-nn.
4. Definizione di overfitting e tecniche per evitarlo
5. Introduzione al clustering con esempi e concetti introduttivi: metodi gerarchici e partizionali.
6. Text mining con esempi e concetti di base: pre-processing (stop words, stem words, ...), rappresentazioni grafiche e utilizzo del clustering per il Text Mining.

Prerequisiti

Analisi Statistica Multivariata e programmazione in R.

Metodi didattici

Lezioni frontali e laboratorio.>

Modalità di verifica dell'apprendimento

Progetto e esame orale.

Scritto

Prova scritta mirata a verificare gli argomenti presentati in classe.

Progetto

Progetto applicativo da svolgere autonomamente o in gruppo su un dataset assegnato dal docente o scelto dagli studenti. Il progetto è realizzato in R e deve dimostrare la capacità di affrontare un problema reale in ogni suo aspetto utilizzando quanto visto a lezione.

Il progetto si compone sia del codice R sia di un report di presentazione.

Orale

Presentazione e discussione del progetto.

Note

Prove intermedie non sono previste.

Gli studenti non frequentanti sono pregati di contattare il docente almeno 15 giorni prima della data dell'esame.

Testi di riferimento

Gareth J., Witten D., Hastie T., Tibshirani R., *An Introduction to statistical learning with application in R*, springer (2013).

Altro materiale verrà indicato a lezione.

Periodo di erogazione dell'insegnamento

I Semestre

Lingua di insegnamento

Italiano
