

# Medindo Desempenho

Prof. Dr. Geraldo Braz Junior

# Matriz de Confusão

		Classe prevista	
		Sim	Não
Classe real	Sim	Verdadeiro Positivo (VP)	Falso Negativo (FN)
	Não	Falso Positivo (FP)	Verdadeiro Negativo (VN)

# Sobre a Matriz de Confusão

- Acurácia (total de acerto geral) – **problemas com o balanceamento**

USO:  $Acc = \frac{VP+VN}{N}$

- Erro (total de erro geral)

USO:  $Err = \frac{FP + FN}{N}$

# Outras

- Sensibilidade (Recall):
  - Mede o quão correto é o classificador ao reconhecer indivíduos da classe positiva

USO:  $S = \frac{VP}{VP + FN}$

- Especificidade (Taxa VN):
  - Mede o quão correto é o classificador ao reconhecer indivíduos da classe negativa

USO:  $E = \frac{VN}{VN + FP}$

# Outras

- Precision (VPP ou confiabilidade positiva)
  - Mede a fração de instâncias relevantes (positivas) corretamente classificadas

USO:  $P = \frac{VP}{VP + FP}$

# Outras

- F-measure (F1 score)
  - Relação entre Precision Recall (quanto maior melhor)

USO:  $F = 2 * \frac{P * S}{P + S}$

# Matriz de confusão

		Condition (as determined by "Gold standard")			
		Condition positive	Condition negative		
Total population				Prevalence = $\frac{\Sigma \text{Condition positive}}{\Sigma \text{Total population}}$	
Test outcome	Test outcome positive	<b>True positive</b>	<b>False positive</b> (Type I error)	Positive predictive value (PPV, Precision) = $\frac{\Sigma \text{True positive}}{\Sigma \text{Test outcome positive}}$	False discovery rate (FDR) = $\frac{\Sigma \text{False positive}}{\Sigma \text{Test outcome positive}}$
	Test outcome negative	<b>False negative</b> (Type II error)	<b>True negative</b>	False omission rate (FOR) = $\frac{\Sigma \text{False negative}}{\Sigma \text{Test outcome negative}}$	Negative predictive value (NPV) = $\frac{\Sigma \text{True negative}}{\Sigma \text{Test outcome negative}}$
Positive likelihood ratio (LR+) = TPR/FPR		True positive rate (TPR, Sensitivity, Recall) = $\frac{\Sigma \text{True positive}}{\Sigma \text{Condition positive}}$	False positive rate (FPR, Fall-out) = $\frac{\Sigma \text{False positive}}{\Sigma \text{Condition negative}}$	Accuracy (ACC) = $\frac{\Sigma \text{True positive} + \Sigma \text{True negative}}{\Sigma \text{Total population}}$	
Negative likelihood ratio (LR-) = FNR/TNR		False negative rate (FNR) = $\frac{\Sigma \text{False negative}}{\Sigma \text{Condition positive}}$	True negative rate (TNR, Specificity, SPC) = $\frac{\Sigma \text{True negative}}{\Sigma \text{Condition negative}}$		
Diagnostic odds ratio (DOR) = LR+/LR-					

# Outras

- Matthews Correlation Coefficient (MCC) (coeficiente phi)
  - Mede a qualidade da classificação
  - Retorna valores entre -1 e +1, onde:
    - 0 é aleatório
    - -1 é péssimo
    - + 1 é ótimo


$$\text{MCC} = \frac{TP \times TN - FP \times FN}{\sqrt{(TP + FP)(TP + FN)(TN + FP)(TN + FN)}}$$



# Receiver Operating Characteristic (ROC)

- ROC Curve
  - Ilustra graficamente o desempenho do classificador
  - Plota
    - Taxa de verdadeiros positivos (Sensibilidade) x Taxa de falso positivos (1 – Especificidade)


# Curva ROC



# AUC – Area Under the Curve

- A AUC é equivalente a probabilidade que um classificador irá randomicamente classificar uma amostra positiva
- Muito usado para comparação de modelos de classificação
  - Porque transforma a curva num escalar que pode ser facilmente usado

# Exemplo



E muitas outras

Cada uma adequada para o  
problema que se está lidando