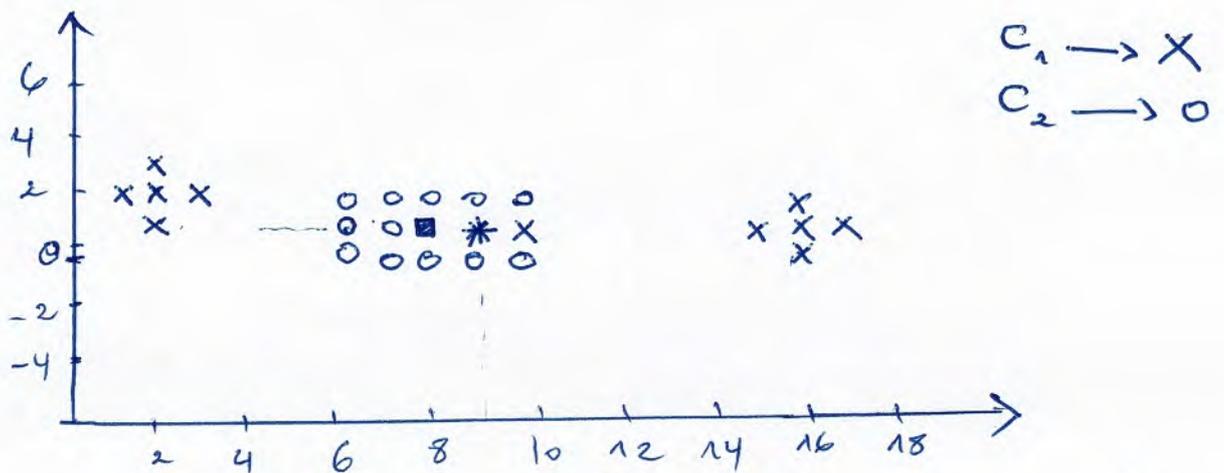


Solution TD n° 4

Exo 1:



1) - La moyenne de classe : $\mu_1 = (\underline{9,09}, 2)^T$, $\mu_2 = (\underline{7,75}, 2)^T$

* / Le point $x = (9, 2)$ est classé dans C_1 parce qu'il est plus proche à sa moyenne c.a.d. : $\|x - \mu_1\| < \|x - \mu_2\|$
il est clair que cette approche n'est pas la meilleure !

2) si $k=1$, le plus proche voisin à x dans l'ensemble de données d'apprentissage appartient à C_1 donc $x \in C_1$.

3) si $k=3$, les 3 ppv à x sont ceux qui ont l'abscisse $x=10$, la majorité de ces points $\in C_2 \Rightarrow x \in C_2$

Exo 2 :

1) L'entropie de 2 événements équiprobables :

$$X = \left\{ \frac{1}{2}, \frac{1}{2} \right\}, H(x) = - \left[\frac{1}{2} \log_2 \left(\frac{1}{2} \right) + \frac{1}{2} \log_2 \left(\frac{1}{2} \right) \right] = 1$$

$$2) X = \left\{ \frac{1}{8}, \frac{3}{4}, \frac{1}{16}, \frac{1}{16} \right\}$$

$$H(x) = - \left[\frac{1}{8} \log_2 \left(\frac{1}{8} \right) + \frac{3}{4} \log_2 \left(\frac{3}{4} \right) + \frac{1}{16} \log_2 \left(\frac{1}{16} \right) + \frac{1}{16} \log_2 \left(\frac{1}{16} \right) \right]$$

$$H(x) = 1,18625$$

(1)

3/	a	b	c	d	class
	0	0	1	1	I
	1	1	0	0	II
	0	1	1	0	II
	1	1	1	1	I

- construction de l'arbre de décision à partir de la caract

a :

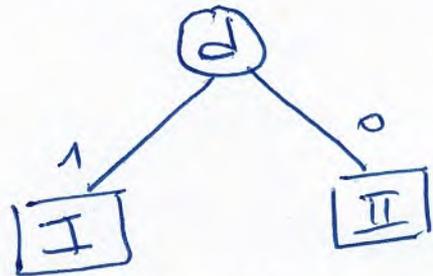
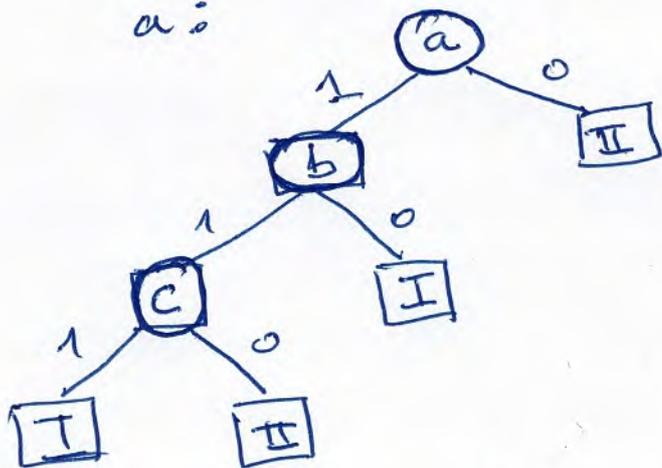


figure (*)
(reponse 4)

4/ construction de l'arbre à partir de mesure du contenu d'information pour chaque caract. a, b, c.

$$\begin{aligned}
 I(C, a) &= P(C=I, a=1) \log_2 \frac{P(C=I, a=1)}{P(C=I) P(a=1)} + \\
 &P(C=I, a=0) \log_2 \frac{P(C=I, a=0)}{P(C=I) P(a=0)} + P(C=II, a=1) \log_2 \frac{P(C=II, a=1)}{P(C=II) P(a=1)} + \\
 &P(C=II, a=0) \log_2 \frac{P(C=II, a=0)}{P(C=II) P(a=0)} = \\
 &= 0,5 \log_2 \frac{0,5}{0,5 \times 0,75} + 0 + 0,25 \log_2 \frac{0,25}{0,5 \times 0,75} + 0,25 \log_2 \frac{0,25}{0,5 \times 0,25}
 \end{aligned}$$

$$= 0,3113$$

$$I(C, b) = 0,25 \log_2 \left(\frac{0,25}{0,5 \times 0,75} \right) + 0,25 \log_2 \left(\frac{0,25}{0,5 \times 0,25} \right) +$$

$$0,5 \log_2 \left(\frac{0,5}{0,5 \times 0,75} \right) + 0 = 0,3113$$

$$I(C, c) = 0,5 \log_2 \left(\frac{0,5}{0,5 \times 0,75} \right) + 0 + 0,25 \log_2 \left(\frac{0,25}{0,5 \times 0,75} \right) + 0$$

(2)

$$I(c, d) = 0,5 \log_2 \left(\frac{0,5}{0,1 \times 0,5} \right) + 0,4 + 0,5 \log_2 \left(\frac{0,5}{0,5 \times 0,5} \right) = 1$$

la caract. I qui a un contenu d'info 1 donne plus d'info. pour déterminer la classe figure (*)

Exo 3.

Dans un problème de décision binaire, le résultat de la classification est soit positive ou négative. La matrice de confusion est :

		réel positif positif	réel négative	
		positive	négative	
résultat	positive	TP	FP	TP = True positives FP false
	négative	FN	TN	TN True negatives FN false

Nous pouvons caractériser les erreurs de classification en calculant :

$$\text{Rappel} = \text{Recall} = \frac{TP}{TP + FN}, \quad \text{TPR} = \frac{TP}{TP + FN}$$

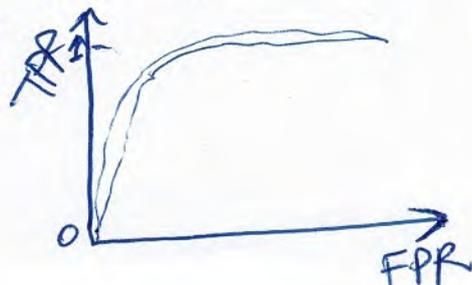
R = rate

$$\text{Précision} = \text{Precision} = \frac{TP}{TP + FP}, \quad \text{FPR} = \frac{FP}{FP + TN}$$

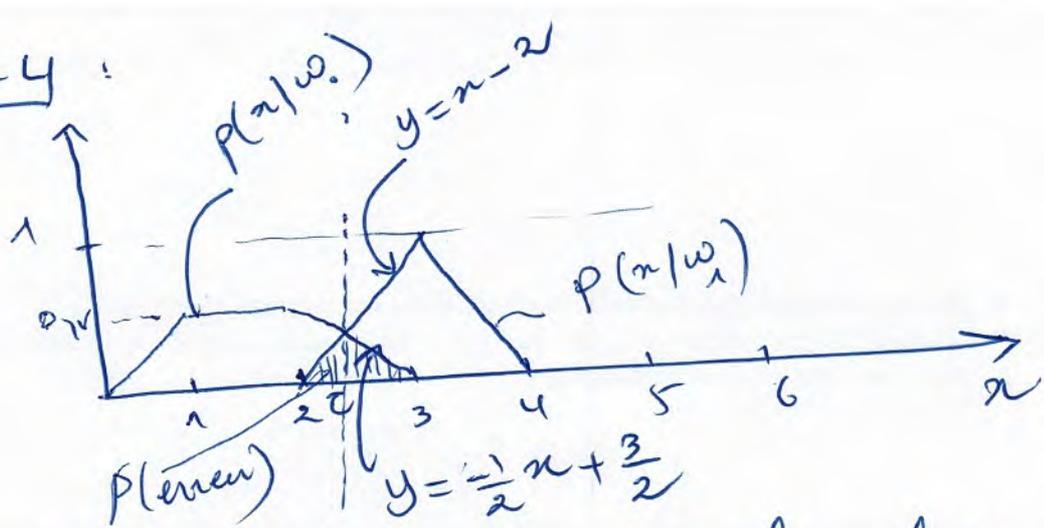
$$1/ \text{precision} = \frac{TP}{TP + FP} = \frac{300}{300 + 50} = \frac{300}{350} = \frac{6}{7}$$

$$\text{recall} = \text{rappel} = \frac{TP}{TP + FN} = \frac{300}{300 + 200} = \frac{300}{500} = \frac{3}{5}$$

2/ Pour tracer la courbe ROC, on prend le TPR sur y et le FPR sur x



Exercice 4 :



La règle de décision à erreur minimale classe x à la classe i pour laquelle $p(w_i | x)$ est maximale donc dans la région R_1 $p(w_0 | x) < p(w_1 | x)$ il est clair dans la figure que :

$$R_1 = \{x \mid x > \tau\} \text{ ou } 2 < \tau < 3 \text{ et } R_0 = R \setminus R_1$$

$$p(w_0 | x) < p(w_1 | x)$$

$$\Rightarrow p(w_0) p(x | w_0) < p(w_1) p(x | w_1)$$

$$\Rightarrow \frac{3}{5} \left(-\frac{1}{2}x + \frac{3}{2} \right) < \frac{2}{5} (x - 2) \Rightarrow x > \frac{17}{7}$$

$$\left\{ \tau = \frac{17}{7} \right\}$$

$$\begin{aligned} p(\text{erreur}) &= \int_{\tau} p(w_1 | w_0) p(w_0) dx + \int_{R_1} p(w_0) p(x | w_0) dx \\ &= \int_2^{\tau} \frac{2}{5} (x - 2) dx + \int_{\tau}^3 \left(-\frac{1}{2}x + \frac{3}{2} \right) dx = \left[\frac{x^2}{5} - \frac{4}{5}x \right]_2^{\tau} + \\ &\quad \left[-\frac{3x^2}{20} + \frac{9}{10}x \right]_{\tau}^3 = \underline{\underline{\frac{21}{245}}} \end{aligned}$$