



UNIVERSITÀ
DEGLI STUDI DI MILANO-BICOCCA

COURSE SYLLABUS

Statistical Models

2122-2-E4102B084-E4102B085M

Obiettivi formativi

Il modulo di modelli statistici intende sviluppare le conoscenze teoriche e applicative circa i modelli di regressione lineare multipla e di regressione logistica multipla.

Conoscenza e comprensione

Lo studente viene introdotto ai concetti sottostanti i modelli statistici e le relative assunzioni. Impara ad utilizzare i modelli attraverso il loro impiego con dati reali e simulati. Impara ad interpretare i risultati e a verificare la sostenibilità del modello. Vengono trattati aspetti di analisi grafica, e analisi computazionale utilizzando la notazione matriciale.

Capacità di applicare conoscenza e comprensione

Il corso sviluppa le competenze per l'analisi dei dati aventi natura multivariata e provenienti da varie fonti informative: contesti aziendali, economici, biologici, fisici, medici, astronomici, ambientali, sociali e sportivi. Lo studente approfondisce le competenze nell'utilizzo della semantica dei software R e SAS sia per le analisi di statistica descrittiva multivariata che per l'applicazione del modello di regressione lineare multipla e del modello di regressione logistica. Lo studente impara a creare dei report dove illustra le analisi effettuate e commenta i risultati ottenuti.

Il corso permette allo studente di acquisire gli elementi di base di teoria e di applicazione dei modelli statistici e si qualifica come indispensabile sia per il successivo percorso universitario di formazione professionale nella scienza dei dati che per eventuali contesti lavorativi.

Contenuti sintetici

Viene introdotta la funzione di regressione lineare multipla nel caso di tre variabili e si esplicitano le assunzioni sottostanti. Viene spiegato il metodo di stima dei minimi quadrati e le proprietà principali degli stimatori dei parametri del modello. Si illustra la distribuzione di Gauss bivariata e multivariata e le relative proprietà vengono enunciate sia a livello teorico che con esempi applicativi basati su dati reali e simulati.

Si considera il modello di regressione lineare multipla a fini esplicativi e previsivi. Si illustra come valutare il modello considerando i seguenti aspetti: gli indici di adattamento, la scelta del numero di variabili esplicative, le analisi grafiche dei residui, ed i criteri d'informazione. Si valuta la presenza di multicollinearità e si accenna ai metodi di linearizzazione. Si considerano le misure di odds e odds ratio e si introduce il modello di regressione logistica generale, i metodi di stima dei parametri e di incertezza associata alla stima tramite gli errori standard, l'interpretazione dei coefficienti stimati e l'utilizzo del modello per scopi fini previsionali.

Nelle prime tre settimane di corso gli esempi su dati reali e simulati vengono svolti nell'ambiente R con l'ausilio di RMarkdown per integrare codice e output. In questo modo lo studente apprende anche ad effettuare analisi riproducibili. Nelle ultime settimane viene spiegato l'utilizzo delle procedure SAS sia in riferimento alle analisi preliminari dei dati sia per l'adattamento del modello di regressione lineare multipla e di regressione logistica.

Programma esteso

Il corso viene introdotto accennando all'impianto concettuale dell'inferenza statistica e alle differenze tra causazione e associazione. Si richiamano le diverse tipologie di caratteri, la rappresentazione matriciale dei dati e l'indice di correlazione tra caratteri quantitativi.

Il modello di regressione lineare multipla viene prima introdotto come funzione di regressione che coinvolge solo tre variabili sia con la notazione estesa che con quella notazione matriciale. Si richiama la scomposizione della devianza totale, ed il metodo dei minimi quadrati. Vengono illustrate le proprietà degli stimatori in base alle assunzioni del modello e l'inferenza sui coefficienti di regressione viene presentata sia per il singolo parametro che per coppie di parametri attraverso la determinazione degli errori standard e degli intervalli di confidenza singoli e congiunti.

Si introduce la distribuzione di Gauss bivariata e multivariata. Si illustra il metodo per ottenere delle realizzazioni simulate da entrambe le distribuzioni attraverso i vettori delle medie e la matrice di varianza-covarianza. Si utilizzano i grafici a dispersione a due e a tre dimensioni e le curve di livello per la distribuzione bivariata insieme all'ellissoide di concentrazione.

Si descrivono le principali analisi diagnostiche riguardanti i residui. Si introduce il criterio d'informazione Bayesiano e le tecniche di stepwise selection per la selezione delle variabili esplicative. Si accenna al problema della multicollinearità e viene introdotto l'indice d'inflazione della varianza. Viene illustrato l'utilizzo del modello ai fini predittivi ed i concetti di [training e validation sets](#). Vengono illustrate le previsioni sia in merito alla risposta riferita ad una singola unità sia in merito al valore medio della risposta.

Nel corso si introducono anche i seguenti aspetti: *i)* il metodo di stima della massima verosimiglianza; *ii)* la trasformazione delle variabili; *iii)* le variabili esplicative categoriali; *iv)* i modelli con ordini di interazione tra variabili esplicative; *v)* gli odds e odds ratio; *vi)* la variabile risposta categoriale con riferimento al modello generale di regressione logistica multipla.

Gli argomenti trattati a livello teorico sono affiancati dall'illustrazione di numerose applicazioni con l'utilizzo di dati reali e simulati che vengono sviluppate tramite l'ambiente statistico R, Rstudio utilizzando il marcatore di testo RMarkdown che permette di sviluppare analisi riproducibili. Nelle ultime due settimane di corso lo studente impara anche la semantica del software SAS per le analisi descrittive e per la stima del modello di regressione lineare multipla e logistica principalmente attraverso le procedure proc sgscatter, proc reg, proc glm, proc glmselect.

Prerequisiti

Si richiede di aver superato gli esami degli insegnamenti propedeutici: Statistica I, Analisi Matematica I, Algebra Lineare, Calcolo delle Probabilità. Per una più agevole comprensione dei contenuti del corso è fortemente consigliato conoscere le nozioni di inferenza statistica impartite al corso di Statistica II.

Metodi didattici

Sono previste lezioni frontali riguardanti la parte di teoria, queste vengono affiancate da esercitazioni pratiche. Tutte le lezioni si svolgono in laboratorio informatico: la parte di teoria viene affiancata allo sviluppo di applicazioni che riguardano dati multivariati riferiti a casi di studio sia reali che simulati e a diversi ambiti applicativi. Sono inoltre previste delle lezioni di tutoraggio affinché lo studente possa essere coadiuvato nell'apprendimento della teoria e nello svolgimento degli esercizi assegnati settimanalmente.

Durante le esercitazioni con l'ausilio di R nell'ambiente RStudio e dell'interfaccia RMarkdown lo studente impara il relativo linguaggio di programmazione e crea documenti riproducibili. Lo studente impara inoltre l'utilizzo del software SAS per le analisi dei dati e la stima dei parametri dei modelli statistici. Viene incentivato l'apprendimento cooperativo. Durante le esercitazioni lo studente viene incoraggiato a riconoscere la problematica dell'esercizio, e a individuare la metodologia più adatta, oltre che ad applicare le analisi e commentare i risultati.

Durante il periodo di emergenza Covid-19 le lezioni si svolgeranno in modalità da remoto (lezioni videoregistrate) con incontri periodici in videoconferenza tramite piattaforma webex secondo le calendarizzazioni previste dall'ateneo e che verranno rese note nella pagina del corso.

Modalità di verifica dell'apprendimento

L'esame è in forma scritta con orale facoltativo. Non sono previste prove intermedie. Le seguenti modalità di verifica dell'apprendimento sono valide sia per gli studenti frequentanti le lezioni in presenza che non frequentanti. L'esame scritto ha durata complessiva di un'ora e trenta minuti e si svolge presso il laboratorio informatico. Lo studente deve rispondere ai punti dell'esercizio utilizzando il computer. Questi riguardano sia la parte di teoria che l'applicazione delle analisi descrittive e dei modelli di regressione lineare multipla o logistica utilizzando dati reali o simulati forniti dal docente. Lo studente predispone un elaborato che deve essere riproducibile con commenti dettagliati rispetto al codice impiegato e ai risultati ottenuti. Domande riferite alla teoria sono inoltre presenti. Lo

svolgimento avviene tramite l'ambiente R oppure tramite il software SAS. *Durante la prova lo studente può disporre di tutto il materiale fornito per il corso, del codice illustrato durante le lezioni e le esercitazioni e del materiale personale (codice, appunti) utilizzato per l'apprendimento e lo svolgimento degli esercizi.* La prova permette la verifica delle nozioni teoriche e della capacità di comprensione del problema applicativo nonché di risoluzione dello stesso tramite l'analisi dei dati. Permette di valutare inoltre la capacità comunicativa tramite la creazione di un report.

La prova orale è facoltativa e riguarda sia la teoria che le applicazioni. Può essere richiesta da coloro che hanno un esito di almeno 18/30 alla prova scritta al momento della pubblicazione degli esiti. Questi ultimi vengono pubblicati sulla pagina di e-learning dedicata al corso.

Durante il periodo di emergenza Covid-19 a seconda delle disposizioni di ateneo l'esame si svolgerà in laboratorio informatico oppure in videoconferenza tramite la piattaforma webex.

Testi di riferimento

Il materiale didattico è costituito principalmente dalle dispense redatte dal docente riguardanti sia la parte teorica che le applicazioni. Tutto il materiale viene reso disponibile dal docente nella pagina della piattaforma e-learning dell'ateneo dedicata al corso. Il docente pubblica al termine di ogni lezione anche le slides, i programmi di calcolo, gli esercizi, i dati, e le soluzioni. Nella stessa pagina sono pubblicati alcuni testi d'esame degli anni precedenti. Il docente è disponibile settimanalmente per i colloqui con gli studenti secondo gli orari pubblicati settimanalmente nella pagina di e-learning del corso.

Durante il periodo di emergenza Covid-19 nella pagina del corso vengono anche pubblicate le videoregistrazioni delle lezioni.

I principali testi di riferimento sono elencati nella bibliografia delle dispense. Alcuni tra questi i seguenti:

Faraway, J. J. (2014). *Linear models in R*, Second Edition, Chapman & Hall, CRC Press.

Johnson, R. A., and Wichern, D. W. (2002). *Applied multivariate statistical analysis*, Pearson Education International, Prentice-Hall.

Hastie, T., D. & Tibshirani, R. (2013). *An introduction to statistical learning*, New York, Springer.

Nolan, D., & Lang, D. T. (2015). *Data Science in R: A Case Studies Approach to Computational Reasoning and Problem Solving*. Chapman & Hall, CRC Press.

Penloni, F. (2021). *Dispensa di Analisi Statistica Multivariata –Modulo Modelli Statistici- parte di teoria e applicazioni con R e SAS*. Dipartimento di Statistica e Metodi Quantitativi, Università degli Studi di Milano-Bicocca.

R Core Team (2021). R: A Language and Environment for Statistical Computing. R Foundation for Statistical Computing, Vienna, Austria. <https://www.R-project.org/>

SAS/STAT 9.4. PROC SGSCATTER, PROC CORR, PROC REG, PROC GLM, PROC GLMSELECT, *User's guide*, SAS Institute, 2012.

Periodo di erogazione dell'insegnamento

II Semestre, III Ciclo: febbraio - aprile 2021

Lingua di insegnamento

Il corso viene erogato in lingua italiana. Gli studenti Erasmus possono utilizzare il materiale didattico in Inglese e possono richiedere al docente che la prova d'esame sia svolta in lingua inglese.
