

# Avaliação de Classificadores

Inteligência na Web e Big Data

---

Fabricio Olivetti de França e Thiago Ferreira Covões  
[folivetti@ufabc.edu.br](mailto:folivetti@ufabc.edu.br), [thiago.covoes@ufabc.edu.br](mailto:thiago.covoes@ufabc.edu.br)

Centro de Matemática, Computação e Cognição  
Universidade Federal do ABC



# Introdução

---

- É intuitivo considerar a taxa de acerto de classificação (ou o erro correspondente)
  - Proporção de classificações corretas
- Para facilitar a análise de erros costuma-se utilizar a Matriz de Confusão (2 classes abaixo)

Classe	Predita Positiva	Predita Negativa
Real Positiva	Verdadeiro Positivo (TP)	Falso Negativo (FN)
Real Negativa	Falso Positivo (FP)	Verdadeiro Negativo (TN)

## Mensurando acerto/erro

- Taxa de acerto pode não ser o ideal
- Os dois classificadores abaixo têm a mesma taxa de acerto.
  - No entanto, um deles parece melhor, qual?

Método 1			Método 2		
Classe	PPos	PNeg	Classe	PPos	PNeg
Pos	0	10	Pos	0	10
Neg	0	9.990	Neg	0	9.990

## Classe menos frequente

- A classe menos frequente (normalmente chamada de positiva) é geralmente a de maior interesse
  - Doença rara
  - Transação fraudulenta
- Um classificador que erra muito a classe positiva é de pouca utilidade

- Uma forma de enfatizar esforços no aprendizado da classe minoritária é atribuir custos diferentes para cada tipo de erro
  - Para calcular o custo total, os erros são multiplicados pelo seu custo
- Em vez de minimizar o erro, o objetivo do classificador é minimizar o custo total

- Nem todo classificador consegue incorporar custos na indução de modelos
- É muito difícil fazer uma atribuição de custos
- Custos podem variar com o tempo
- Existe uma relação direta entre custos e alterar artificialmente a proporção de objetos entre as classes

- É possível incorporar custos:
  - Pesos diferentes para objetos
  - Reamostragem do conjunto de treinamento, proporção de objetos positivos/negativos de acordo com custo



- Taxa de Falsos Positivos (Erro Tipo I):
  - De todos os objetos negativos, quantos foram erroneamente preditos como positivos


$$TFP = \frac{FP}{FP + TN}$$

- Taxa de Falsos Negativos (Erro Tipo II):
  - De todos os objetos positivos, quantos foram erroneamente preditos como negativos

$$TFN = \frac{FN}{FN + TP}$$

## Erro Tipo I/Tipo II

**Type I error**  
(false positive)



**Type II error**  
(false negative)



Figura 1:

<https://marginalrevolution.com/marginalrevolution/2014/05/type-i-and-type-ii-errors-simplified.html>

- Taxa de Verdadeiros Positivos
  - De todos os objetos positivos, quantos eu acertei?
  - Também conhecido como recall, revocação, sensibilidade

$$TVP = \frac{TP}{TP + FN}$$

- Precisão
  - Dos objetos preditos como positivos, quantos eram de fato positivos

$$\text{Precisão} = \frac{TP}{TP + FP}$$

- F-Measure
  - Média harmônica entre Precisão e Revocação

$$F_1 = 2 \cdot \frac{\text{Precisão} \cdot \text{Revocação}}{\text{Precisão} + \text{Revocação}}$$

## Exemplo

- Computar taxa de acerto, precisão, revocação, F-measure, taxa de falso positivo e taxa de falso negativo da matriz de confusão abaixo

Classe	Predita Positiva	Predita Negativa
Real Positiva	70	30
Real Negativa	40	60

## Exemplo

Classe	Predita Positiva	Predita Negativa
Real Positiva	70	30
Real Negativa	40	60

- Taxa de acerto =  $\frac{TP+TN}{N} =$
- Precisão =  $\frac{TP}{TP+FP} =$
- Revocação =  $\frac{TP}{TP+FN} =$
- TFP =  $\frac{FP}{FP+TN} =$
- TFN =  $\frac{FN}{FN+TP} =$

## Exemplo

Classe	Predita Positiva	Predita Negativa
Real Positiva	70	30
Real Negativa	40	60

- Taxa de acerto =  $\frac{TP+TN}{N} = \frac{130}{200} = 0,65$
- Precisão =  $\frac{TP}{TP+FP} = \frac{70}{110} = 0,63$
- Revocação =  $\frac{TP}{TP+FN} = \frac{70}{100} = 0,7$
- TFP =  $\frac{FP}{FP+TN} = \frac{40}{100} = 0,4$
- TFN =  $\frac{FN}{FN+TP} = \frac{30}{100} = 0,3$

## Classificação versus Ranking

- Alguns classificadores indicam apenas a classe predita
- Outros fornecem um indicativo de confiança (chamados de score)
  - Pode ser uma probabilidade
  - Normalmente obtidos/transformados entre  $[0,1]$  ou  $[0,100]$




- Como obter score para:
  - KNN
  - Árvore de decisão

- A partir destes scores podemos obter diferentes classificadores considerando os valores possíveis para o limiar de decisão
  - Conservador: limiar alto
  - Liberal: limiar baixo

- Receiver Operating Characteristic curve
- Origem
  - Detecção de sinais
  - Compromisso entre alarme falso/acerto
- Gráfico TFP x TVP (FPR x TPR)

$$TFP = \frac{FP}{FP + TN}$$

$$TVP = \frac{TP}{TP + FN}$$



1. Ordene os objetos da base de teste em ordem crescente de score (probabilidade de estar na classe positiva).
2. Para cada objeto **em ordem de score**:
  - 2.1 Seja  $s_t$  o score do objeto sendo processado
  - 2.2 Considere todos os objetos com score maior ou igual à  $s_t$  como POSITIVOS
  - 2.3 Considere todos os objetos com score menor que  $s_t$  como NEGATIVOS
  - 2.4 Compute TP e FP

- O primeiro ponto é sempre no (1,1) (Por quê?)
- A cada objeto processado estamos alterando apenas a predição dele
  - Assumindo que não tem valores iguais de limiar
- Cada vez que alteramos a predição de um objeto (deixa de ser predito negativo passa a ser predito positivo):
  - Se ele é da classe negativa: FP é decrementado
  - Se ele é da classe positiva: TP é decrementado

## Gerando a curva ROC

---

```
1 def gera_pontos_curva_roc(scores, classes):
2     sorted_idx = np.argsort(scores)
3     ultimo = sorted_idx[0]
4     n_positivos = sum(classes == '+')
5     n_negativos = sum(classes == '-')
6     tp, fp, tpr, fpr = n_positivos, n_negativos, 1, 1
7     pontos = [(scores[ultimo], (1,1))]
8     for t in sorted_idx[1:]:
9         if classes[ultimo] == "+": tp -= 1
10        else: fp -= 1
11        tpr, fpr = tp/n_positivos, fp/n_negativos
12        ultimo = t
13        pontos.append([(scores[t], (fpr, tpr))])
14    pontos.append([(np.inf, (0, 0))])
15    return pontos
```


---

## Exemplo

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



# Exemplo



- Area Under the Curve
- Probabilidade de que um objeto positivo vai estar ranqueado acima de um objeto negativo
- Pode ser calculado pela regra do trapézio
- Quanto maior a área, melhor é o desempenho médio do classificador

- Curvas precisão x revocação
- Curvas de custo
- Curvas list
- ...