

# CC-226 Introdução à Análise de Padrões

## Visão Geral do Reconhecimento de Padrões

Carlos Henrique Q. Forster<sup>1</sup>

<sup>1</sup>Divisão de Ciência da Computação  
Instituto Tecnológico de Aeronáutica

25 de fevereiro de 2008

- 1 Aplicações da Análise de Padrões
- 2 Exemplo de problema de classificação automática
- 3 Reconhecimento de padrões
  - Preprocessamento
  - Extração de feições
  - Classificação
  - Questões sobre a classificação e pós-processamento
- 4 Código-exemplo
- 5 Tarefa
- 6 Leituras Complementares

## Aplicações típicas de percepção por máquina

- reconhecimento de fala
- identificação de impressão digital
- reconhecimento óptico de caracteres
- identificação de seqüências de DNA
- avaliação de risco de crédito
- busca de imagens semelhantes num base de dados
- categorização automática de documentos
- "mineração de dados"de forma geral

# Exemplo do Duda e Hart

Uma fábrica de empacotamento de peixes deve selecionar automaticamente os peixes como "salmão" ou "corbina" (sea bass)



# Atributos (features) dos peixes

Decidiu-se por utilizar uma câmara e medir diferenças físicas entre os tipos de peixe.

Alguns atributos:

- comprimento
- brilho
- largura
- número de barbatanas
- posição da boca
- ...

- As classes "Salmão" e "Corbina" são descritas por modelos criados a partir das observações que fizemos.
- Esses modelos são descrições matemáticas.
- O reconhecimento de padrões consiste em criar uma hipótese de qual modelo é mais adequado para um padrão observado.

# Fases do reconhecimento de padrões

- Préprocessamento
- Extração de feições (atributos, propriedades ou características)
- Classificação

- Remoção de ruído (exemplo: filtragem da imagem)
- Segmentação (exemplo: limiarização da imagem para remover o fundo)
- Normalização (exemplo: ajustar automaticamente o nível da luz para aferir o brilho)




Medindo algumas feições de um conjunto de amostras para treinamento:

- Comprimento (maior extensão do segmento da imagem do peixe)
- Largura (extensão na direção ortogonal do comprimento)
- Brilho (intensidade média da imagem do peixe)

Estudar o valor dessas feições


- Histograma do comprimento das amostras de peixe para cada classe

# Histograma do comprimento




É útil essa medida de comprimento?

# Histograma do comprimento




É útil essa medida de comprimento?

# Histograma do brilho



E essa medida do brilho?

# Histograma do brilho




E essa medida do brilho?

Pode-se utilizar uma tupla com várias medidas de feições para caracterizar um padrão. Esse vetor pode ser chamado vetor de atributos.


$$\mathbf{x} = \begin{pmatrix} x_1 \\ x_2 \\ \vdots \\ x_l \end{pmatrix}$$

# Scatterplot para dois atributos



Como eu posso definir um mecanismo para classificar peixes dadas medidas desses dois atributos?


# Scatterplot para dois atributos



Como eu posso definir um mecanismo para classificar peixes dadas medidas desses dois atributos?




# Classificador linear



Utilizar a equação de uma reta para separar.

# Classificador linear



Utilizar a equação de uma reta para separar.

A equação da superfície de separação no caso bidimensional:

$$w_1 \cdot x_1 + w_2 \cdot x_2 + w_3 = 0$$

Na forma matricial (utilizando multiplicação de matrizes):

$$\begin{pmatrix} w_1 & w_2 & w_3 \end{pmatrix} \begin{pmatrix} x_1 \\ x_2 \\ 1 \end{pmatrix} = 0$$

ou simplesmente, (produto interno de vetores)

$$\mathbf{w}^T \mathbf{x} = 0$$

A equação da superfície de separação no caso bidimensional:

$$w_1 \cdot x_1 + w_2 \cdot x_2 + w_3 = 0$$

Na forma matricial (utilizando multiplicação de matrizes):

$$\begin{pmatrix} w_1 & w_2 & w_3 \end{pmatrix} \begin{pmatrix} x_1 \\ x_2 \\ 1 \end{pmatrix} = 0$$

ou simplesmente, (produto interno de vetores)

$$\mathbf{w}^T \mathbf{x} = 0$$

A equação da superfície de separação no caso bidimensional:

$$w_1 \cdot x_1 + w_2 \cdot x_2 + w_3 = 0$$

Na forma matricial (utilizando multiplicação de matrizes):

$$\begin{pmatrix} w_1 & w_2 & w_3 \end{pmatrix} \begin{pmatrix} x_1 \\ x_2 \\ 1 \end{pmatrix} = 0$$

ou simplesmente, (produto interno de vetores)

$$\mathbf{w}^T \mathbf{x} = 0$$

Decido que pertence a uma das classes se

$$\mathbf{w}^T \mathbf{x} < 0$$

ou que pertence à outra classe se

$$\mathbf{w}^T \mathbf{x} > 0$$

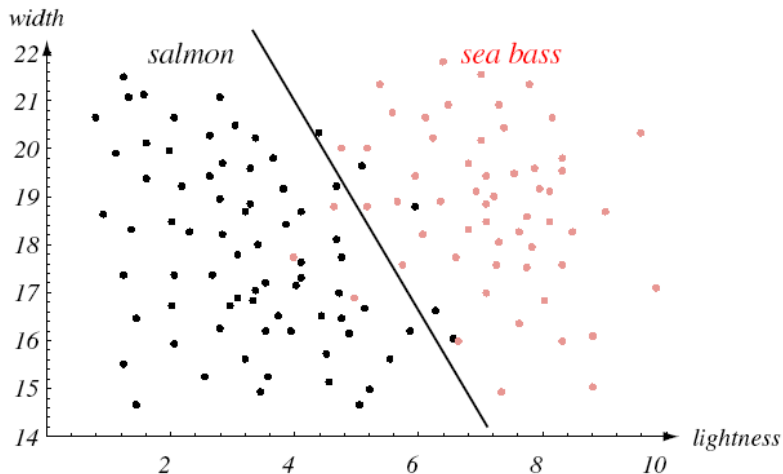
Dado um conjunto de  $N$  vetores  $\mathbf{x}_j$  para treinamento, encontramos o vetor de parâmetros  $\mathbf{w}$  que define a regra de decisão do classificador.

## Questões adicionais

- O que eu faço se a corbina for muito mais cara que o salmão?
- O que eu faço com atributos correlatos (e redundantes) como largura e comprimento?
- De forma geral, como sei se um novo atributo é bom ou não dados os outros atributos que já tenho?
- Quantos atributos devo utilizar? E se utilizar muitos?
- Como devo treinar e avaliar o classificador?

# Generalização

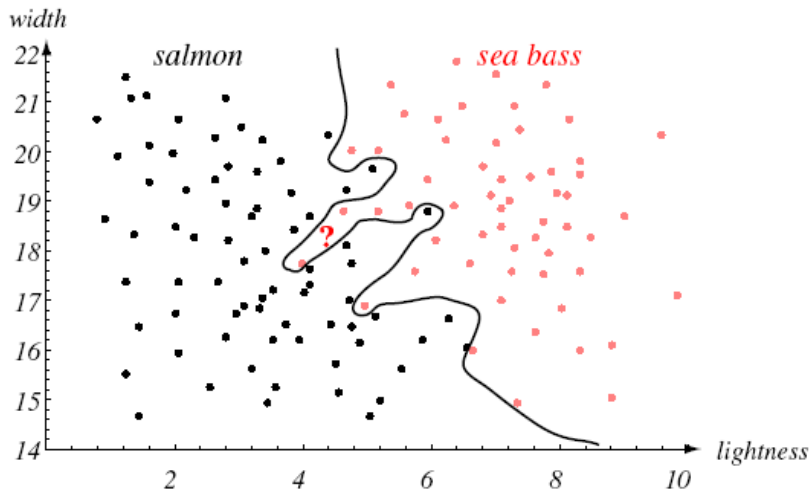
Qual classificador é melhor? Este?





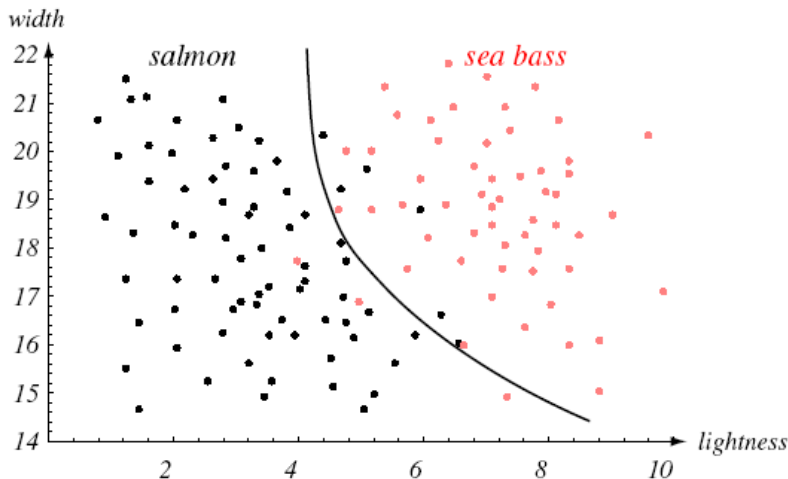
# Generalização

Ou este?

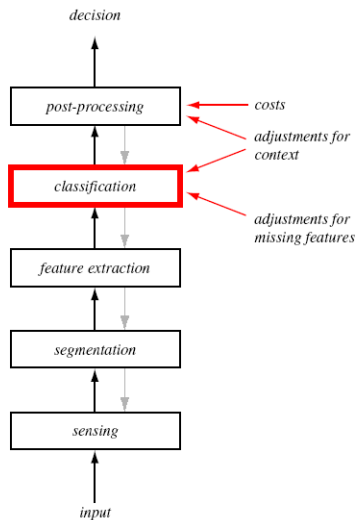


# Classificador ótimo

Esse classificador pondera simplicidade do classificador (princípio da parcimônia, Occam's Razor) e taxa de acerto no conjunto de treinamento.



# Sistema de reconhecimento de padrões



# Código MATLAB do nosso classificador linear

```
% "leitura" dos dados
% no caso são dados artificiais
% obtidos de distribuicoes normais
randn('seed',0);
corb_len=(randn(100,1)*10+18);
salmon_len=(randn(100,1)*13+15);
corb_len=corb_len-min(corb_len)+2;
salmon_len=salmon_len-min(salmon_len)+2;
corb_lig=(randn(100,1));
salmon_lig=(randn(100,1));
corb_lig=corb_lig-min(corb_lig)+4;
salmon_lig=salmon_lig-min(salmon_lig);
```

```
figure;  
%% histograma da distribuicao do comprimento  
hist([corb_len, salmon_len]);  
xlabel('length');  
ylabel('count');  
legend('corbina', 'salmon');
```

```
figure;  
%% histograma da distribuicao do brilho  
hist([corb_lig,salmon_lig]);  
xlabel('lightness');  
ylabel('count');  
legend('corbina','salmon');
```

```
figure; %% scatter
plot(corb_len, corb_lig, 'bo',
     salmon_len, salmon_lig, 'r. ');
xlabel('length');
ylabel('lightness');
legend('corbina', 'salmon');
```

```
figure; %% classificador linear
plot(corb_len, corb_lig, 'bo',
      salmon_len, salmon_lig, 'r. '); hold;
xlabel('length');
ylabel('lightness');
legend('corbina', 'salmon');
a=[corb_len, corb_lig, ones(100,1);
   salmon_len, salmon_lig, ones(100,1)];
b=[ones(100,1); -ones(100,1)];
x=pinv(a)*b;
plot([0, 75],
      [-x(3)/x(2), -x(3)/x(2)-x(1)*75/x(2)],
      'g-');
```



## EX001

Entender o código dos slides anteriores e explicar como foi encontrada a reta de decisão (ou separação) para o modelo das classes.

- Duda, Hart e Stork. Primeiro capítulo.
- Jain et al., Statistical Pattern Recognition: A Review