

Introdução a ***Machine Learning***

Nina S. T. Hirata

(nina@ime.usp.br)

Departamento de Ciência da Computação

Instituto de Matemática e Estatística

(IME - USP)

Maio / 2017

Departamento de Ciência da Computação (IME)

Bacharelado em Ciência da Computação

MACxxx - Introdução à computação
(Poli, IF, IAG, IGc, FEA, IO, Moleculares, ICB)

Processamento e análise de imagens

Machine learning

Colaboração com o IAG

NAP LabCosmos (coord. Profa. Cláudia Oliveira)

- Separação de estrelas e quasares (ALHAMBRA)
- Classificação de imagens de galáxias
- Deblending de pixels em imagens

Pesquisas em imagens em machine learning

Aplicações:

- classificação de imagens de plâncton
- imagens de telescópio óptico
- imagens de documentos
- imagens de comics
- expressões matemáticas manuscritas
- imagens de retina (vasos sanguíneos)
- detecção de QR codes

Exemplos de problemas tratados com ML

- Reconhecer objetos, pessoas, etc, em imagens
- Reconhecer texto/escrita
- Reconhecer falas e sons
- diagnóstico médico
- qual anúncio publicar no meu site ?
- identificar prenúncios de um desastre natural

Evolução ao longo dos anos ...

Fascínio por máquinas inteligentes / ficção

Escritórios (documentos) / indústria (linha de produção)

Avanço em tecnologia de processamento de dados – computação eficiente

Avanço em tecnologia de sensores – abundância de dados

Veículos autônomos, tradutores simultâneos, jogadores (xadrez, go, etc)

Big data, eScience

- Volume
- Velocity
- Variety
- Veracity / Variability
- Value

Desafio: Extrair informação útil ou conhecimento a partir do volume de dados

Estatística e machine learning desempenham papel importante nesse processo

O que é *Machine learning*

- 1. Contexto** (estudo em questão)
- 2. Recorte** X dentro do contexto: observação + informação (conhecimento sobre a observação)
 - observações (entrada \mathbf{x})
 - estado, identidade, ação (saída y) – conhecimento
- 3. Suposição:** existe uma relação entre X e y
- 4. Objetivo:** determinar a relação entre X e y , de tal forma que dado um elemento x qualquer de X eu consiga prever a saída correspondente y

Recorte: classificação de imagens de plâncton

Espaço *X*: imagens de plâncton




Appendicularia




Bubble




Calanoida



Dinoflagellate




Dinoflagellate M



Chaetoceros




Cnidaria



Copepoda




Coscinodiscus




Cyclopoida



Detritus



Detritus ball




Filaments




Nauplii




Noctiluca



Penilia




P. Dactylosolen



Stalked c.

Conceitos

Extrair *features*: converter representação RAW para outra $\rightarrow (x_1, x_2, \dots, x_n)$



- informação de forma, cor, textura, ...

Modelar a relação:

- y dado \Rightarrow supervisionado (classificação, regressão)
- y não dado \Rightarrow não-supervisionado (clustering)

Supervised Classification

Entrada: *features* (atributos)

$$\mathbf{x} = (x_1, x_2, \dots, x_n) \in \mathbb{R}^n$$

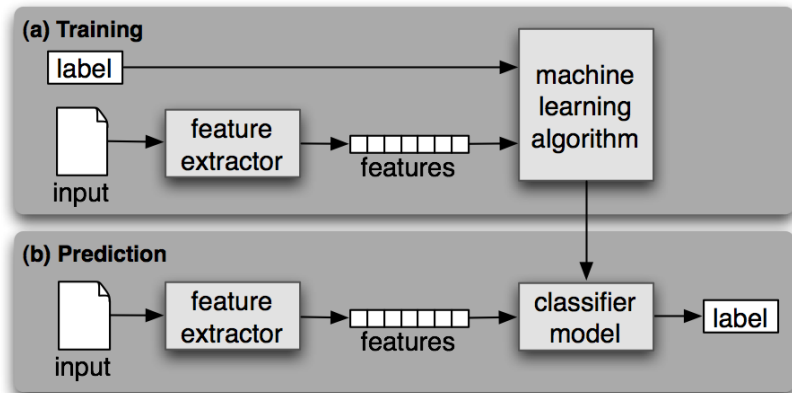
Saída:

- Classificação: rótulo de classe $y \in Y = \{1, 2, \dots, c\}$
- Regressão: um valor $y \in Y = \mathbb{R}$

Conjunto de exemplos de treinamento

$$S = \{(\mathbf{x}_i, y_i) : i = 1, 2, \dots, N\}$$


Treinamento / predição



<http://www.nltk.org/book/ch06.html>

Regressão


$n = 1$



Classificação × regressão


Classificação: encontrar uma fronteira de decisão

Regressão: ajustar uma curva/superfície aos dados



$n = 2$ e $n = 1$, resp

Regressão



$$n = 2$$

Prática

1. abrir o arquivo `html/main.html` no browser
2. item 2.A
3. abrir o notebook `practice_basics.ipynb`
4. executar o notebook `practice_basics.ipynb`
(mesmo conteúdo de 2.A)

Função linear de uma variável

$$x \in \mathbb{R}$$

$$h(x) = w_0 + w_1 x_1$$

$$\mathbf{x} = (1, x) \in \mathbb{R}^2$$


$$\mathbf{w} = (w_0, w_1)$$

$$h(\mathbf{x}) = \mathbf{w}^T \mathbf{x}$$

Regressão linear

Linear Regression

$$y = w_0 + w_1 X$$



Regressão linear

$$(x_1, x_2, \dots, x_n) \implies (1, x_1, x_2, \dots, x_n) \in \mathbb{R}^{n+1}$$

$\mathbf{w} = (w_0, w_1, \dots, w_n) \in \mathbb{R}^{n+1}$ vetor de pesos

$$h_{\mathbf{w}}(\mathbf{x}) = w_0 + w_1 x_1 + w_2 x_2 + \dots + w_n x_n = \sum_{j=0}^n w_j x_j$$

$$h_{\mathbf{w}}(\mathbf{x}) = \mathbf{x}^T \mathbf{w}$$

Queremos $h_{\mathbf{w}}(\mathbf{x}_i) \approx y_i$

Uma ideia simples:

1. chutar um vetor de pesos qualquer \mathbf{w}
2. verificar se a função linear se ajusta adequadamente
3. se sim, terminar
4. senão, alterar ligeiramente a função linear (i.e., \mathbf{w}) e voltar para o passo 2

Mas até quando repetir isso?

Se $z_i = h_{\mathbf{w}}(\mathbf{x}_i) = \mathbf{x}_i^T \mathbf{w}$

queremos que a diferença entre y_i e z_i seja a menor possível.

Essa diferença pode ser expressa, por exemplo, por

$$\begin{aligned} SSR_D(\mathbf{w}) &= \sum_{\mathbf{x}_i \in D} (y_i - z_i)^2 \\ &= \sum_{\mathbf{x}_i \in D} (y_i - \mathbf{x}_i^T \mathbf{w})^2 \end{aligned}$$

Problema: queremos encontrar o ponto \mathbf{w} que minimiza SSR_D

Método do gradiente descendente

Função custo

$$J_D(\mathbf{w}) = \frac{1}{2} \sum_{\mathbf{x}_i \in D} (y_i - z_i)^2$$

É uma função quadrática positiva; logo tem ponto de mínimo

Gradiente descendente: Método de otimização de função, que consiste em:

- chutar um valor para \mathbf{w}
- calcular o vetor gradiente de J_D em \mathbf{w}
- alterar \mathbf{w} na direção oposta ao do vetor gradiente

Método do gradiente descendente

Vetor gradiente de J :

$$\nabla J(\mathbf{w}) = \left[\frac{\partial J}{\partial w_0}, \frac{\partial J}{\partial w_1}, \dots, \frac{\partial J}{\partial w_n} \right]$$

$$\begin{aligned} \frac{\partial J}{\partial w_j} &= \frac{\partial}{\partial w_j} \frac{1}{2} \sum_i (y_i - z_i)^2 \\ &= \frac{1}{2} \sum_i \frac{\partial}{\partial w_j} (y_i - z_i)^2 \\ &= \frac{1}{2} \sum_i 2(y_i - z_i) \frac{\partial}{\partial w_j} (y_i - z_i) \\ &= \sum_i (y_i - z_i) \frac{\partial}{\partial w_j} (y_i - (w_0 + w_1 x_{i1} + \dots + w_j x_{ij} + \dots + w_n x_{in})) \\ &= - \sum_i (y_i - z_i) x_{ij} \end{aligned}$$

Método do gradiente descendente

Peso inicial: $\mathbf{w}(0)$


Regra de atualização:

$$\mathbf{w}(r + 1) = \mathbf{w}(r) + \eta \Delta \mathbf{w}(r)$$

$$\Delta \mathbf{w}(r) = -\nabla J(\mathbf{w})$$

$$\Delta w_j(r) = \sum_i (y_i - z_i) x_{ij}$$

Método do gradiente descendente



Regressão linear: resumo

- Ajustar uma função linear aos dados pode ser modelado como um problema de minimizar uma função custo J_D expressa em termos da soma do quadrado dos resíduos (RSS).
- Para cada função linear, caracterizado por um vetor de pesos \mathbf{w} específico, há um custo $J_D(\mathbf{w})$ associado
- O ponto de mínimo pode ser calculado usando-se o método do gradiente descendente

Prática

1. item 2.B

2. abrir e executar o notebook

`practice_regression.ipynb`

Classificação

Problema que queremos resolver: dado um conjunto de amostras, encontrar uma fronteira de decisão que melhor separe as duas classes.

Pontos a serem considerados:

- que tipo de fronteira de decisão ?
- qual o significado de “melhor separação” ?
- quantas classes são ?
- etc

Classificação

$y = 0$: exemplo **negativo**


$y = 1$: exemplo **positivo**

Podemos aplicar a regressão linear e decidir da seguinte forma ?

$$z = \begin{cases} 1, & \text{se } h_{\mathbf{w}}(\mathbf{x}) > 0, \\ 0, & \text{se } h_{\mathbf{w}}(\mathbf{x}) \leq 0. \end{cases}$$


Pergunta: é uma boa solução ?

Parece que não ...



Em problemas de classificação, podemos usar a regressão logística


Logistic Regression: 1 Feature



Função logística

Função logística (sigmoide):

$$s(x) = \frac{1}{1 + e^{-x}}$$



$$0 \leq s(x) \leq 1$$

Função custo

Regressão linear

$$J_D(\mathbf{w}) = \frac{1}{2} \sum_{\mathbf{x}_i \in D} (y_i - \mathbf{w}^T \mathbf{x}_i)^2$$

Classificação: poderia ser essa ?

$$J_D(\mathbf{w}) = \frac{1}{2} \sum_{\mathbf{x}_i \in D} (y_i - s(\mathbf{w}^T \mathbf{x}_i))^2$$

Função logística como probabilidade

$$h_{\mathbf{w}}(\mathbf{x}) = \mathbf{x}^T \mathbf{w} = \sum_{j=0}^n w_j x_j$$

$$g_0(\mathbf{x}) = s(h_{\mathbf{w}}(\mathbf{x})) = \frac{1}{1 + e^{-h_{\mathbf{w}}(\mathbf{x})}}$$

$$g_0(\mathbf{x}) = 1 - g_1(\mathbf{x})$$

$$h_{\mathbf{w}}(\mathbf{x}) = 0 \iff g_0(\mathbf{x}) = g_1(\mathbf{x}) = 0.5$$

$$h_{\mathbf{w}}(\mathbf{x}) < 0 \iff g_0(\mathbf{x}) > g_1(\mathbf{x})$$

$$h_{\mathbf{w}}(\mathbf{x}) > 0 \iff g_0(\mathbf{x}) < g_1(\mathbf{x})$$

Regressão logística

Função de verossimilhança

$$L(\mathbf{w}) = \prod_{i=1}^N P(y_i | \mathbf{x}_i, \mathbf{w}) = \prod_{i=1}^N [g_1(\mathbf{x}_i)]^{y_i} [1 - g_1(\mathbf{x}_i)]^{(1-y_i)}$$

Função de custo: O ponto de máximo da função L é o ponto de mínimo da função


$$J(\mathbf{w}) = -\ln L(\mathbf{w})$$

Assim, pelo método do gradiente descendente obtém-se:

$$\Delta w_j(r) = \sum_{i=1}^N (y_i - g_1(\mathbf{x}_i)) \mathbf{x}_{ij}$$

Regressão logística: resumo

- Usado para encontrar uma fronteira de decisão linear para problemas de classificação
- O valor $h_{\mathbf{w}}(\mathbf{x})$ é modulado pela sigmoide s de forma que fique no intervalo $[0, 1]$ antes do cálculo da distância até y
- O vetor de peso \mathbf{w} pode ser obtido aplicando-se o método do gradiente descendente ao log da função de verossimilhança
- A fronteira de decisão resultante é linear



Fronteiras de decisão não lineares

1. Criar novas *features*

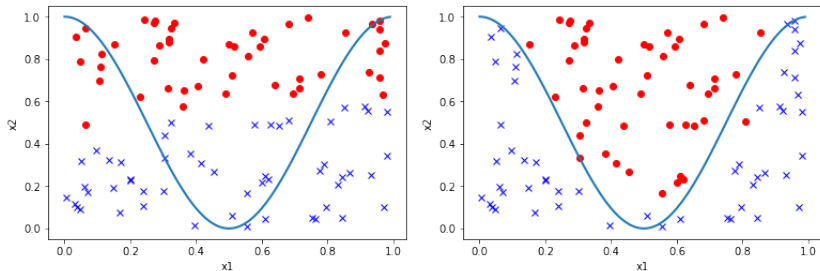
Exemplo: $(1, x_1, x_2) \implies (1, x_1, x_2, x_1^2, x_1 x_2, x_2^2)$

$n = 2$ passa para $n' = 5$

e aplicar a regressão logística

2. Usar modelos não-lineares (ex.: rede neural)

Fronteiras de decisão não lineares



linear \times não linear (SVM)

Prática

1. item 2.C

2. abrir e executar o notebook

`practice_classification1.ipynb`

3. abrir e executar o notebook

`practice_classification2.ipynb`

Prática – scikitlearn

<http://scikit-learn.org/>

1. item 2.D e 2.E
2. abrir e executar o notebook
`practice_scikitlearn.ipynb`
3. abrir e executar o notebook
`mais_scikitlearn.ipynb`

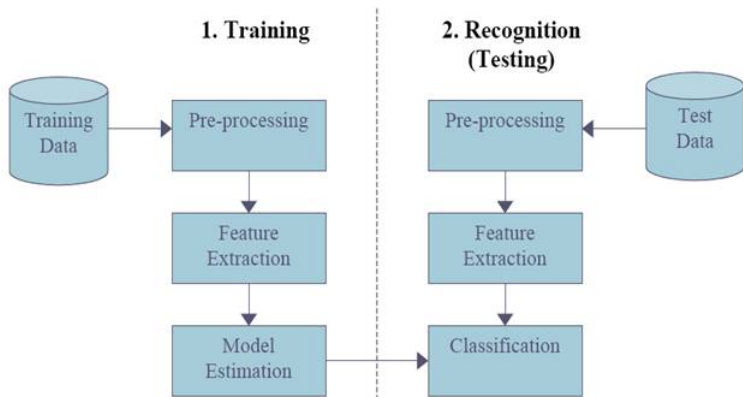


Figure 2: The pattern classification process