

**CÓDIGO: PBEA7347**

**DISCIPLINA: Reconhecimento de Padrões e Aprendizado de Máquina**

Carga Horária Total: 60 horas

Créditos: 04

**Pré-requisitos:** 1. Álgebra Linear e Análise Matricial; 2. Introdução à Estatística Matemática; 3. Programação de Computadores

**Objetivo:**

Reconhecimento de Padrões e Aprendizado de Máquina Objetivo: Este curso introduz conceitos fundamentais, teorias e algoritmos para Reconhecimento de Padrões e Aprendizado de Máquina que são usados em visão computacional, processamento de imagens, reconhecimentos de vozes, mineração de dados, estatística e bioinformática.

**Ementa:**

Distribuições de Probabilidade; Modelos Lineares para Regressão; Modelos Lineares para Classificação; Redes Neurais; Métodos de Núcleo; Máquinas de Agrupamento Esparso; Modelos Gráficos; Modelos de Mistura e EM (Estimação-Maximização); Inferência Aproximada; Métodos de Amostragem; Variáveis Latentes Contínuas; Dados Sequenciais; Combinação de Modelos.

**Bibliografia:**

1. C.M. Bishop, "**Pattern Recognition and Machine Learning**", Springer, 2006 [Requerido]
2. R. Duda, P. Hart, D. Stork, "**Pattern Classification**", second edition, 2000. [Referência]
3. T. Hastie, R. Tibshurani, and J.H. Friedman, "**The Elements of Statistical Learning: Data Mining, Inference, and Prediction**", Spinger Series in Statistics, 2001. [Referência]
4. N. Cristianini and J. Shawe-Taylor, "**An Introduction to Support Vector Machines**", Cambridge Univ. Press, 2000. [Referência]
5. B. D. Ripley, "**Pattern Recognition and Neural Networks**", Cambridge University Press, 1996. [Referência]

**Recursos Adicionais:**

1. Sítio do Livro-Texto:  
<http://research.microsoft.com/en-us/um/people/cmbishop/PRML/>
2. Sítio do Software NetLab:  
<http://www.ncrg.aston.ac.uk/netlab/index.php>
3. Necessário ter o MatLab instalado.

**Programa:**

1. Introdução.
  - 1.1. Exemplo: Ajuste Polinomial de curvas;
  - 1.2. Teoria da Probabilidade
  - 1.3. Seleção de Modelo
  - 1.4. Maldição da Dimensionalidade
  - 1.5. Teoria da Decisão
  - 1.6. Teoria da Informação
2. Distribuições de Probabilidade
  - 2.1. Variáveis Binárias
  - 2.2. Variáveis Multinomiais
  - 2.3. A Distribuição Gaussiana
  - 2.4. A Família Exponencial
  - 2.5. Métodos Não-Paramétricos
3. Modelos Lineares para Regressão;
  - 3.1. Modelos de Função Base Linear
  - 3.2. A Decomposição Tendência-Variância
  - 3.3. Regressão Linear Bayesiana
  - 3.4. Comparação Bayesiana de Modelos
  - 3.5. A Aproximação de Evidências (Método de Bayes Empírico)
  - 3.6. Limitações das Funções de Bases Fixas
4. Modelos Lineares para Classificação
  - 4.1. Funções Discriminantes
  - 4.2. Modelos Geradores Probabilísticos
  - 4.3. Modelos Discriminadores Probabilísticos
  - 4.4. A Aproximação de Laplace
  - 4.5. Regressão Logística Bayesiana
5. Redes Neurais
  - 5.1. Funções de Redes Pró-Alimentadas (Feedforward)
  - 5.2. Treinamento de Redes
  - 5.3. Retropropagação de Erros
  - 5.4. A Matriz Hessiana
  - 5.5. Regularização em Redes Neurais
  - 5.6. Redes de Mistura de Densidades

- 5.7. Redes Neurais Bayesianas
- 6. Métodos de Núcleo
  - 6.1. Representações Duais
  - 6.2. Construindo Núcleos
  - 6.3. Redes de Funções Base-radial
  - 6.4. Processos Gaussianos
- 7. Máquinas de Núcleos Esparsos;
  - 7.1. Classificadores de Margem Máxima
  - 7.2. Máquina de Vetor Relevância
- 8. Modelos Gráficos
  - 8.1. Redes Bayesianas
  - 8.2. Independência Condicional
  - 8.3. Campos Randômicos de Markov
  - 8.4. Inferência no Modelo Gráfico
- 9. Modelos de Mistura e EM (Estimação-Maximização)
  - 9.1. Agrupamento por K-Médias
  - 9.2. Mistura de Gaussianas
  - 9.3. Uma visão alternativa do EM
  - 9.4. O algoritmo EM em geral
- 10. Inferência Aproximada
  - 10.1. Inferência Variacional
  - 10.2. Ilustração: Mistura Variacional de Gaussianas
  - 10.3. Regressão Linear Variacional
  - 10.4. A Família Exponencial
  - 10.5. Métodos Variacionais Locais
  - 10.6. Regressão Logística Variacional
  - 10.7. Propagação do Valor Esperado
- 11. Métodos de Amostragem
  - 11.1. Algoritmos Básicos de Amostragem
  - 11.2. Cadeias de Markov Monte Carlo
  - 11.3. Amostragem de Gibbs
  - 11.4. Amostragem por partes
  - 11.5. O Algoritmo Monte Carlo Híbrido
- 12. Variáveis Latentes Contínuas
  - 12.1. Análise de Componentes Principais (PCA)
  - 12.2. PCA Probabilística
  - 12.3. PCA Núcleo
  - 12.4. Modelos de Variáveis Latentes Não-Lineares
- 13. Dados Sequenciais
  - 13.1. Modelos de Markov
  - 13.2. Modelos de Markov Ocultos
  - 13.3. Sistemas Dinâmicos Lineares
- 14. Combinação de Modelos.
  - 14.1. Média de Modelos Bayesiano
  - 14.2. Comitês
  - 14.3. Algoritmo Boosting
  - 14.4. Modelos Baseados em Árvores
  - 14.5. Modelos Mistura Condicionais