

Programa de Ensino

Curso: Mestrado Profissional em Economia

Disciplina: Aprendizagem Bayesiana

Perodo Letivo: 2020-1

Professor: Hedibert Freitas Lopes

Monitor: Thiago Mendonça

Ementa: O objetivo final desse curso é permitir ao egresso decidir criticamente entre o enfoque clássico ou Bayesiano, ou uma combinação de ambos, quando confrontado com problemas reais de tomada de decisão na presença de incerteza. Áreas onde esses problemas reais aparecem, como exemplos no curso, são microeconomia, macroeconomia, finanças, marketing quantitativo, entre várias outras. Com esse objetivo em mente, estudaremos os ingredientes básicos do paradigma Bayesiano: elaboração de binômio modelo-priori, comparação de modelos e combinação de modelos, aspectos computacionais e de tomada de decisão Bayesiana. Na segunda parte do curso serão introduzidos o enfoque Bayesiano para os tradicionais modelos de regressão linear e regressão logística, bem como suas versões modernas onde as prioris são tratadas como mecanismos regularizadores e indutores de esparsidade. Esparsidade estará presente ao longo da 2a e 3a partes do curso, quando tratarmos de modelos altamente dimensionais e/ou altamente complexos. Na terceira e última parte do curso, apresentamos vários modelos estatísticos utilizados atualmente para esse fim, tais como modelos de misturas, modelos hierárquicos, modelos fatoriais e modelos de árvores de regressão, além de modelos baseados em redes neurais e modelos que usam textos e documentos como dados (*text modeling*). Todos, vale dizer, sob o enfoque Bayesiano unificado e coerente. Todos os cálculos durante o curso serão feitos via o pacote estatístico R.

Conteúdo Programático:

- Ingredientes básicos de inferência, crítica aos modelos e computação
 - Distribuições a priori, a posteriori e preditiva
 - Bayes sequencial, análise conjugada e permutabilidade
 - Aspectos de teoria estatística de decisão
 - Fator de Bayes, mistura Bayesiana de modelos e critérios de informação
 - Métodos Monte Carlo (MC) e Monte Carlo via Cadeia de Markov (MCMC)
- Modelagem preditiva
 - Mistura de densidades: modelagem semi e não-paramétrica
 - Modelos hierárquicos: diferenciando níveis de agregação dos dados
 - Regularização: modelos de regressão linear e logística com muitas covariáveis
 - Modelos fatoriais: combinando redução de dimensionalidade e esparsidade
 - Árvores de regressão aditivas (BART): regressões não-lineares flexíveis
 - Redes neurais profundas: mais regressões não-lineares flexíveis
 - Modelos de tópicos: modelagem de textos

Avaliação:

- Participação: 10%
- Média listas de exercícios: 50%
- Projeto final: 40%

Bibliografia básica: (não recomendo a compra)

- MCMC: Stochastic Simulation for Bayesian Inference
Dani Gamerman and Hedibert F. Lopes
<http://www.dme.ufrj.br/mcmc>
- Statistical Inference: An Integrated Approach
Helio S. Migon, Dani Gamerman and Francisco Louzada-Neto
- Decision Theory: Principles and Approaches
G. Parmigiani and L. Inoue (with contribution by Hedibert F. Lopes)
- An Introduction to Statistical Learning with Applications in R
Gareth James, Daniela Witten, Trevor Hastie and Robert Tibshirani
<http://faculty.marshall.usc.edu/gareth-james/ISL/>
- Bayesian Statistics and Marketing
Greg M. Allenby, Peter E. Rossi and Rob McCulloch
- Data Science, Marketing & Business
Pedro J. Fernandez e Paulo C. Marques F.
<https://datascience.insper.edu.br/>

Bibliografia Complementar:

- Murphy (2012) Machine Learning: A Probabilistic Perspective
- Barber (2012) Bayesian Reasoning and Machine Learning
- Hastie, Tibshirani and Friedman (2001) The Elements of Statistical Learning
- Bishop (2006) Pattern Recognition and Machine Learning
- Hastie, Tibshirani and Wainwright (2015) Statistical Learning with Sparsity