

# 6. 评测方法

---

WU Xiaokun 吴晓堃

xkun.wu [at] gmail

2022/03/18

**评测：精确率，召回率，F度量**

# 回顾：两类误差

## 假阳 False positives (Type I errors)

- 查出错误信息
- 提高准确度 accuracy、精度 precision

## 假阴 False negatives (Type II errors)

- 没有查出正确信息
- 提高覆盖率 coverage、召回率 recall

# 回顾：两类误差

假阳 **False positives** (Type I errors)

- 查出错误信息
- 提高准确度 accuracy、精度 precision

假阴 **False negatives** (Type II errors)

- 没有查出正确信息
- 提高覆盖率 coverage、召回率 recall

评测：模型的预测性能，即预测正确率

# 预测与标注

首先考虑只有两个类的情况，如正负面评价

- 预测值只有两种可能性：+，-
- 标注也只有两种可能性：T，F

# 预测与标注

首先考虑只有两个类的情况，如正负面评价

- 预测值只有两种可能性：+，-
- 标注也只有两种可能性：T，F

评测时需要将预测与标注**两两组合**进行对比

- 假阳：错误的阳性；预测是+，但实际是F
- 假阴：错误的阴性；预测是-，但实际是T

# 混淆矩阵

混淆 confusion 矩阵：预测与标注对比的可视化

	T	F
P	True Positive (TP)	False Positive (FP)
N	False Negative (FN)	True Negative (TN)

- 两种正确的预测
  - TP: 正确的阳性
  - TN: 正确的阴性

# 混淆矩阵

混淆 confusion 矩阵：预测与标注对比的可视化

	T	F
P	True Positive (TP)	False Positive (FP)
N	False Negative (FN)	True Negative (TN)

- 两种正确的预测
  - TP: 正确的阳性
  - TN: 正确的阴性

评测：计算预测的正确率

- 一定与正确的预测（TP和TN）有关

# 准确度

准确度 accuracy: 正确的预测所占百分比

	T	F
P	TP	FP
N	FN	TN

$$A = \frac{TP+TN}{TP+FP+TN+FN}$$

# 准确度

准确度 accuracy: 正确的预测所占百分比

	T	F
P	TP	FP
N	FN	TN

$$A = \frac{TP+TN}{TP+FP+TN+FN}$$

看起来像是很自然的度量

- 问题: 当类间数据不平衡时会失效

# 不平衡的网页检索

假设网页检索返回 $1 \cdot 10^6$ 条信息

- 但只有100条是相关的，比如\*\*搜索

# 不平衡的网页检索

假设网页检索返回  $1 \cdot 10^6$  条信息

- 但只有100条是相关的，比如\*\*搜索

构造一个假的分类器：对任何输入都输出“不相关”

- 准确度： $A = \frac{TP+TN}{TP+FP+TN+FN} = 99.99\%$

# 不平衡的网页检索

假设网页检索返回 $1 \cdot 10^6$ 条信息

- 但只有100条是相关的，比如\*\*搜索

构造一个假的分类器：对任何输入都输出“不相关”

- 准确度： $A = \frac{TP+TN}{TP+FP+TN+FN} = 99.99\%$

目标是发现罕见情况时，越罕见问题就越严重

- 例如：对罕见病检测都预测阴性

# 不平衡的网页检索

假设网页检索返回 $1 \cdot 10^6$ 条信息

- 但只有100条是相关的，比如\*\*搜索

构造一个假的分类器：对任何输入都输出“不相关”

- 准确度： $A = \frac{TP+TN}{TP+FP+TN+FN} = 99.99\%$

目标是发现罕见情况时，越罕见问题就越严重

- 例如：对罕见病检测都预测阴性

推论：**TP**要更重要一些，而TN会带来大量干扰信息

# 精确度、召回率

精确度 precision: 预测为+的结果中, 正确 (实际确实是) 的百分比

召回率 recall: 标注为T的数据中, 正确检测出来 (预测阳性) 的百分比

	<b>T</b>	<b>F</b>
<b>P</b>	TP	FP
<b>N</b>	FN	TN

$$P = \frac{TP}{TP+FP}$$
$$R = \frac{TP}{TP+FN}$$

# 精确度、召回率

精确度 precision: 预测为+的结果中, 正确 (实际确实是) 的百分比

召回率 recall: 标注为T的数据中, 正确检测出来 (预测阳性) 的百分比

	T	F
P	TP	FP
N	FN	TN

$$P = \frac{TP}{TP+FP}$$
$$R = \frac{TP}{TP+FN}$$

注意: 两者都只关注TP, 而把容易带来干扰的TN排除了

- 例如医疗检测中的TN就是健康人

# 精确度、召回率

精确度 precision: 预测为+的结果中, 正确 (实际确实是) 的百分比

召回率 recall: 标注为T的数据中, 正确检测出来 (预测阳性) 的百分比

	T	F
P	TP	FP
N	FN	TN

$$P = \frac{TP}{TP+FP}$$
$$R = \frac{TP}{TP+FN}$$

注意: 两者都只关注TP, 而把容易带来干扰的TN排除了

- 例如医疗检测中的TN就是健康人

前面例子:  $R = \frac{TP}{TP+FN} = \frac{0}{100} = 0\%$

# 分类问题应用

精确度高：阳性置信度高；召回率高：阳性辨识力强。

- 如何确定辨识力？选取**阈值**

# 分类问题应用


精确度高：阳性置信度高；召回率高：阳性辨识力强。

- 如何确定辨识力？选取**阈值**

例如分类真值： $[T, F, F]$ ；预测值： $[0.7, 0.3, 0.5]$


- 阈值0.5： $P = \frac{TP}{TP+FP} = 1/2$ ； $R = \frac{TP}{TP+FN} = 1$

# Precision-Recall Curve



- 閾值0：所有真值都检出； 閾值接近1：所有真值都正确
  - 曲线越向右上角越好


# Precision-Recall Curve



- 閾值0: 所有真值都检出; 閾值接近1: 所有真值都正确
  - 曲线越向右上角越好

**Area Under Curve (AUC):** 面积越大越好

# 准确度、精确度



- TP: 靶心附近; FP: 偏离靶心

	T	F	
P	TP	FP	$P = \frac{TP}{TP+FP}$
N	FN	TN	
			$A = \frac{TP+TN}{TP+FP+TN+FN}$

# 单一度量

实际应用通常希望将两种度量（精确度、召回率）综合考虑

- 最常用的是加权调和平均 **harmonic mean**

$$F_{\alpha} = \frac{1}{\alpha \frac{1}{P} + (1 - \alpha) \frac{1}{R}}$$

# 单一度量

实际应用通常希望将两种度量（精确度、召回率）综合考虑

- 最常用的是加权调和平均 **harmonic mean**

$$F_{\alpha} = \frac{1}{\alpha \frac{1}{P} + (1 - \alpha) \frac{1}{R}}$$

- 调和平均是**保守 conservative**度量：（相比算数平均）较低的值权重更高

# 单一度量

实际应用通常希望将两种度量（精确度、召回率）综合考虑

- 最常用的是加权调和平均 **harmonic mean**

$$F_{\alpha} = \frac{1}{\alpha \frac{1}{P} + (1 - \alpha) \frac{1}{R}}$$

- 调和平均是**保守 conservative**度量：（相比算数平均）较低的值权重更高

常用变换形式： $\beta^2 = \frac{1}{\alpha} - 1 \Rightarrow \beta^2 + 1 = \frac{1}{\alpha}$

- $\beta$ 的定义可以保证 $\frac{1}{\alpha} - 1$ 非负

# 单一度量

实际应用通常希望将两种度量（精确度、召回率）综合考虑

- 最常用的是加权调和平均 **harmonic mean**

$$F_{\alpha} = \frac{1}{\alpha \frac{1}{P} + (1 - \alpha) \frac{1}{R}}$$

- 调和平均是**保守 conservative**度量：（相比算数平均）较低的值权重更高

常用变换形式： $\beta^2 = \frac{1}{\alpha} - 1 \Rightarrow \beta^2 + 1 = \frac{1}{\alpha}$

- $\beta$ 的定义可以保证 $\frac{1}{\alpha} - 1$ 非负

$$F_{\alpha} = \frac{\frac{1}{\alpha}}{\frac{1}{P} + (\frac{1}{\alpha} - 1) \frac{1}{R}} = \frac{\beta^2 + 1}{\frac{1}{P} + \beta^2 \frac{1}{R}}$$

# F度量

F度量 F-measure: 精确度、召回率的加权调和平均

$$F_{\alpha} = \frac{1}{\alpha \frac{1}{P} + (1 - \alpha) \frac{1}{R}} = \frac{\beta^2 + 1}{\frac{1}{P} + \beta^2 \frac{1}{R}}$$
$$F_{\beta} = \frac{(\beta^2 + 1)PR}{\beta^2 P + R}$$

# F度量

F度量 F-measure: 精确度、召回率的加权调和平均

$$F_{\alpha} = \frac{1}{\alpha \frac{1}{P} + (1 - \alpha) \frac{1}{R}} = \frac{\beta^2 + 1}{\frac{1}{P} + \beta^2 \frac{1}{R}}$$
$$F_{\beta} = \frac{(\beta^2 + 1)PR}{\beta^2 P + R}$$

- $\beta > 1$ : 强调召回率;  $\beta < 1$ : 强调精确度

# F度量

F度量 F-measure: 精确度、召回率的加权调和平均

$$F_{\alpha} = \frac{1}{\alpha \frac{1}{P} + (1 - \alpha) \frac{1}{R}} = \frac{\beta^2 + 1}{\frac{1}{P} + \beta^2 \frac{1}{R}}$$
$$F_{\beta} = \frac{(\beta^2 + 1)PR}{\beta^2 P + R}$$

- $\beta > 1$ : 强调召回率;  $\beta < 1$ : 强调精确度

最常用的是 $F_1$ 度量:  $\beta = 1$

$$F_1 = \frac{2PR}{P + R}$$

# Average Precision (AP)

精确度的加权和；权重：召回率增量

$$AP = \sum_{k=0}^{n-1} [R(k) - R(k+1)] * P(k)$$

- $R(n) = 0, P(n) = 1$

# Average Precision (AP)

精确度的加权和；权重：召回率增量

$$AP = \sum_{k=0}^{n-1} [R(k) - R(k+1)] * P(k)$$

- $R(n) = 0, P(n) = 1$

Mean Average Precision (mAP): 多类AP均值

$$AP = \frac{1}{n} \sum_{k=1}^n AP_k$$