

# Tema 05

## Estimação de Erro

Professora:  
Ariane Machado Lima

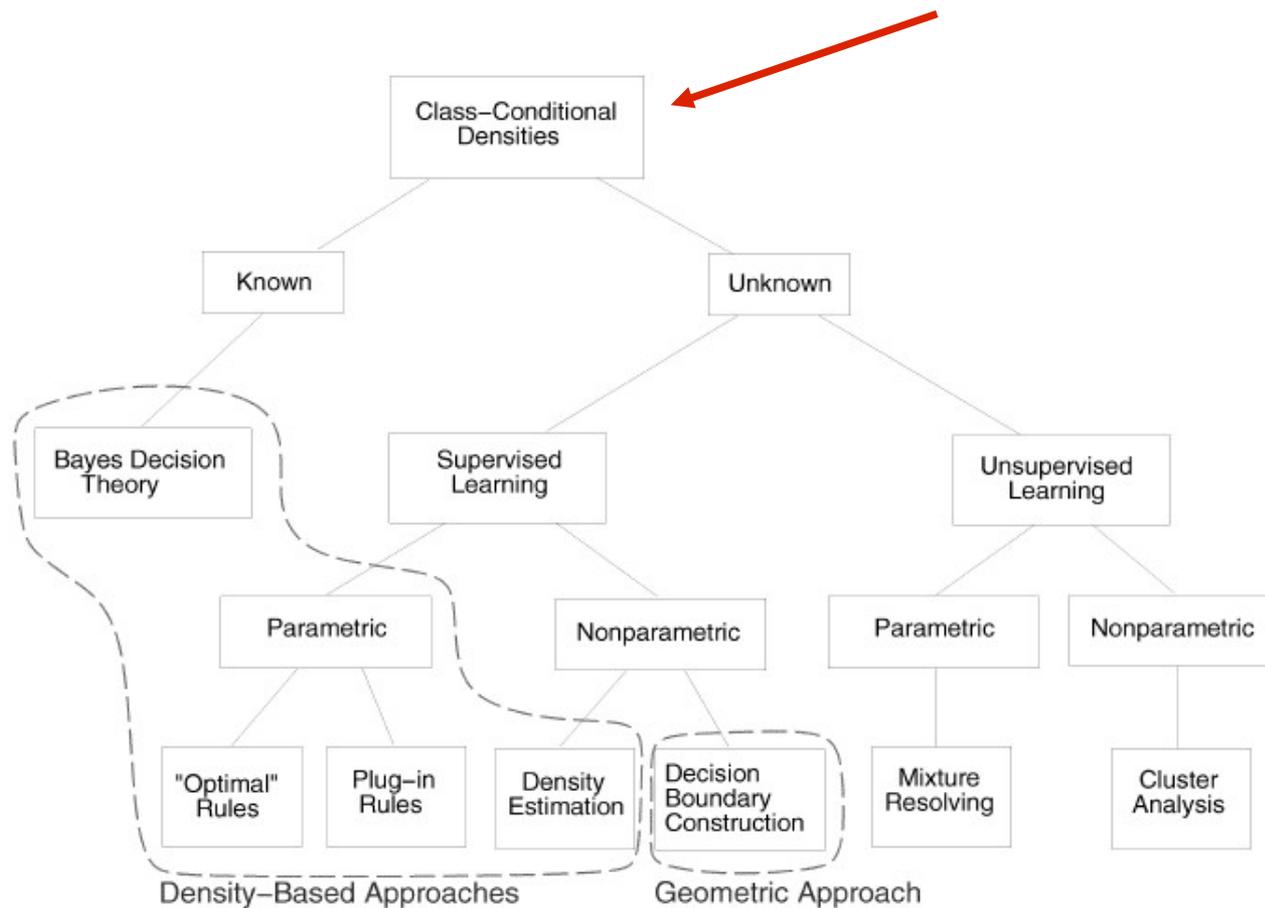


# Classificação

Vimos na aula anterior que, se você conhece as densidades condicionais das classes envolvidas ( $P(x|c)$ ), o classificador Bayesiano deve ser usado pois ele é o que fornece MENOR erro (classificador ÓTIMO).



# Técnicas de Classificação



[JAIN et al, 2000]



# Problema

- Normalmente não conhecemos as probabilidades condicionais  $P(\cdot | c_i)$
- Neste caso temos que estimá-las a partir de dados conhecidos, o que pode ser complexo



# Alternativas

- Nestes casos, temos que optar por um classificador mais simples
- Por ex: escolher uma família de densidades conhecida, ou seja, com uma forma matemática conhecida e um número finito de parâmetros. Daí basta estimar os parâmetros (ex. Normal, Poisson, ...)
- 
-

# Alternativas

- Nestes casos, temos que optar por um classificador mais simples
- Por ex: escolher uma família de densidades conhecida, ou seja, com uma forma matemática conhecida e um número finito de parâmetros. Daí basta estimar os parâmetros (ex. Normal, Poisson, ...)
  - **CLASSIFICADOR PARAMÉTRICO**



# Alternativas

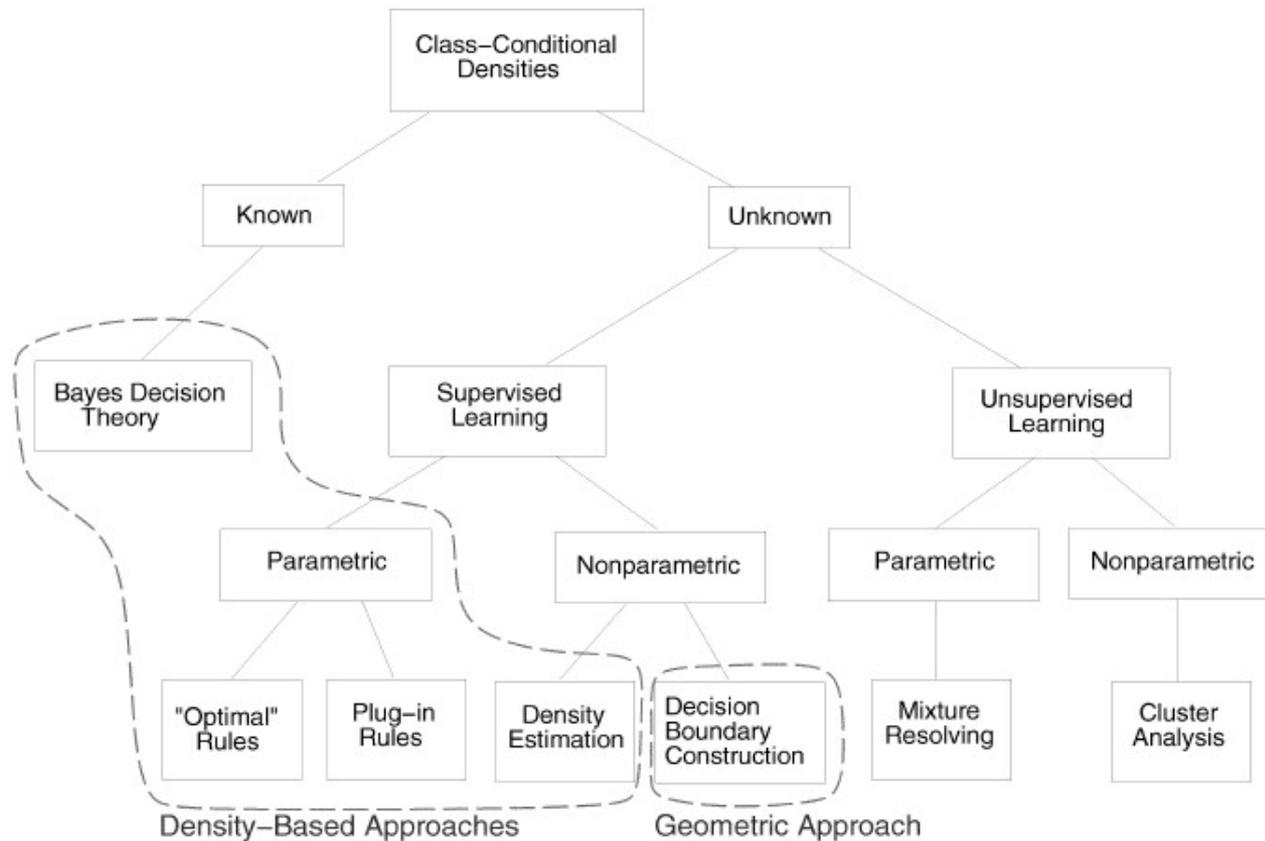
- Nestes casos, temos que optar por um classificador mais simples
- Por ex: escolher uma família de densidades conhecida, ou seja, com uma forma matemática conhecida e um número finito de parâmetros. Daí basta estimar os parâmetros (ex. Normal, Poisson, ...)
  - **CLASSIFICADOR PARAMÉTRICO**
- Quando não é possível escolher uma forma matemática então opta-se por um **CLASSIFICADOR NÃO PARAMÉTRICO**



# Métodos de construção de um classificador

- Aprendizado supervisionado: o modelo é aprendido a partir de amostras rotuladas (com sua classificação)
  - Amostra de treinamento:  
 $X = \{(x,c) \mid x \text{ é um exemplo e } c \text{ é sua classe}\}$
- Aprendizado não supervisionado: a classificação é feita a partir de dados não rotulados

# Métodos de Classificação



[JAIN et al, 2000]

# Como avaliar um classificador?



# Como avaliar um classificador?

- Taxa de erro
- Difícil obter uma expressão analítica
- Para regras de treinamento consistentes, a taxa de erro se aproxima do erro de Bayes à medida que cresce o tamanho da amostra de treinamento
- Na prática, como estimar o erro?
- Se eu tenho uma determinada amostra rotulada, tenho que treinar e estimar o erro. Como faço?



# Estimação de erro de um classificador

- Uma amostra para treinar e uma amostra para testar
- Os erros na amostra de teste são uma estimativa do erro
- As amostras de treinamento e de teste deveriam ser:
  - Grandes
  - Independentes
  - Mas nem sempre conseguimos...
- Como utilizar uma dada amostra para isso?
  - Vários métodos de estimação de erro



# Métodos de estimação de erro de um classificador

- Resubstituição
- Holdout
- Leave-one-out
- Rotação ou k-fold cross-validation (validação cruzada k-vezes)
- Bootstrap

# Resubstituição

- Toda a amostra original é usada para treinamento e depois para teste
- Problema?



# Resubstituição

- Toda a amostra original é usada para treinamento e depois para teste
- Fornece uma estimativa otimista do erro
- Não revela se está havendo *overfitting*
- Quanto menor a amostra de treinamento, pior a estimativa
- Pior opção



# Holdout

- Uma parte da amostra original é usada para treinamento e o restante para teste (não necessariamente 50%)
- Problema:

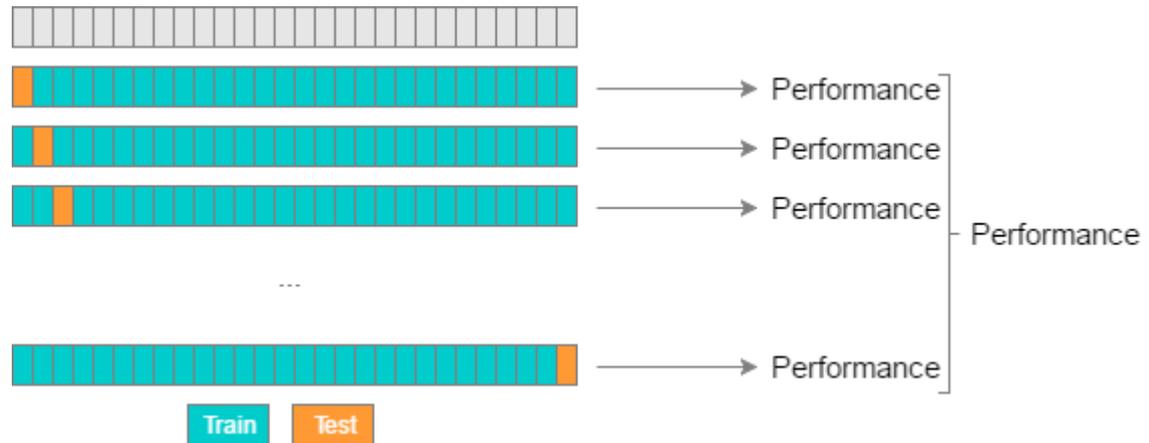


# Holdout

- Uma parte da amostra original é usada para treinamento e o restante para teste (não necessariamente 50%)
- Problema: diferentes divisões provavelmente darão diferentes estimativas

# Leave-one-out

- Se a amostra original tem  $n$  dados, treina com  $n-1$  dados e testa no que restou
- Repetir o processo  $n$  vezes, cada vez deixando um dado de fora para teste
- A estimativa de erro é a média do erro de cada rodada



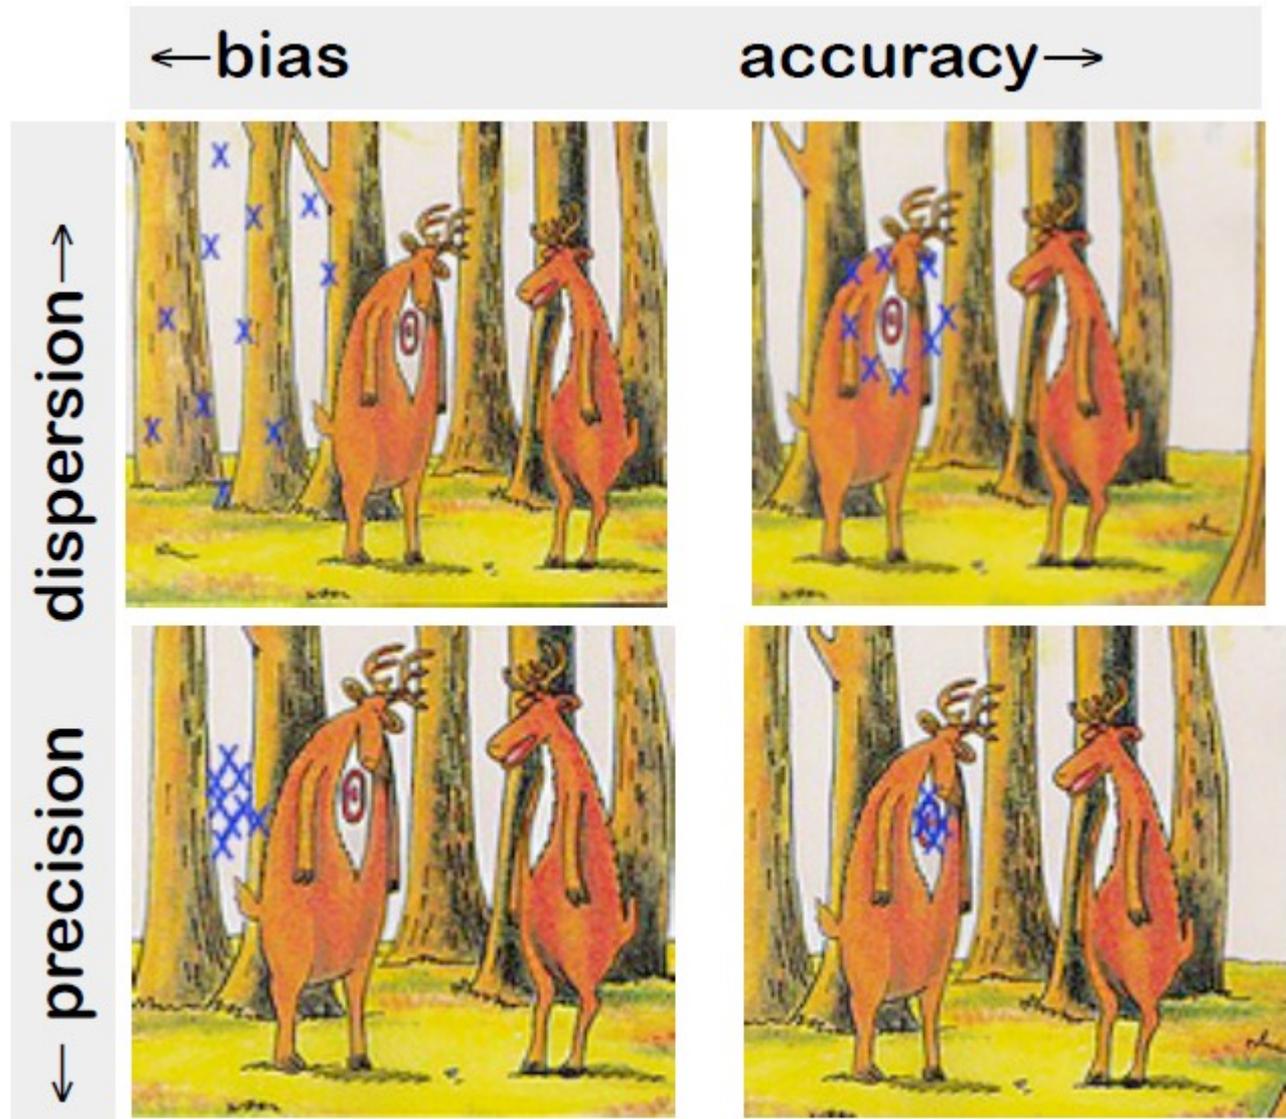
# Leave-one-out

- Estimativa menos enviesada
- Alta variância entre os  $n$  testes (erro = 0 ou 1)
- Alto custo computacional ( $n$  treinamentos e testes de classificadores)



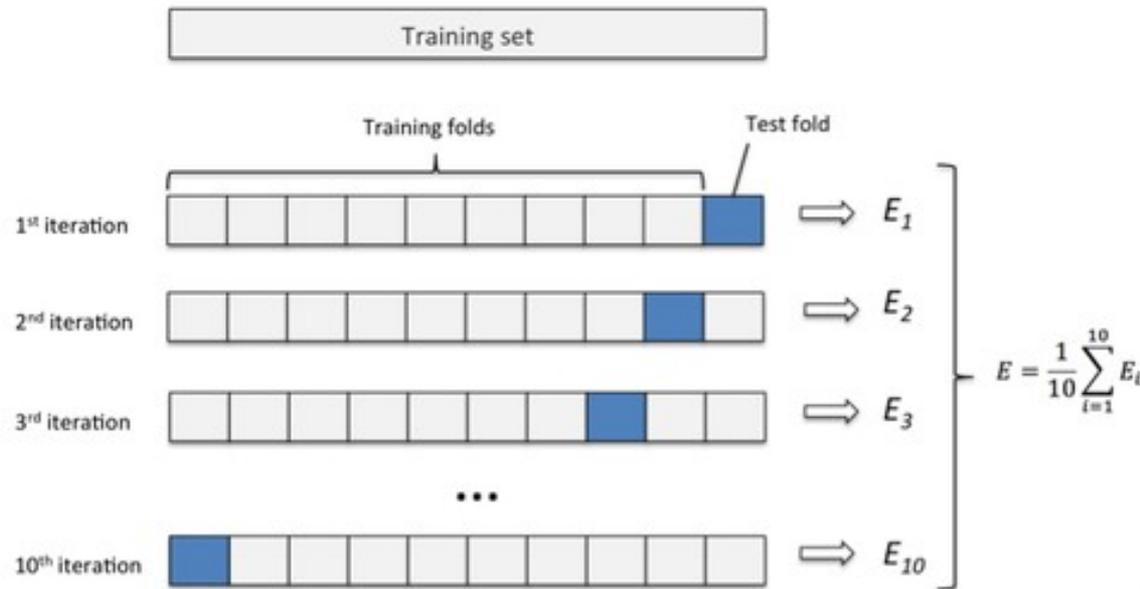
# Viés (bias) x variância

**Viés:** tendência  
(distorção) para  
um dado ponto;  
polarização.



# Validação cruzada k-vezes (k-fold cross-validation)

- Divida a amostra original em k ( $k < n$ ) partes
- Treina com k-1 partes, testa com a que sobrou
- Repetir o processo k vezes, cada vez deixando uma parte diferente de fora do treinamento (para teste)



# Validação cruzada k-vezes (k-fold cross-validation)

- Divida a amostra original em  $k$  ( $k < n$ ) partes
- Treina com  $k-1$  partes, testa com a que sobrou
- Repetir o processo  $k$  vezes, cada vez deixando uma parte diferente de fora do treinamento (para teste)

Balanco entre holdout e leave-one-out:

**Mais/menos?** enviesada que o holdout

**Mais/menos?** custoso que o leave-one-out

**Maior/menor?** variância que a do leave-one-out



# Validação cruzada k-vezes (k-fold cross-validation)

- Divida a amostra original em  $k$  ( $k < n$ ) partes
- Treina com  $k-1$  partes, testa com a que sobrou
- Repetir o processo  $k$  vezes, cada vez deixando uma parte diferente de fora do treinamento (para teste)

Balanco entre holdout e leave-one-out:

Menos enviesada que o holdout

**Mais/menos?** custoso que o leave-one-out

**Maior/menor?** variância que a do leave-one-out



# Validação cruzada k-vezes (k-fold cross-validation)

- Divida a amostra original em  $k$  ( $k < n$ ) partes
- Treina com  $k-1$  partes, testa com a que sobrou
- Repetir o processo  $k$  vezes, cada vez deixando uma parte diferente de fora do treinamento (para teste)

Balanco entre holdout e leave-one-out:

Menos enviesada que o holdout

Menos custoso que o leave-one-out ( $k$  classificadores)

**Maior/menor?** variância que a do leave-one-out



EACH

# Validação cruzada k-vezes (k-fold cross-validation)

- Divida a amostra original em  $k$  ( $k < n$ ) partes
- Treina com  $k-1$  partes, testa com a que sobrou
- Repetir o processo  $k$  vezes, cada vez deixando uma parte diferente de fora do treinamento (para teste)

Balanco entre holdout e leave-one-out:

Menos enviesada que o holdout

Menos custoso que o leave-one-out ( $k$  classificadores)

Menor variância que a do leave-one-out



EACH

# Bootstrap

- Gera várias amostras de tamanho de tamanho  $m$ ,  $m \leq n$  (sorteios com reposição)
- Treina com uma e testa com outra
- Variância menor
- Computacionalmente caro
- Útil quando a amostra original é pequena

# Medidas de acurácia



# Matriz de confusão

$M_{ij}$ : quanto elementos da classe  $j$  foram preditos como sendo da classe  $i$

		Classe real				
		classe 1	classe 2	...	classe n	Totais
Predição	classe 1					
	classe 2					
	...					
	classe n					
	Totais					

# Matriz de confusão

$M_{ij}$ : quanto elementos da classe  $j$  foram preditos como sendo da classe  $i$

		Classe real				
		classe 1	classe 2	...	classe n	Totais
Predição	classe 1					
	classe 2					
	...					
	classe n					
Totais						

Diagonal tem os acertos, e o resto os erros



# Medidas de acurácia

- Classificação binária: considere uma classe positiva
  - Ex: peça defeituosa (+; P; positivo) e normal (-; N; negativo)
- Há dois tipos de erro:
  - Falso positivo (FP): o classificador diz que é (+) quando na verdade não é (-)
  - Falso negativo (FN): o classificador diz que não é (-) quando na verdade é (+)
- Há dois tipos de acerto:
  - Verdadeiro positivo (TP - *true positive*)
  - Verdadeiro negativo (TN - *true negative*)

# Matriz de confusão (caso binário)

		Classe real		
		classe +	classe -	Totais
Predição	classe +			
	classe -			
Totais				

# Matriz de confusão (caso binário)

		Classe real		
		classe +	classe -	Totais
Predição	classe +	TP	FP	
	classe -	FN	TN	
Totais				

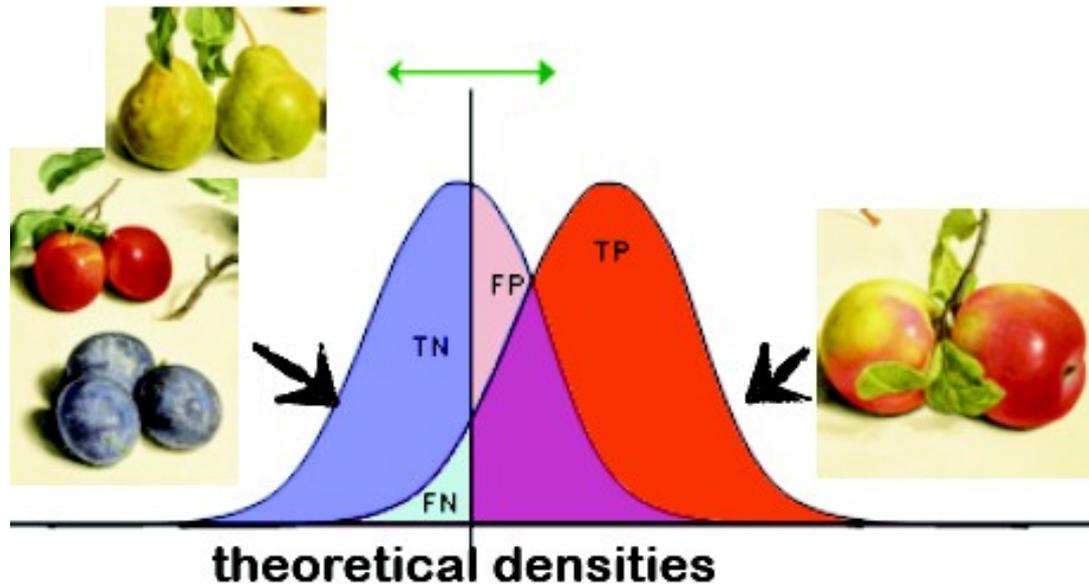
# Medidas de acurácia

- Amostra de tamanho  $m$ 
  - $N$  objetos negativos
  - $P$  objetos positivos
  - $N+P = m$
  - $N = TN + FP$
  - $P = TP + FN$
- **Acurácia:**  $(TP+TN)/m$
- **Erro:**  $(FP+FN)/m$   
 $= 1\text{-acurácia}$
- **Taxa de Falsa Aceitação (FAR):**  $FP/m$
- **Taxa de Falsa Rejeição (FRR):**  $FN/m$
- **Sensibilidade** ou **recall** ou **TP rate:**  $TP/P$
- **Especificidade:**  $TN/N$
- **FP rate** =  $FP/N = 1\text{-especificidade}$
- **Precisão:**  $TP/(TP+FP)$



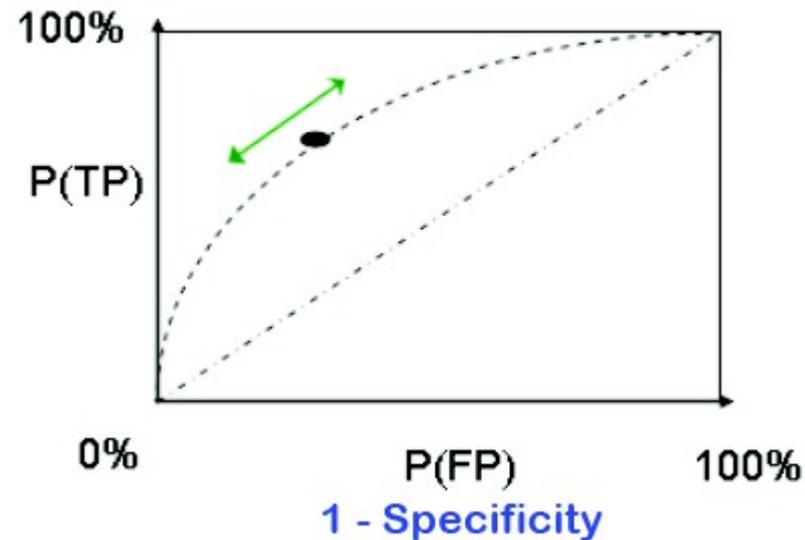
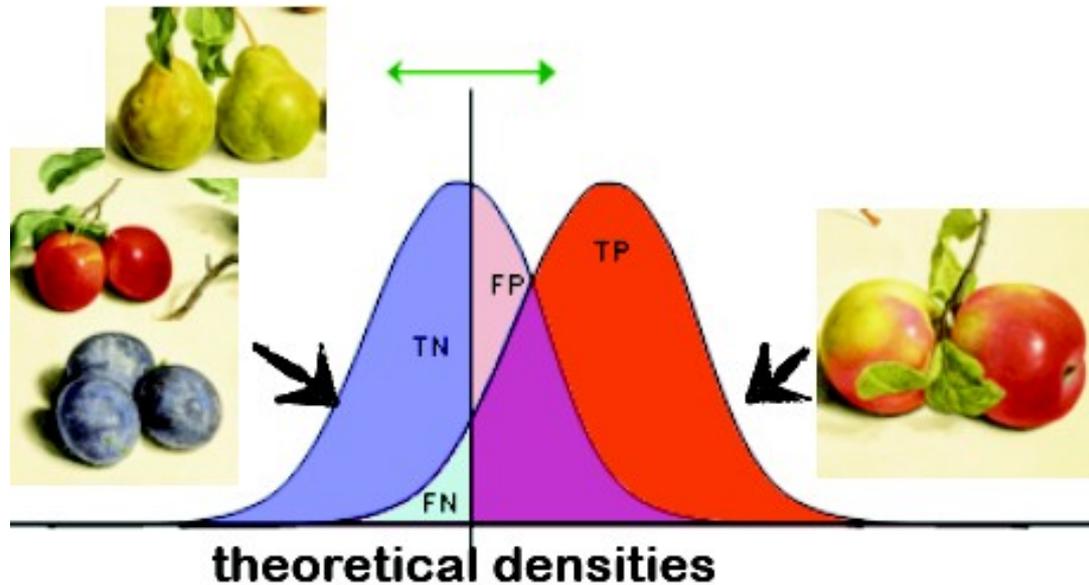
# Medidas de acurácia

- Dependendo da aplicação, prioriza-se mais a sensibilidade (recall) ou a especificidade (precisão)
- Diferentes limiares de classificação modificam esses valores

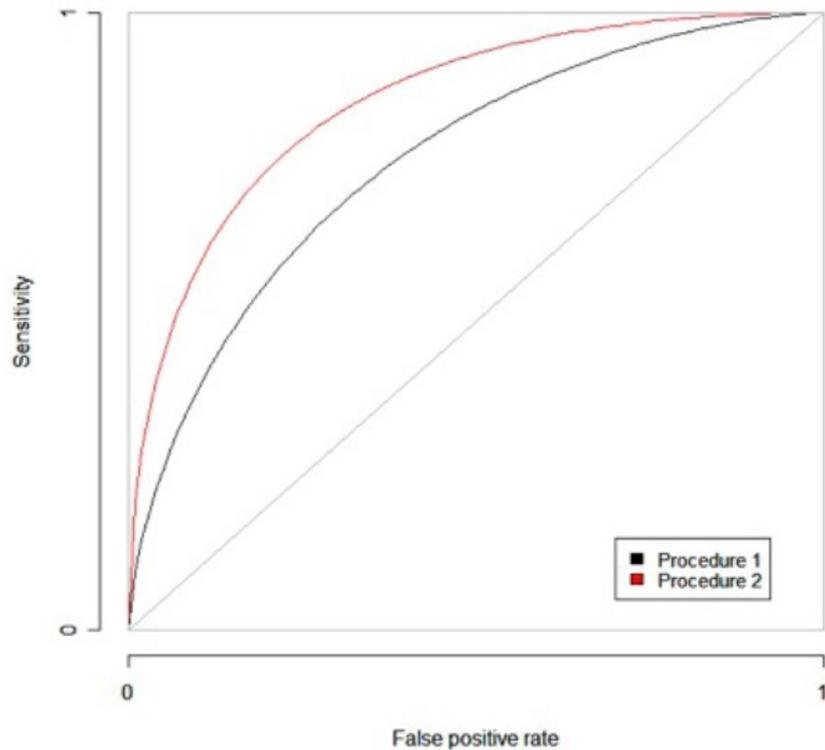


# Medidas de acurácia

- Dependendo da aplicação, prioriza-se mais a sensibilidade (recall) ou a especificidade (precisão)
- Diferentes limiares de classificação modificam esses valores
- Quando uma sobe a outra desce
- Ex: maçã x outras frutas

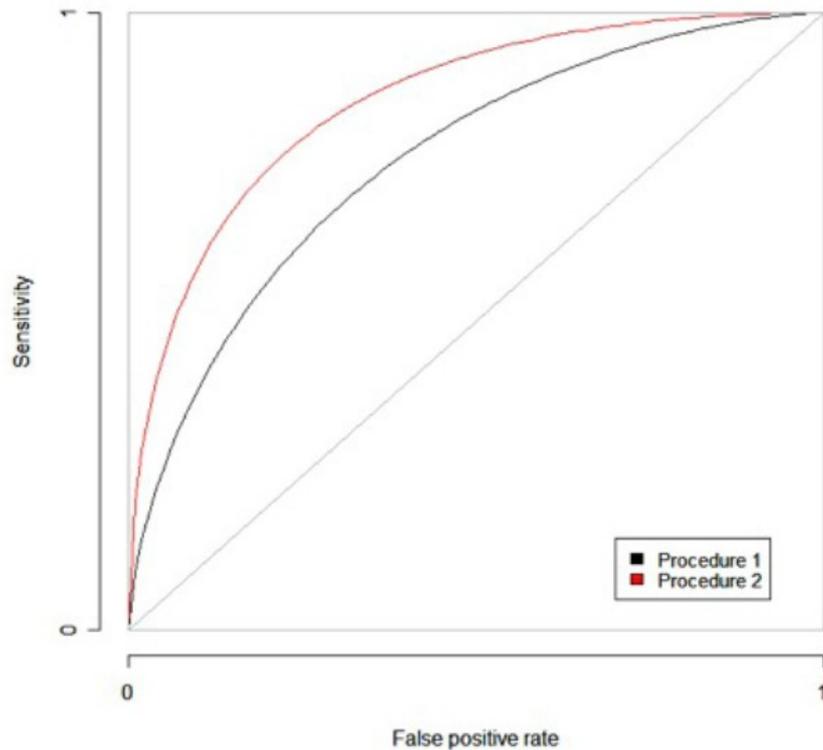


# Curvas ROC – Receiver Operating Characteristic



- Ajuda a escolher um limiar
- Forma de comparar diferentes classificadores

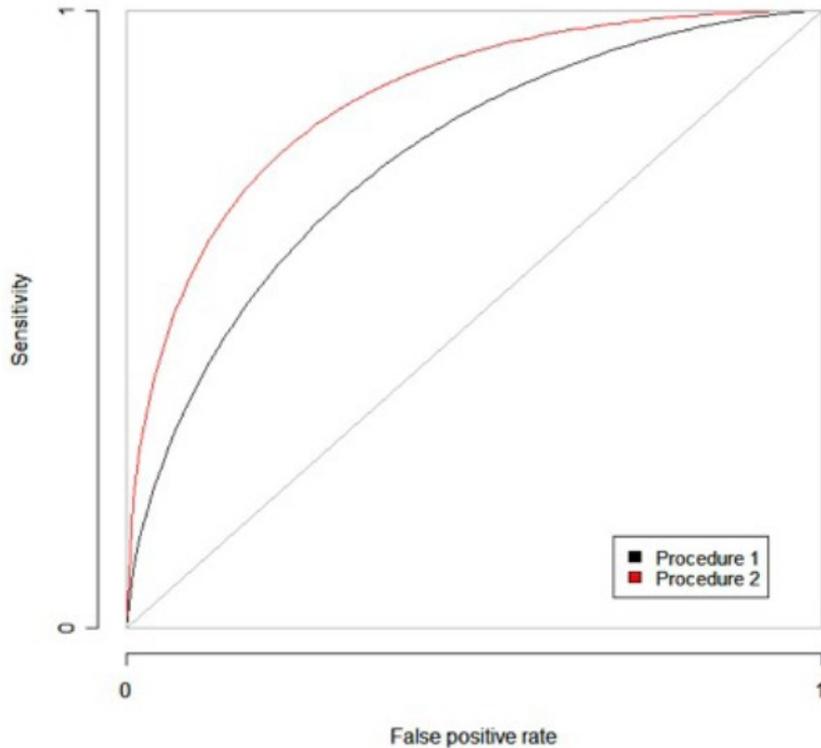
# Curvas ROC – Receiver Operating Characteristic



- Qual dos dois algoritmos é melhor? Por quê?

- Ajuda a escolher um limiar
- Forma de comparar diferentes classificadores

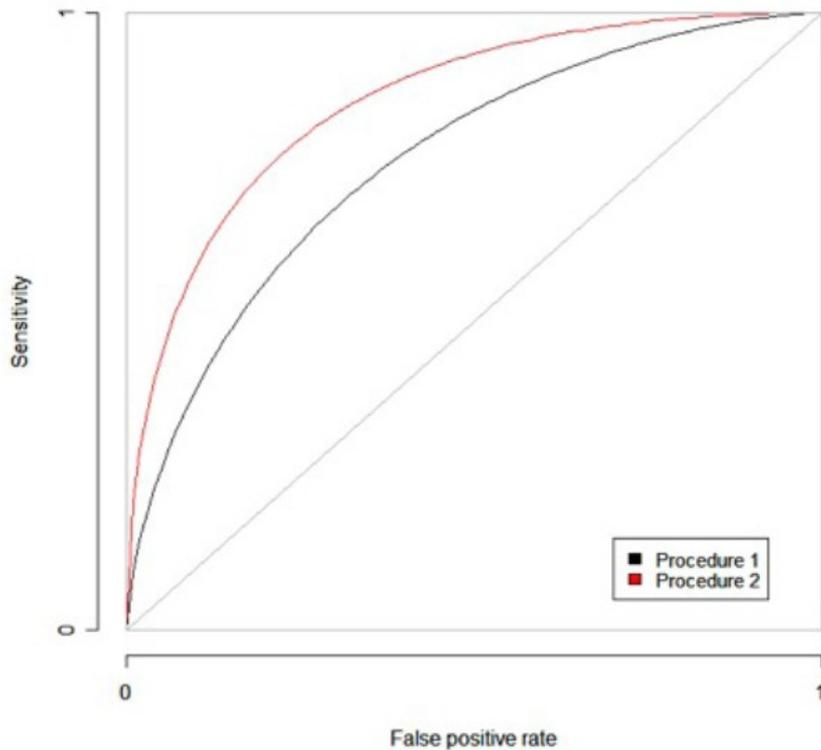
# Curvas ROC – Receiver Operating Characteristic



- Qual dos dois algoritmos é melhor? Por quê?
  - 2 (linha vermelha)
  - Porque apresenta melhores taxas de TP e FP

- Ajuda a escolher um limiar
- Forma de comparar diferentes classificadores

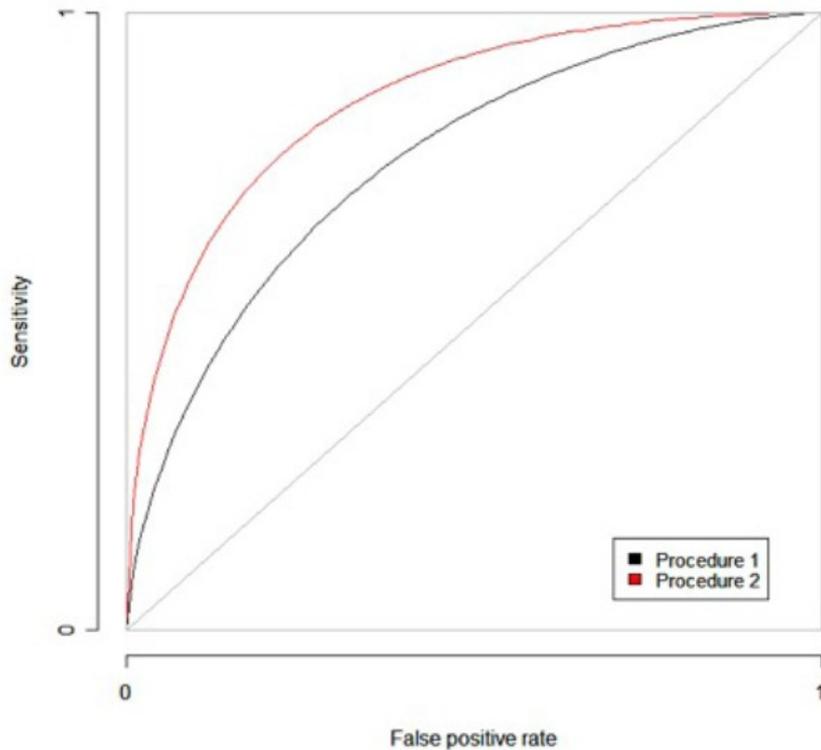
# Curvas ROC – Receiver Operating Characteristic



- Qual dos dois algoritmos é melhor? Por quê?
  - 2 (linha vermelha)
  - Porque apresenta melhores taxas de TP e FP
- Como seria a curva para um classificador ideal?

- Ajuda a escolher um limiar
- **Forma de comparar diferentes classificadores**

# Curvas ROC – Receiver Operating Characteristic



- Qual dos dois algoritmos é melhor? Por quê?
  - 2 (linha vermelha)
  - Porque apresenta melhores taxas de TP e FP
- Como seria a curva para um classificador ideal?
  - Ponto (0,1)

- Ajuda a escolher um limiar
- Forma de comparar diferentes classificadores

# Como construir uma curva ROC

- Classificadores que só fornecem a classe: representam um único ponto
- Classificadores que fornecem uma probabilidade ou um score:
  - Teoricamente: basta variar o limiar de  $-\infty$  a  $+\infty$
  - Na prática: variar o limiar para cada probabilidade/score apresentado pelas instâncias de teste

# Como construir uma curva ROC

Ex: 20 instâncias de teste (10 positivas e 10 negativas)

positivas			negativas		
Inst#	Class	Score	Inst#	Class	Score
1	p	.9	11	p	.4
2	p	.8	12	n	.39
3	n	.7	13	p	.38
4	p	.6	14	n	.37
5	p	.55	15	n	.36
6	p	.54	16	n	.35
7	n	.53	17	p	.34
8	n	.52	18	n	.33
9	p	.51	19	p	.30
10	n	.505	20	n	.1

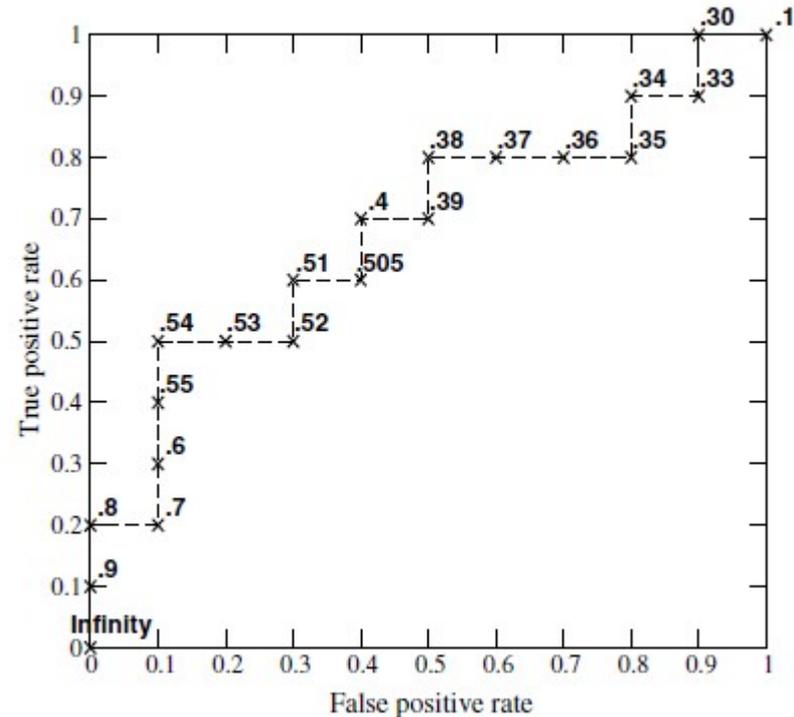
Apenas para fins didáticos, as instâncias positivas e negativas estão ordenadas decrescentemente pelo score



# Como construir uma curva ROC

Ex: 20 instâncias de teste (10 positivas e 10 negativas)

positivas			negativas		
Inst#	Class	Score	Inst#	Class	Score
1	p	.9	11	p	.4
2	p	.8	12	n	.39
3	n	.7	13	p	.38
4	p	.6	14	n	.37
5	p	.55	15	n	.36
6	p	.54	16	n	.35
7	n	.53	17	p	.34
8	n	.52	18	n	.33
9	p	.51	19	p	.30
10	n	.505	20	n	.1



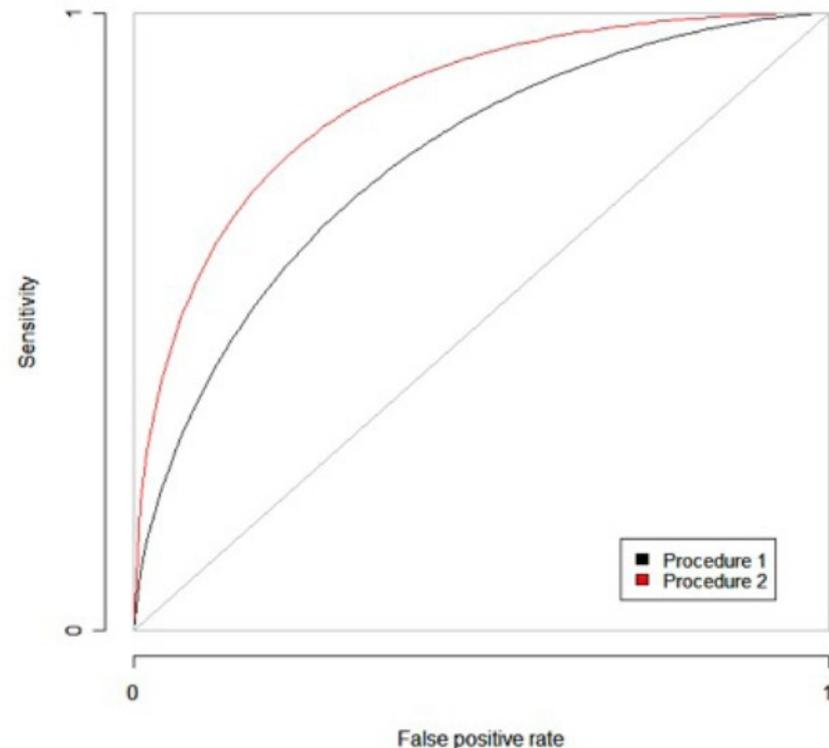
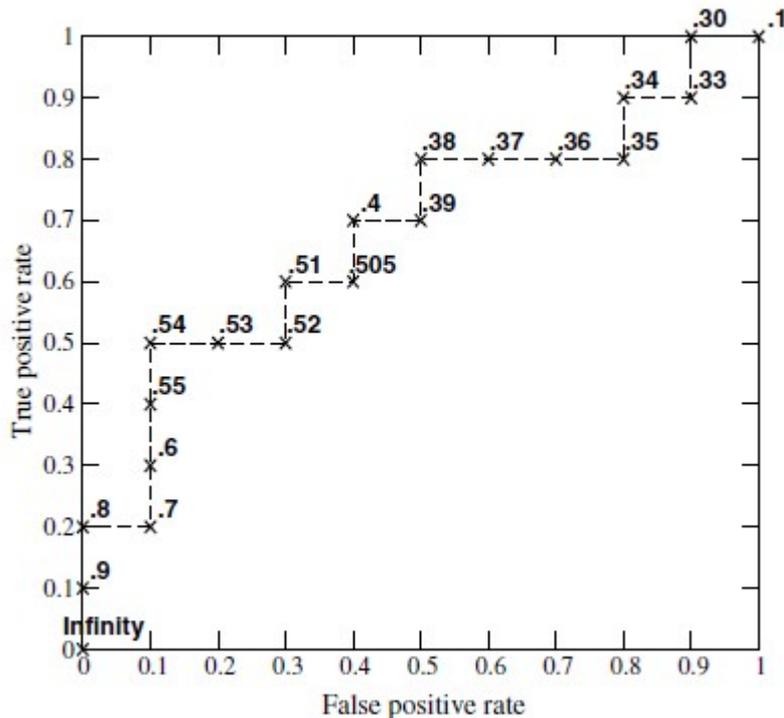
Apenas para fins didáticos, as instâncias positivas e negativas estão ordenadas decrescentemente pelo score

Cada valor distinto de score (acrescido do ponto (0,0)) corresponde a um possível limiar que resultará em um ponto da função degrau que define a curva ROC



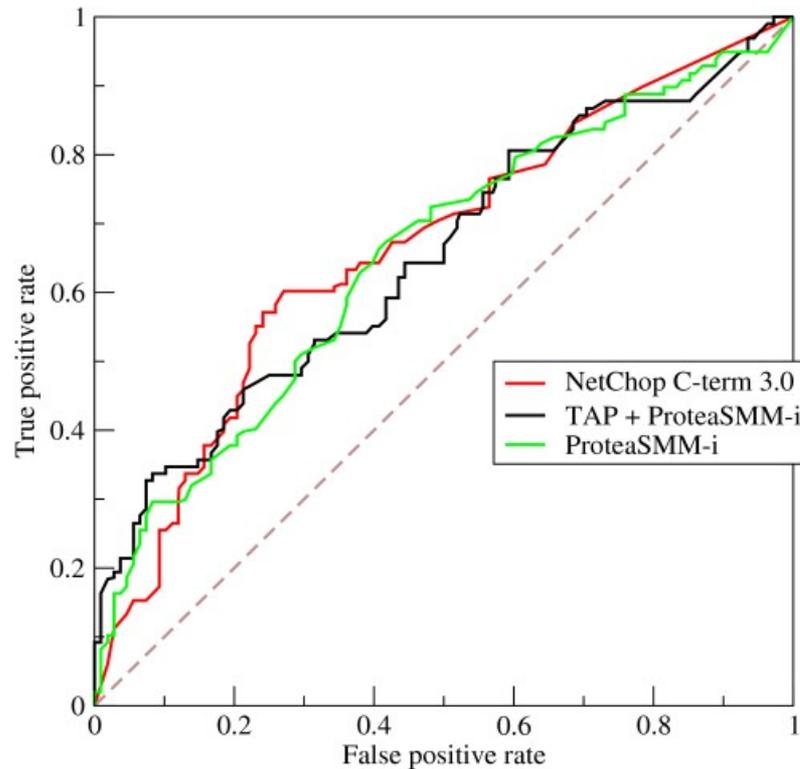
# Como construir uma curva ROC

A função degrau tenderá a uma curva de verdade à medida que o número de instâncias tender a infinito



# Curvas ROC

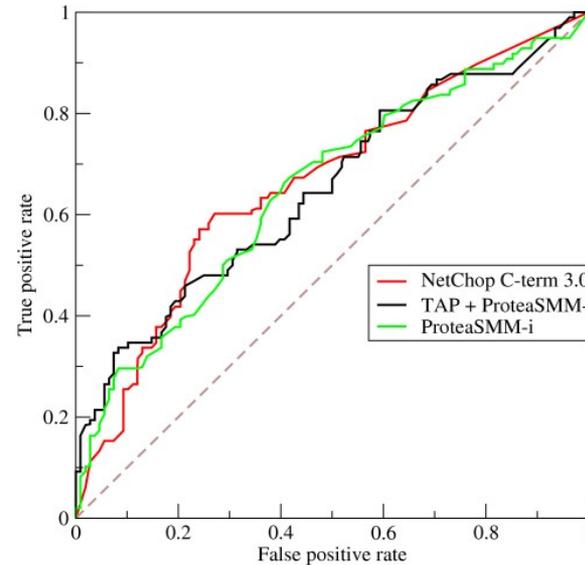
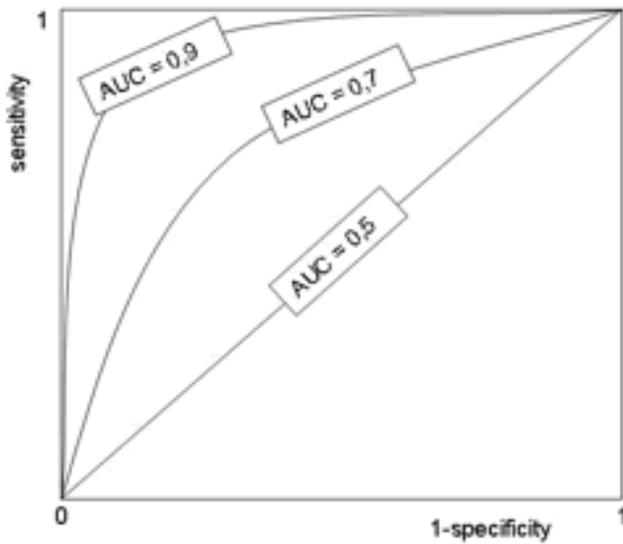
Comparar visualmente dois ou mais classificadores pode não ser fácil



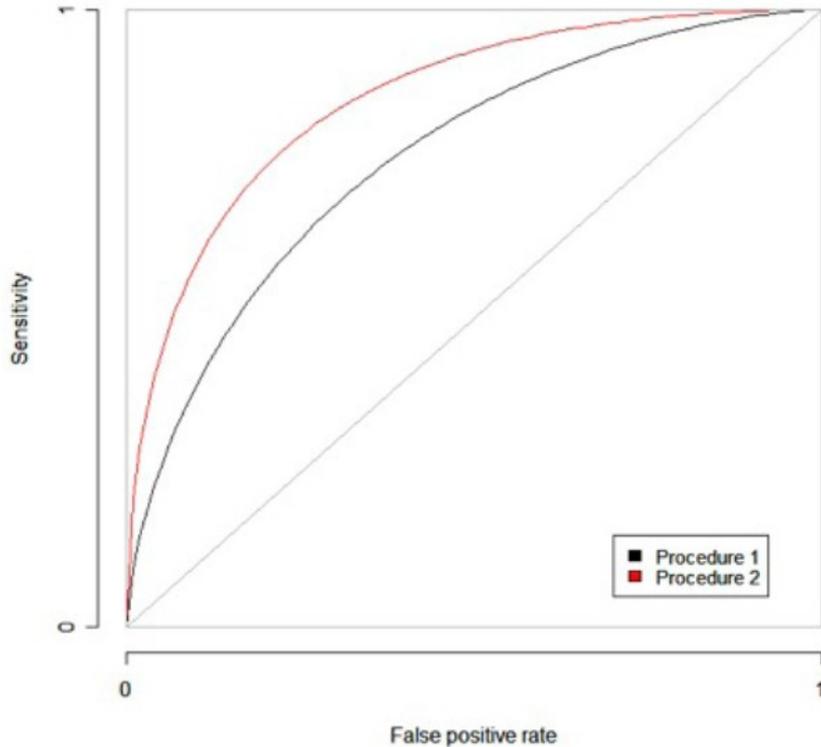
# AUC - Area Under the Curve

A área sob a curva ROC (AUC) é uma boa medida da qualidade do classificador

- quanto mais próximo do ideal (ponto (0,1)) maior a AUC



# Curvas ROC – Receiver Operating Characteristic

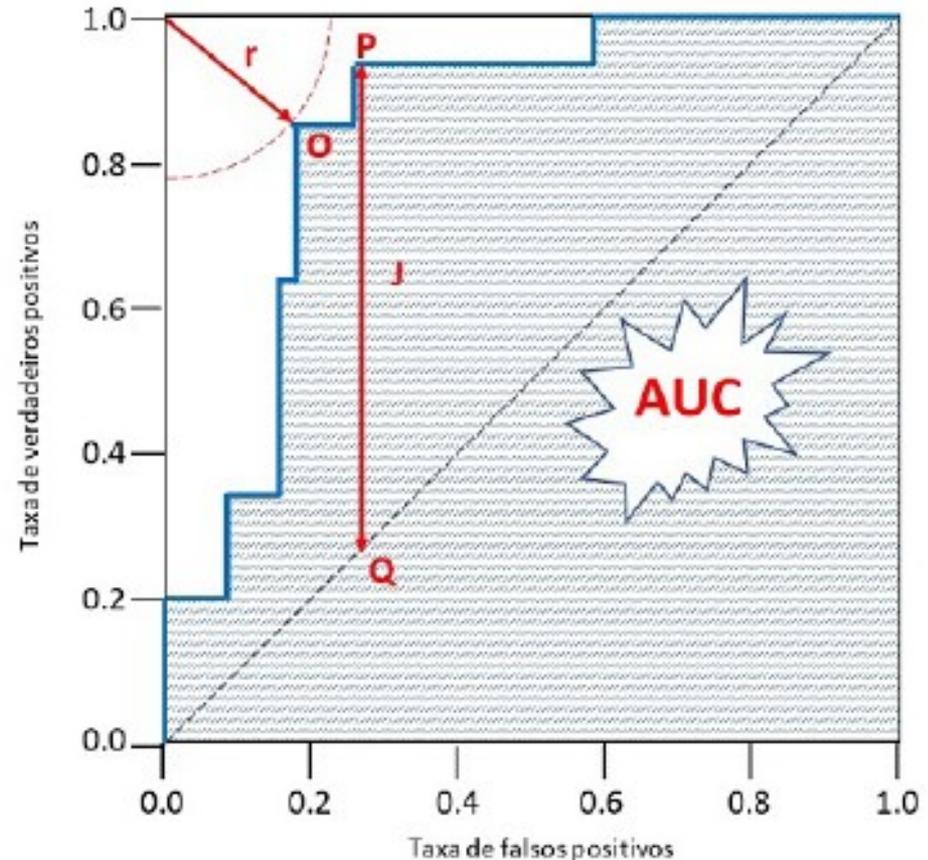


- A AUC te ajuda a avaliar um classificador para os vários limiares, mas na hora de usá-lo, qual limiar escolher?
- Você pode definir um balanço específico entre sensibilidade e especificidade
- Ou utilizar um critério específico

- **Ajuda a escolher um limiar**
- Forma de comparar diferentes classificadores

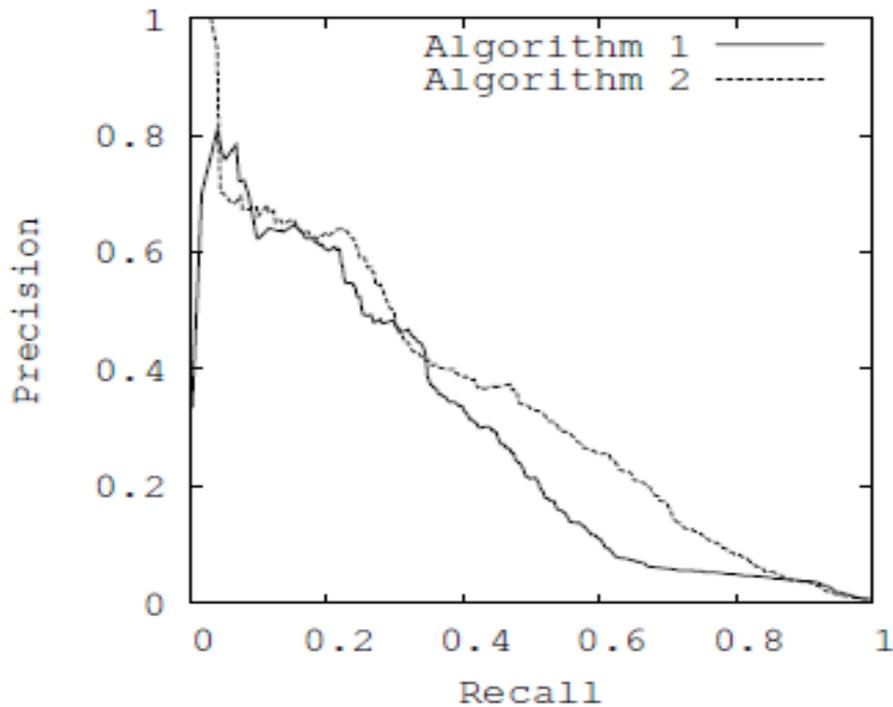
# Curvas ROC – escolha de um limiar (optimal cutpoints)

- Alguns critérios:
  - Youden: escolher o que apresenta maior distância (no eixo y) da diagonal (que representa uma classificação totalmente ao acaso (na figura: ponto P)
  - O1: escolher o mais próximo do ponto (0,1) (na figura: ponto O)



# Curvas “ROC-like”

## Ex: curvas precision-recall



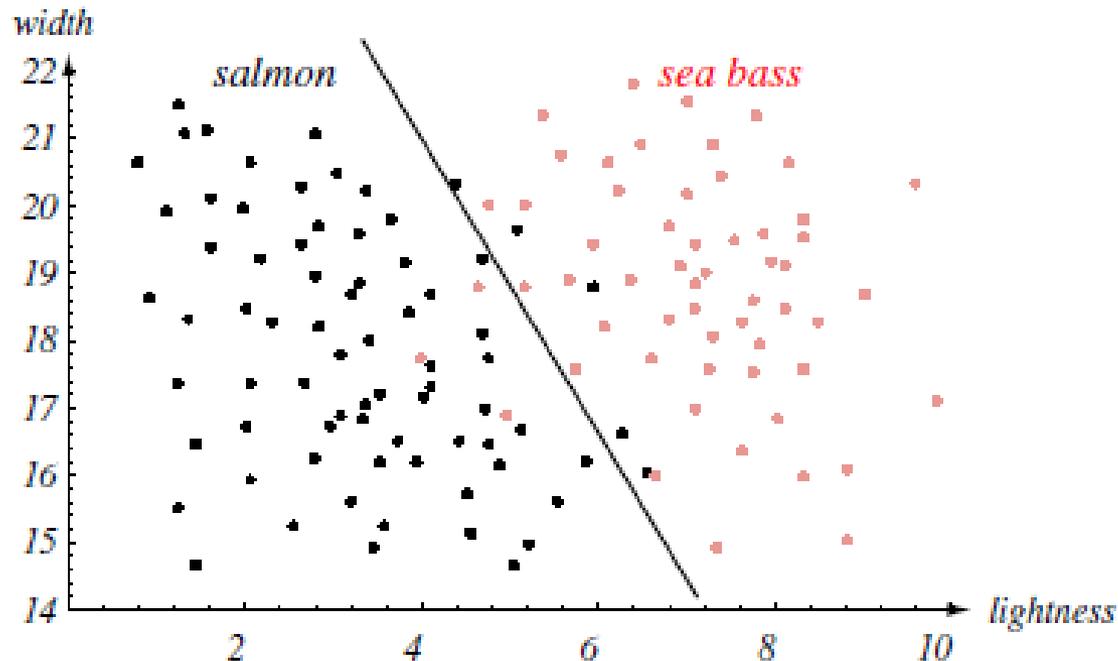
Outras métricas (além da TPR e FPR) podem ser usadas

Duas métricas “opostas”: no sentido de que quando uma sobre outra desce  
Ponto ótimo depende das métricas, assim como a melhor AUC

<ftp://ftp.cs.wisc.edu/machine-learning/shavlik-group/davis.icml06.pdf>

# Taxa de rejeição

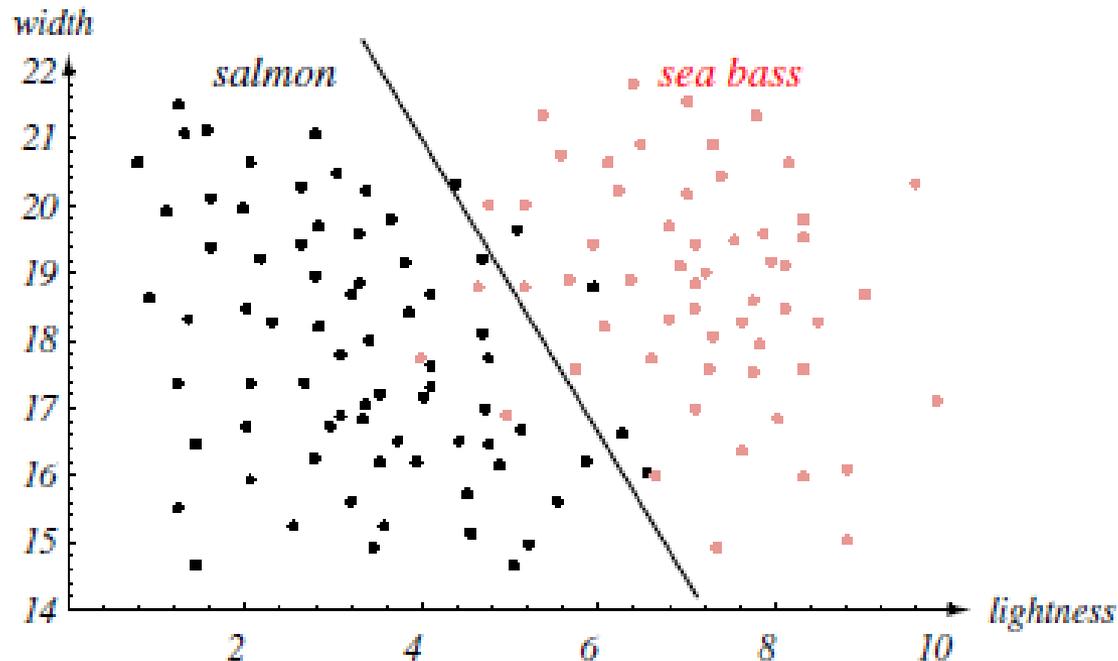
- O que fazer com os dados que caem muito próximos da fronteira de decisão?



[DUDA, HART & STORK, 2001]

# Taxa de rejeição

- Uma alternativa é rejeitá-los (recusar-se a classificá-los)

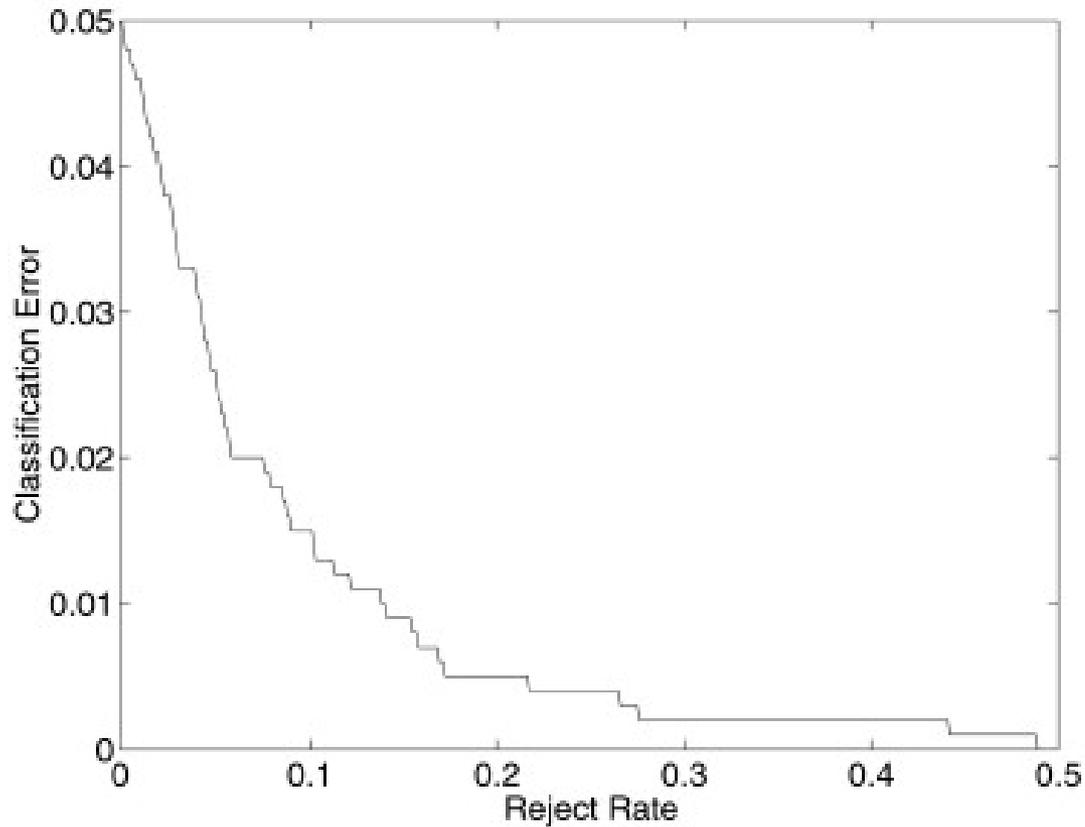


[DUDA, HART & STORK, 2001]

# Taxa de rejeição

- Taxa de rejeição: razão do número de rejeitados (para classificação) sobre o total
- Quanto maior a taxa de rejeição, menor a taxa de erro sobre os que sobraram, e vice-versa

# Curva taxa de rejeição x erro de classificação



[JAIN et al, 2000]

# Atividade 4

- Implementar uma função que FARÁ uma estimativa de erro de um classificador baseada em k-fold cross-validation
- Por enquanto, a função deve receber como parâmetros:
  - um conjunto de dados (amostra original)
  - o valor de ke deve dividir a amostra original em k subconjuntos de amostras (treinamento e teste)
- Futuramente, essa função vai estimar o erro de um classificador



# Atividade 4

- Observações:
  - Cada parte deve ter tamanho diferente de outra em no máximo 1 elemento
  - Cada parte deve manter a proporção de cada classe
  - No final imprimir quantos elementos ficaram em cada parte (quantos de cada classe e quantos no total)



# Referências

- DUDA, R.; HART, P.; STORK, D. **Pattern Classification** . John Willey, 2001 (Cap. 2.1 a 2.3)
- FAWCETT, T. An Introduction to ROC Analysis. **Pattern Recognition Letters**, v. 27, p. 861-874, 2006.
- JAIN, A.K.; DUIN, R.P.W.; MAO, J. Statistical Pattern Recognition : A Review. **IEEE Transactions on Pattern Analysis and Machine Intelligence**, v. 22, n. 1, p. 4-37, 2000 (seções 2 e 7)

