



UNIVERSITÀ
DEGLI STUDI DI MILANO-BICOCCA

SYLLABUS DEL CORSO

Data Mining M

2526-1-F8206B007

Obiettivi formativi

Il corso si pone come obiettivo l'approfondimento di tecniche per l'analisi dei dati e di *data mining* e il perfezionamento delle abilità di modellizzazione con finalità previsiva, con relative implementazioni nell'ambiente di programmazione R.

Il corso fornisce una preparazione avanzata sull'analisi statistica dei modelli di regressione, con un equilibrio tra aspetti teorici, computazionali e applicativi. Dopo un richiamo al modello lineare e ai suoi algoritmi efficienti, vengono trattati metodi per la selezione del modello, la gestione del compromesso distorsione-varianza e i principali approcci penalizzati. Il corso approfondisce inoltre tecniche di regressione flessibili utili per modellare relazioni complesse. Gli studenti acquisiranno competenze per applicare in modo critico tali metodi a problemi reali, consolidando l'autonomia di giudizio nell'ambito dell'inferenza statistica, in linea con l'area "**Statistica**" del corso di laurea magistrale in Scienze Statistiche ed Economiche.

Contenuti sintetici

Il programma dettagliato è disponibile nella [pagina web del corso](#). Gli argomenti principali sono:

- A-B-C: modelli lineari ed aspetti computazionali
- Compromesso distorsione e varianza, ottimismo
- Selezione del modello e metodi penalizzati per modelli lineari (regressione ridge, lasso, *elastic-net*)
- Regressione nonparametrica (regressione lineare locale, splines di regressione e di liscio)
- Modelli additivi (GAM and MARS)

Programma esteso

- **A-B-C**
 - Il modello lineare e: ripasso e notazione
 - Equazioni normali, scomposizione di Cholesky ed algoritmi efficienti per i minimi quadrati
 - Scomposizione QR, metodo delle ortogonalizzazioni successive
 - Minimi quadrati iterati
 - Modelli lineari generalizzati: ripasso e notazione
- **Compromesso distorsione e varianza, ottimismo**
 - Regressione polinomiale
 - Insieme di stima ed insieme di verifica
 - Ottimismo, compromesso distorsione varianza, indice di Mallows
 - Convalida incrociata e convalida incrociata generalizzata
 - Criteri di informazione (AIC, BIC, etc.)
- **Selezione del modello e metodi penalizzati per modelli lineari**
 - *Best subset selection*
 - Regressione tramite componenti principali
 - Regressione *ridge*
 - Regressione *LARS* e Lasso
 - *Elastic-net*
- **Regressione nonparametrica**
 - Regressione lineare locale
 - Splines di regressione e di liscio
 - Regressione nonparametrica, caso bivariato
 - Maledizione della dimensionalità
- **Modelli additivi**
 - *Generalized Additive Models* (GAM)
 - *Multivariate Adaptive Regression Splines* (MARS)

Prerequisiti

È richiesta la conoscenza di (i) nozioni di algebra lineare, (ii) modelli di regressione lineare, (iii) modelli di regressione lineare generalizzati (GLM), (iv) inferenza statistica, (v) calcolo delle probabilità. È inoltre richiesta una solida conoscenza del software R.

Si raccomanda inoltre la conoscenza degli argomenti avanzati di probabilità e statistica inferenziale trattati nei corsi *Probabilità e Statistica Computazionale M* e *Statistica Avanzata M*.

Metodi didattici

Le lezioni si svolgono sia in aula che in laboratorio, integrando aspetti di carattere teorico con quelli pratico-applicativi di analisi dei dati e di programmazione in R.

Le 47 ore di didattica saranno così suddivise:

- 35 ore di lezione svolte in modalità erogativa in presenza;
- 12 ore di attività di laboratorio svolte in modalità interattiva da remoto.

Modalità di verifica dell'apprendimento

L'esame è composto da due parti, entrambe obbligatorie:

- (20 punti su 30) Prova scritta a **domande aperte**, in cui vengono valutati gli aspetti teorici del corso.
- (10 punti su 30) **Progetto individuale** (*data challenge*).

Il voto finale è dato dalla somma dei punteggi delle due parti.

Nella seconda metà del corso viene annunciata il tema del progetto individuale (*data challenge*). Gli studenti dovranno produrre ed inviare al docente delle **previsioni** relative al caso studio assegnato, congiuntamente ad una **relazione** di 4-5 pagine. Il materiale del progetto deve essere inviato al docente prima dell'esame scritto e ha validità di un anno, a partire dal momento in cui la competizione è stata annunciata.

Testi di riferimento

Riferimenti principali

- Azzalini, A. and Scarpa, B. (2011), [*Data Analysis and Data Mining*](#), Oxford University Press.
- Hastie, T., Tibshirani, R. and Friedman, J. (2009), [*The Elements of Statistical Learning*](#), Second Edition, Springer.

Approfondimenti

- Efron, B. and Hastie, T. (2016), [*Computer Age Statistical Inference*](#), Cambridge University Press.
- Lewis, Kane, Arnold (2019) *A Computational Approach to Statistical Learning*. Chapman And Hall/Crc.

Ulteriore materiale didattico verrà messo a disposizione nella [pagina web del corso](#).

Periodo di erogazione dell'insegnamento

Secondo semestre

Lingua di insegnamento

Inglese

Sustainable Development Goals

ISTRUZIONE DI QUALITÀ
