

# Evaluation en imagerie médicale

Irène Buvat  
U678 INSERM  
Paris

[buvat@imed.jussieu.fr](mailto:buvat@imed.jussieu.fr)  
<http://www.guillemet.org/irene>

février 2005

# Plan du cours

---

- Evaluation et tests statistiques
  - population, échantillon et inférence statistique
  - distribution et caractérisation d'une population
  - intervalles de confiance
  - hypothèses  $H_0$ ,  $H_1$ , tests unilatéral et bilatéral
  - valeur de  $p$  ( $p < 0,05$ ), niveau de significativité
  - degrés de liberté
  - tests d'hypothèse
- Problème de l'évaluation diagnostique
  - Définitions classiques en évaluation diagnostique
  - Insuffisance des indices classiques
- Courbes ROC
  - Définition et construction d'une courbe ROC
  - Caractéristiques et propriétés des courbes ROC
  - Tracé des courbes ROC
- Comparaison de courbes ROC
  - Calcul de l'aire sous une courbe ROC
  - Comparaison de deux courbes
  - Comparaison de plus de deux courbes
- Considérations pratiques en analyse ROC
  - Nombre de cas à inclure
  - Sélection des cas
  - Ordre de lecture
  - Gold standard imparfait
  - Echelle de cotation
  - Paramétrique ou non paramétrique
  - Lectures multiples
- Annexes

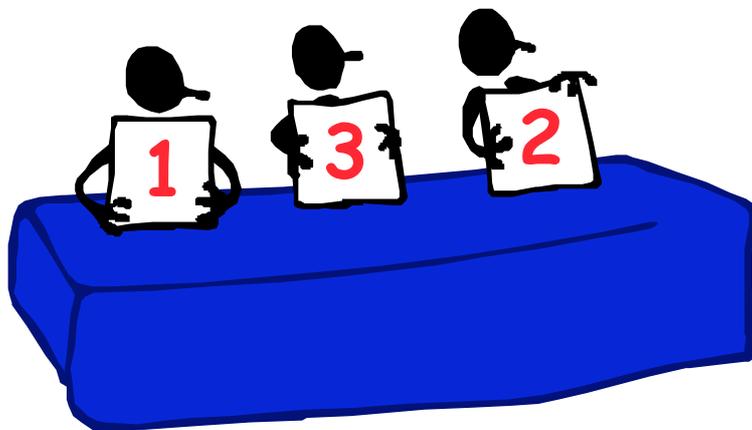
# Evaluation diagnostique

---

- Comment évaluer l'utilité diagnostique d'un **indice** ?
  - marqueur biologique
  - variable extraite d'une image
  - diagnostic posé par un observateur à partir d'une image



- Y a-t-il une corrélation entre la valeur de l'indice et la présence de l'anomalie ?
- Avec quelle fiabilité l'indice permet-il de prédire la présence de l'anomalie ?
- L'indice 1 est-il meilleur ou moins "bon" que l'indice 2 ?
  - comparaison de marqueurs biologiques
  - comparaison de variables extraites des images
  - comparaison de deux types d'images



# Comment répondre ?

---

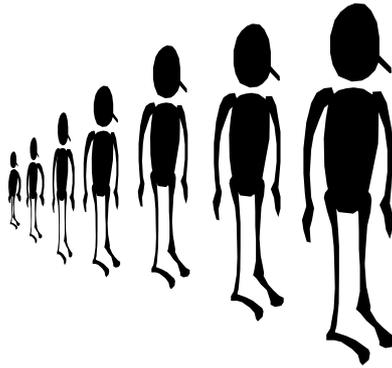
## Effectuer des tests statistiques

- Procédure permettant de déterminer si une hypothèse est acceptée ou rejetée, de façon statistiquement significative
- Utilisé quasiment systématiquement pour présenter des résultats de façon objective
- Repose sur un certain nombre de notions à comprendre :
  - population, échantillon et inférence statistique
  - distribution d'une population
  - moyenne, écart-type
  - intervalles de confiance
  - hypothèse  $H_0$
  - tests unilatéral et bilatéral
  - valeur de  $p$  ( $p < 0,05$ )
  - erreurs de type I et II,  $\alpha$  et  $\beta$

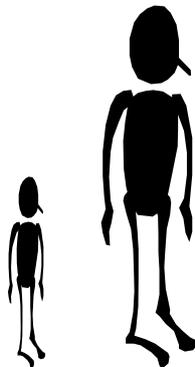
# Population, échantillons et inférence statistique

---

- Population : grand ensemble de valeurs, d'observations, d'objets, trop gros en pratique pour pouvoir faire l'objet de mesures exactes pour le caractériser



- Echantillon : petite partie d'une population qu'il est possible d'observer et sur laquelle il est possible de faire des mesures

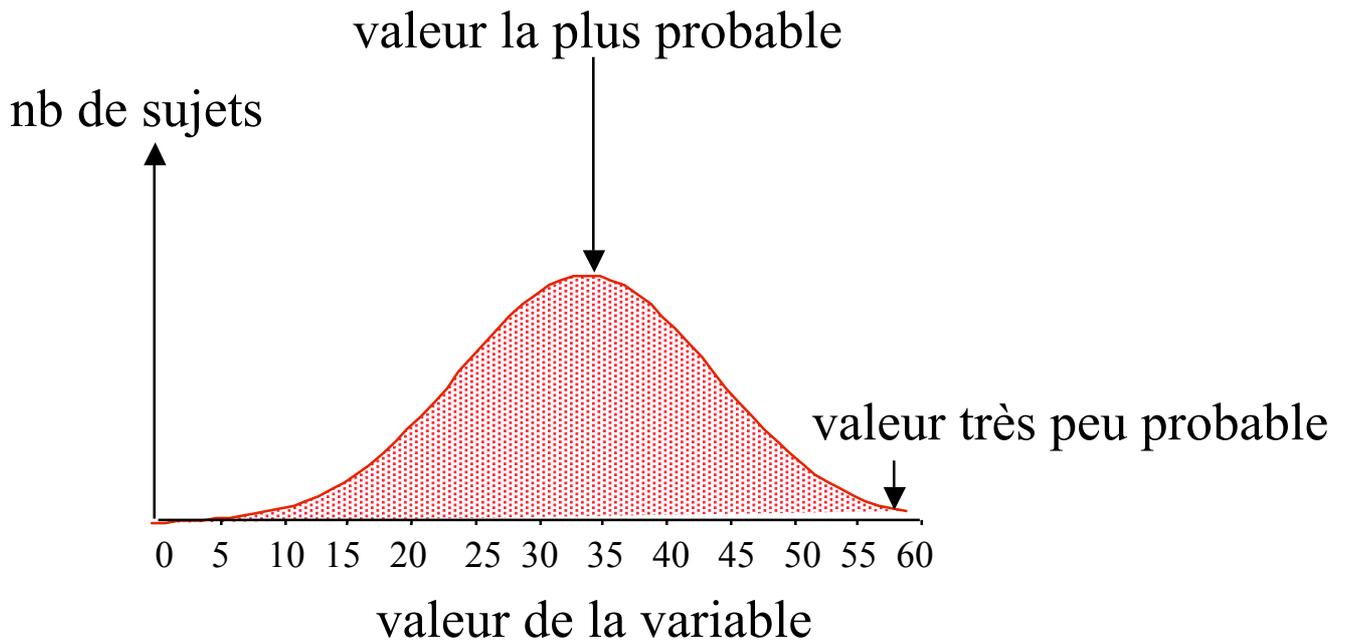


- Inférence statistique : tirer des enseignements sur la population à partir des observations faites sur l'échantillon
- Exemple : estimer la moyenne d'une population à partir de la moyenne d'un échantillon

# Distribution d'une population

---

- Diagramme représentant la fréquence des différentes valeurs prises par la population



- Il existe différentes formes de distributions, la plus fréquente étant la distribution normale

# Caractérisation d'une population : moyenne, écart-type

---

7, 6, 3, 11, 5, 7, 7, 9, 6, 5

- Moyenne : somme de toutes les observations  $x_i$  divisée par le nombre d'observation  $N$

$$\begin{aligned}\text{moyenne} &= x_{\text{moyen}} = \sum_i x_i / N \\ &= (7 + 6 + 3 + 11 + 5 + 7 + 7 + 9 + 6 + 5) / 10 \\ &= 66 / 10 = 6,6\end{aligned}$$

Caractérise la « position » de la distribution

- Ecart-type (racine carré de la variance) caractérise la dispersion (l'étalement) de la distribution

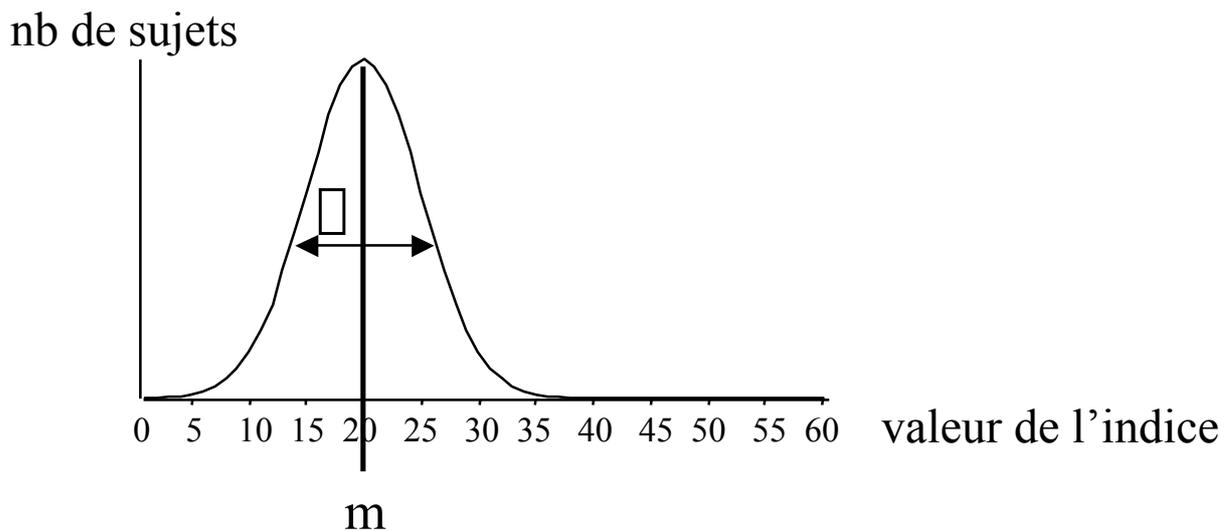
$$\begin{aligned}\text{Écart-type} &= \sigma = \left\{ \sum_i (x_i - x_{\text{moyen}})^2 / (N-1) \right\}^{1/2} \\ &= \left\{ \left[ \sum_i x_i^2 - (\sum_i x_i)^2 / N \right] / (N-1) \right\}^{1/2} \\ &= 2,2\end{aligned}$$

- Coefficient de variation =  $100 * \text{écart-type} / \text{moyenne}$

# La loi normale (ou gaussienne)

---

- Loi symétrique, en forme de cloche, décrivant bien la distribution statistique de nombreux indices « naturels » (tension artérielle, taille, etc).
- Entièrement caractérisée par 2 paramètres : moyenne  $m$  et écart-type  $\sigma$



$$y = \frac{1}{\sqrt{2\pi}\sigma} \exp \frac{-(x - m)^2}{2\sigma^2}$$

## Calcul d'écart-types

---

- Ecart-type de la moyenne d'un échantillon de taille  $N$  (à ne pas confondre avec l'écart-type de l'échantillon)

$$ET = \text{écart-type de l'échantillon} / N^{1/2}$$

- Ecart-type de la différence entre les 2 moyennes  $m_1$  et  $m_2$  d'échantillons de tailles  $N_1$  et  $N_2$  et d'écart-type  $\sigma_1$  et  $\sigma_2$

$$ET = [(\sigma_1^2/N_1 + \sigma_2^2/N_2)]^{1/2}$$



En pratique, une valeur résultat devrait toujours être accompagnée de son écart-type, qui donne une indication sur la confiance qu'on peut accorder à la valeur

# Intervalles de confiance

---

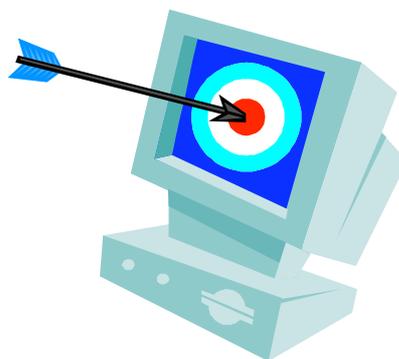
- Intervalle dans lequel la probabilité P pour que la valeur du paramètre k recherché se trouve est de X%
- Pour une population suivant une loi normale, cet intervalle est donnée par

$$[k_{\text{moyen}} - 1,96 \text{ ET} ; k_{\text{moyen}} + 1,96 \text{ ET}]$$

où  $k_{\text{moyen}}$  est la moyenne sur l'échantillon observé  
ET représente l'écart-type de  $k_{\text{moyen}}$   
et P = 95% (N>30)

$$[k_{\text{moyen}} - 1,64 \text{ ET} ; k_{\text{moyen}} + 1,64 \text{ ET}] \text{ pour } P = 90\%$$

$$[k_{\text{moyen}} - 2,576 \text{ ET} ; k_{\text{moyen}} + 2,576 \text{ ET}] \text{ pour } P = 99\%$$



Objectif : répondre à des questions

---



Effectuer des tests statistiques

## Notion d'hypothèse H0

---

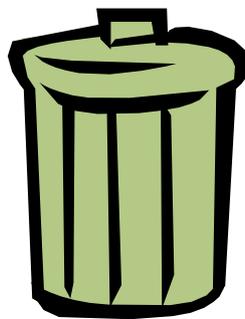
- H0 : hypothèse nulle correspondant à l'hypothèse que l'on souhaite tester

e.g. :

H0 :  $A = B$  : il n'y a pas de différence entre les valeurs de fraction d'éjection mesurées à partir des images de type A et celles mesurées à partir des images de type B

H0 : les observations proviennent d'une distribution de Poisson

L'hypothèse nulle est généralement formulée de façon à être rejetée (sauf dans le cas d'ajustement de courbes)



Pourquoi ?

Car il y a en général plusieurs hypothèses alternatives possibles, et qu'il est plus facile de formuler l'hypothèse à rejeter que toutes les alternatives possibles

# Notion d'hypothèse alternative

---

- H1 : hypothèse à opposer à H0

e.g. :

H0 :  $A = B$  : il n'y a pas de différence entre les valeurs de fraction d'éjection mesurées à partir des images de type A et celles mesurées à partir des images de type B

H1 :  $A \neq B$  : les valeurs de fraction d'éjection mesurées à partir des images de type A sont différentes de celles mesurées à partir des images de type B



- 2 types d'hypothèses alternatives :

- bilatérale (2-tailed)

H1 :  $A \neq B$  : les valeurs sont différentes

- unilatérale (1-tailed)

H1 :  $A > B$

ou

H1 :  $A < B$

# Valeurs de p

---

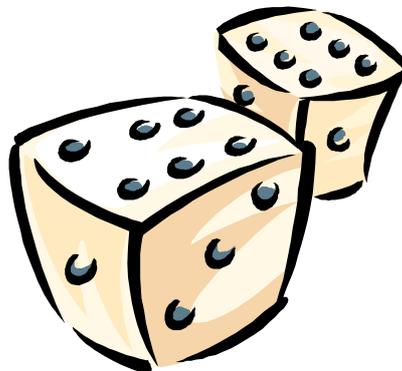
- $p < 0,05$

Valeur de p associée à un test = probabilité d'observer la valeur obtenue si l'hypothèse  $H_0$  est vraie

Exemple :

- les patients ayant reçu la thérapie X ont eu moins d'accidents cardiaques que les patients sous placebo ( $p < 0,05$ )

Signifie que la probabilité pour que les patients du groupe I aient eu moins d'accidents cardiaques que les patients du groupe II uniquement par hasard (sans relation avec la thérapie) est inférieure à 5% (moins d'1 chance sur 20)



# Significativité statistique, niveau de significativité

---

- Fixer un niveau de significativité  $\alpha$ , c'est choisir avec quelle probabilité on accepte de rejeter  $H_0$  alors que  $H_0$  est vraie
- Rejeter  $H_0$  alors que  $H_0$  est vraie = erreur de type I, habituellement notée  $\alpha$  ( $\alpha = 0,05 = 5\%$ )
- Erreur de type II = accepter  $H_0$  alors qu'elle est fautive, habituellement notée  $\beta$
- Puissance du test = probabilité de rejeter  $H_0$  à juste titre =  $1 - \beta$
- $\alpha$  et  $\beta$  ne sont pas indépendants : si  $\alpha$  augmente,  $\beta$  diminue et réciproquement

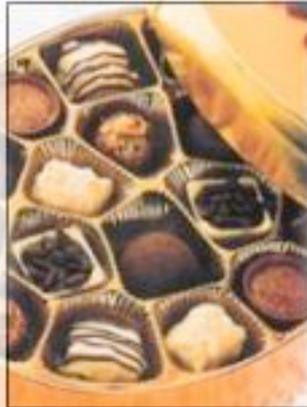


# Degrés de liberté

---

- Nombre d'observations variant indépendamment après que certaines contraintes aient été placées sur ces observations
- Le plus souvent,  $ddl = N-1$
- Exemple : choisir dans une boîte de N chocolats

Pour chaque chocolat, on a le choix, jusqu'à ce qu'il ne reste plus qu'un chocolat dans la boîte, où là, on n'a plus le choix. On a donc  $N-1$  choix.



# Généralités sur les tests d'hypothèse

---

- La procédure implique le calcul d'une variable : la statistique de test
- Le test peut être paramétrique (faisant des hypothèses sur la distribution de la population impliquée dans le test) ou non paramétrique
- Il existe un grand ensemble de tests statistiques, chacun étant approprié pour tester certains types d'hypothèse  $H_0$
- e.g.,
  - Pour un appareil de comptage :  
 $H_0$  : il n'y a pas de différence entre les nombres de coups prédits et ceux mesurés  
Test approprié : test du Chi-2
  - Pour l'étude de l'effet d'une substance :  
 $H_0$  : la tension artérielle mesurée après traitement est identique à celle mesurée avant traitement  
Test approprié : test t apparié

# Principe d'un test d'hypothèse statistique

---

- Formuler clairement le problème à étudier
- Formuler l'hypothèse  $H_0$  correspondante
- Déterminer le test d'hypothèse approprié pour tester  $H_0$  :  
e.g. :  
test t de Student, test z, test du Chi-2
- Choisir un degré de significativité  $\alpha$ , i.e., la probabilité d'erreur de type I : probabilité de rejeter  $H_0$  alors que  $H_0$  est vraie (erreur de type I, habituellement,  $\alpha = 0,05 = 5\%$ )
- Calculer la statistique de test  $s$   
e.g. : valeur du t de Student, valeur de z, valeur du Chi-2
- Consulter la table appropriée indiquant la probabilité  $p$  d'observer la valeur de la statistique  $s$  si  $H_0$  est vraie
- Si  $p < \alpha$ , rejeter  $H_0$ , sinon, accepter  $H_0$

## Exemple : le test t de Student

---

- Test paramétrique qui suppose que :
  - la distribution statistique des populations desquelles sont issus les échantillons observés suivent des lois normales
  - les échantillons sont indépendants
  - les populations normales ont la même variance
  - les variables caractérisant les populations sont continues
- Test robuste, c'est-à-dire restant valide pour de faibles écarts aux conditions ci-dessus
- Test approprié pour de petits échantillons ( $N < 30$ )
- Statistique de test :

$$t = \frac{\text{moyenne1} - \text{moyenne2}}{\text{écart-type}_{(\text{moyenne1} - \text{moyenne2})}}$$

- Test approprié pour tester différentes hypothèses

## Exemple : test t appliqué à un échantillon

---

- On dispose d'un échantillon de N mesures, de moyenne m et d'écart-type  $\sigma$
- On veut savoir si la moyenne M de la population dont est issu l'échantillon est significativement différente de la moyenne connue  $\mu$  d'une population donnée
- Statistique de test :

$$t = \frac{m - \mu}{\sigma / N^{1/2}}$$

- Comparer la valeur de t à la valeur dans la table en considérant N-1 ddl

# Table des valeurs de t

**TABLE A-2**

Critical values						ddl
<i>n</i>	p=0,1 p=0,2	p=0,05 p=0,1	p=0,025 p=0,05	p=0,01 p=0,02	p=0,005 (unilatéral) p=0,01 (bilatéral)	
2	3.078	6.314	12.706	31.821	63.657	1
3	1.886	2.920	4.303	6.965	9.925	2
4	1.638	2.353	3.182	4.541	5.841	3
5	1.533	2.132	2.776	3.747	4.604	4
6	1.476	2.015	2.571	3.365	4.032	5
7	1.440	1.943	2.447	3.143	3.707	6
8	1.415	1.895	2.365	2.998	3.499	7
9	1.397	1.860	2.306	2.896	3.355	8
10	1.383	1.833	2.262	2.821	3.250	9
11	1.372	1.812	2.228	2.764	3.169	10
12	1.363	1.796	2.201	2.718	3.106	11
13	1.356	1.782	2.179	2.681	3.055	12
14	1.350	1.771	2.160	2.650	3.012	13
15	1.345	1.761	2.145	2.624	2.977	14
16	1.341	1.753	2.131	2.602	2.947	15
17	1.337	1.746	2.120	2.583	2.921	16
18	1.333	1.740	2.110	2.567	2.898	17
19	1.330	1.734	2.101	2.552	2.878	18
20	1.328	1.729	2.093	2.539	2.861	19
21	1.325	1.725	2.086	2.528	2.845	20
22	1.323	1.721	2.080	2.518	2.831	21
23	1.321	1.717	2.074	2.508	2.819	22
24	1.319	1.714	2.069	2.500	2.807	23
25	1.318	1.711	2.064	2.492	2.797	24
26	1.316	1.708	2.060	2.485	2.787	25
27	1.315	1.706	2.056	2.479	2.779	26
28	1.314	1.703	2.052	2.473	2.771	27
29	1.313	1.701	2.048	2.467	2.763	28
30	1.311	1.699	2.045	2.462	2.756	29
inf.	1.282	1.645	1.960	2.326	2.576	inf.

• Exemple :

Echantillon de 20 sujets dont la tension artérielle diastolique vaut en moyenne  $m = 98$  ( $\sigma=6,2$ ).

H0 : cet échantillon est issu d'une population dont la tension artérielle diastolique moyenne est  $\mu=93$

H1 : cet échantillon est issu d'une population dont la tension artérielle diastolique moyenne est supérieure à 93

$$t = (98-93)/(6,2/20^{1/2}) = 3,61$$

$$p < 0,005$$

## Exemple : test t entre 2 échantillons indépendants

---

- On dispose de 2 échantillons de  $N_1$  et  $N_2$  mesures chacun, de moyennes  $m_1$  et  $m_2$  et d'écart-type  $\sigma_1$  et  $\sigma_2$
- $H_0$  : il n'y a pas de différence entre la valeur du paramètre entre les 2 populations dont sont issus les 2 échantillons
- Statistique de test :

$$t = \frac{m_1 - m_2}{\text{écart-type}_{(m_1-m_2)}}$$

- $\text{écart-type}_{(m_1-m_2)} = [s^2(1/N_1 + 1/N_2)]^{1/2}$

où  $s^2 = [(N_1-1) \sigma_1^2 + (N_2-1) \sigma_2^2] / (N_1+N_2-2)$

$$\text{et ddl} = N_1 + N_2 - 2$$

Exemple :

Echantillon 1 : 2, 4, 3 et 5

Echantillon 2 : 3, 3, 1 et 2

$H_1$  : il y a une différence entre la valeur du paramètre entre les 2 populations

$$t = 1,56$$

$$\text{ddl} = 6$$

$0,1 < p < 0,2$  : on ne peut pas rejeter  $H_0$

## Exemple : test z entre 2 échantillons indépendants

---

- On dispose de 2 échantillons de N1 et N2 mesures chacun ( $N1 > 30$  et  $N2 > 30$ ), de moyennes  $m_1$  et  $m_2$  et d'écart-type  $\sigma_1$  et  $\sigma_2$
- Les distributions des populations dont sont issus les 2 échantillons sont approximativement normales
- $H_0$  : il n'y a pas de différence entre la valeur du paramètre entre les 2 populations dont sont issus les 2 échantillons
- Statistique de test :

$$Z = \frac{m_1 - m_2}{\text{écart-type}_{(m1-m2)}}$$

- $\text{écart-type}_{(m1-m2)} = [(\sigma_1^2/N1 + \sigma_2^2 /N2)]^{1/2}$
- Comparer à la valeur de z critique dans la table

# Table des valeurs de probabilités pour une loi z

**TABLE A-1**

Probability table for the normal distribution

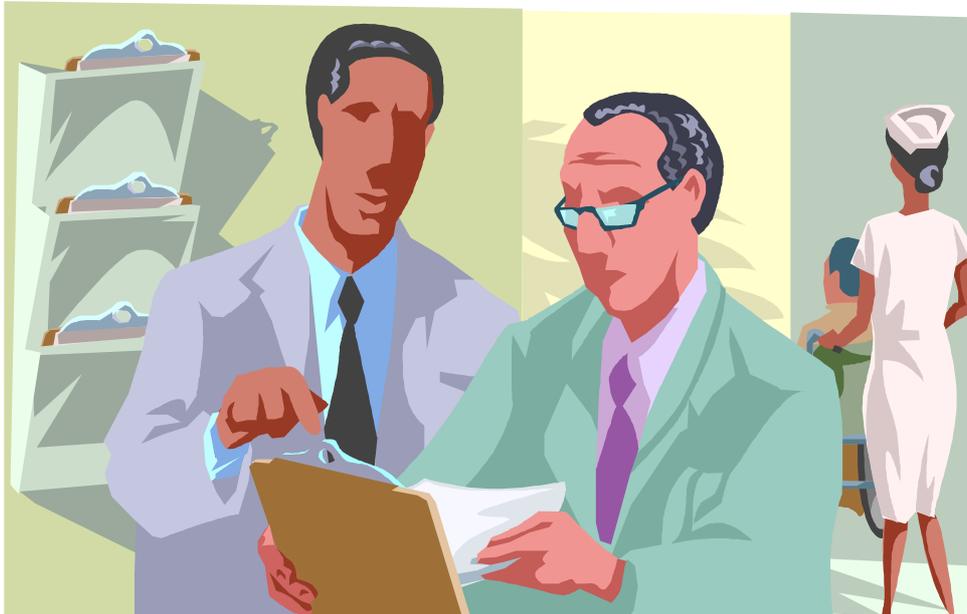
z	α	z	α	z	α	z	α	z	α	z	α	z	α	z	α
0.00	.5000	0.35	.3632	0.70	.2420	1.05	.1469	1.40	.0808	1.75	.0401	2.10	.0179	2.45	.0071
0.01	.4960	0.36	.3594	0.71	.2389	1.06	.1446	1.41	.0793	1.76	.0392	2.11	.0174	2.46	.0069
0.02	.4920	0.37	.3557	0.72	.2358	1.07	.1423	1.42	.0778	1.77	.0384	2.12	.0170	2.47	.0068
0.03	.4880	0.38	.3520	0.73	.2327	1.08	.1401	1.43	.0764	1.78	.0375	2.13	.0166	2.48	.0066
0.04	.4840	0.39	.3483	0.74	.2296	1.09	.1379	1.44	.0749	1.79	.0367	2.14	.0162	2.49	.0064
0.05	.4801	0.40	.3446	0.75	.2266	1.10	.1357	1.45	.0735	1.80	.0359	2.15	.0158	2.50	.0062
0.06	.4761	0.41	.3409	0.76	.2236	1.11	.1335	1.46	.0721	1.81	.0351	2.16	.0154	2.51	.0060
0.07	.4721	0.42	.3372	0.77	.2206	1.12	.1314	1.47	.0708	1.82	.0344	2.17	.0150	2.52	.0059
0.08	.4681	0.43	.3336	0.78	.2177	1.13	.1292	1.48	.0694	1.83	.0336	2.18	.0146	2.53	.0057
0.09	.4641	0.44	.3300	0.79	.2148	1.14	.1271	1.49	.0681	1.84	.0329	2.19	.0143	2.54	.0055
0.10	.4602	0.45	.3264	0.80	.2119	1.15	.1251	1.50	.0668	1.85	.0322	2.20	.0139	2.55	.0054
0.11	.4562	0.46	.3228	0.81	.2090	1.16	.1230	1.51	.0655	1.86	.0314	2.21	.0136	2.56	.0052
0.12	.4522	0.47	.3192	0.82	.2061	1.17	.1210	1.52	.0643	1.87	.0307	2.22	.0132	2.57	.0051
0.13	.4483	0.48	.3156	0.83	.2033	1.18	.1190	1.53	.0630	1.88	.0301	2.23	.0129	2.58	.0049
0.14	.4443	0.49	.3121	0.84	.2005	1.19	.1170	1.54	.0618	1.89	.0294	2.24	.0125	2.59	.0048
0.15	.4404	0.50	.3085	0.85	.1977	1.20	.1151	1.55	.0606	1.90	.0287	2.25	.0122	2.60	.0047
0.16	.4364	0.51	.3050	0.86	.1949	1.21	.1131	1.56	.0594	1.91	.0281	2.26	.0119	2.61	.0045
0.17	.4325	0.52	.3015	0.87	.1922	1.22	.1112	1.57	.0582	1.92	.0274	2.27	.0116	2.62	.0044
0.18	.4286	0.53	.2981	0.88	.1894	1.23	.1093	1.58	.0571	1.93	.0268	2.28	.0113	2.63	.0043
0.19	.4247	0.54	.2946	0.89	.1867	1.24	.1075	1.59	.0559	1.94	.0262	2.29	.0110	2.64	.0041
0.20	.4207	0.55	.2912	0.90	.1841	1.25	.1056	1.60	.0548	1.95	.0256	2.30	.0107	2.65	.0040
0.21	.4168	0.56	.2877	0.91	.1814	1.26	.1038	1.61	.0537	1.96	.0250	2.31	.0104	2.66	.0039
0.22	.4129	0.57	.2843	0.92	.1788	1.27	.1020	1.62	.0526	1.97	.0244	2.32	.0102	2.67	.0038
0.23	.4090	0.58	.2810	0.93	.1762	1.28	.1003	1.63	.0516	1.98	.0239	2.33	.0099	2.68	.0037
0.24	.4052	0.59	.2776	0.94	.1736	1.29	.0985	1.64	.0505	1.99	.0233	2.34	.0096	2.69	.0036
0.25	.4013	0.60	.2743	0.95	.1711	1.30	.0963	1.65	.0495	2.00	.0228	2.35	.0094	2.70	.0035
0.26	.3974	0.61	.2709	0.96	.1685	1.31	.0951	1.66	.0485	2.01	.0222	2.36	.0091	2.71	.0034
0.27	.3936	0.62	.2676	0.97	.1660	1.32	.0934	1.67	.0475	2.02	.0217	2.37	.0089	2.72	.0033
0.28	.3897	0.63	.2643	0.98	.1635	1.33	.0918	1.68	.0465	2.03	.0212	2.38	.0087	2.73	.0032
0.29	.3859	0.64	.2611	0.99	.1611	1.34	.0901	1.69	.0455	2.04	.0207	2.39	.0084	2.74	.0031
0.30	.3821	0.65	.2578	1.00	.1587	1.35	.0885	1.70	.0446	2.05	.0202	2.40	.0082	2.75	.0030
0.31	.3783	0.66	.2546	1.01	.1562	1.36	.0869	1.71	.0436	2.06	.0197	2.41	.0080	2.76	.0029
0.32	.3745	0.67	.2514	1.02	.1539	1.37	.0853	1.72	.0427	2.07	.0192	2.42	.0078	2.77	.0028
0.33	.3707	0.68	.2483	1.03	.1515	1.38	.0838	1.73	.0418	2.08	.0188	2.43	.0075	2.78	.0027
0.34	.3669	0.69	.2451	1.04	.1492	1.39	.0823	1.74	.0409	2.09	.0183	2.44	.0073	2.79	.0026

- Valeurs adaptées aux tests unilatéral
- Pour test bilatéral, multiplier la valeur de probabilité par 2

# Problème de l'évaluation diagnostique

---

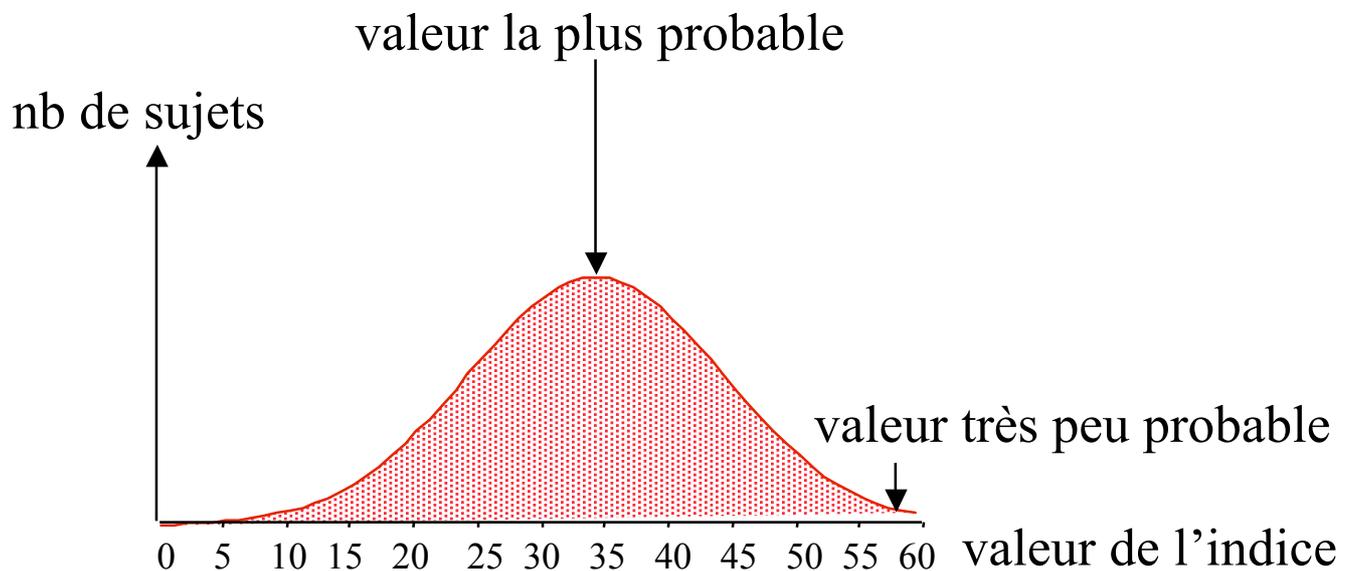
- Comment évaluer l'utilité diagnostique d'un **indice** ?
  - marqueur biologique
  - variable extrait d'une image
  - diagnostic posé par un observateur à partir d'une image



## Difficultés posées par l'évaluation (1)

---

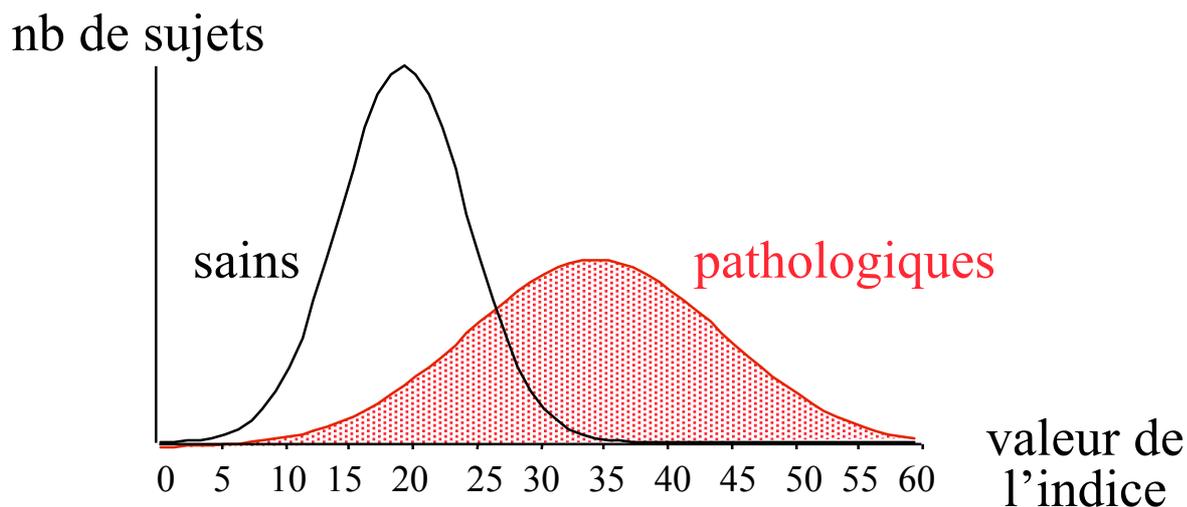
- Pour une population « homogène », l'indice peut prendre différentes valeurs.
- L'ensemble de valeurs que peut prendre l'indice est décrit par sa distribution statistique.
  
- Distribution statistique de la « valeur » de l'indice (nb de cas en fonction de la valeur)



## Difficultés posées par l'évaluation (2)

---

- Recouvrement des valeurs de l'indice pour les populations avec et sans l'anomalie



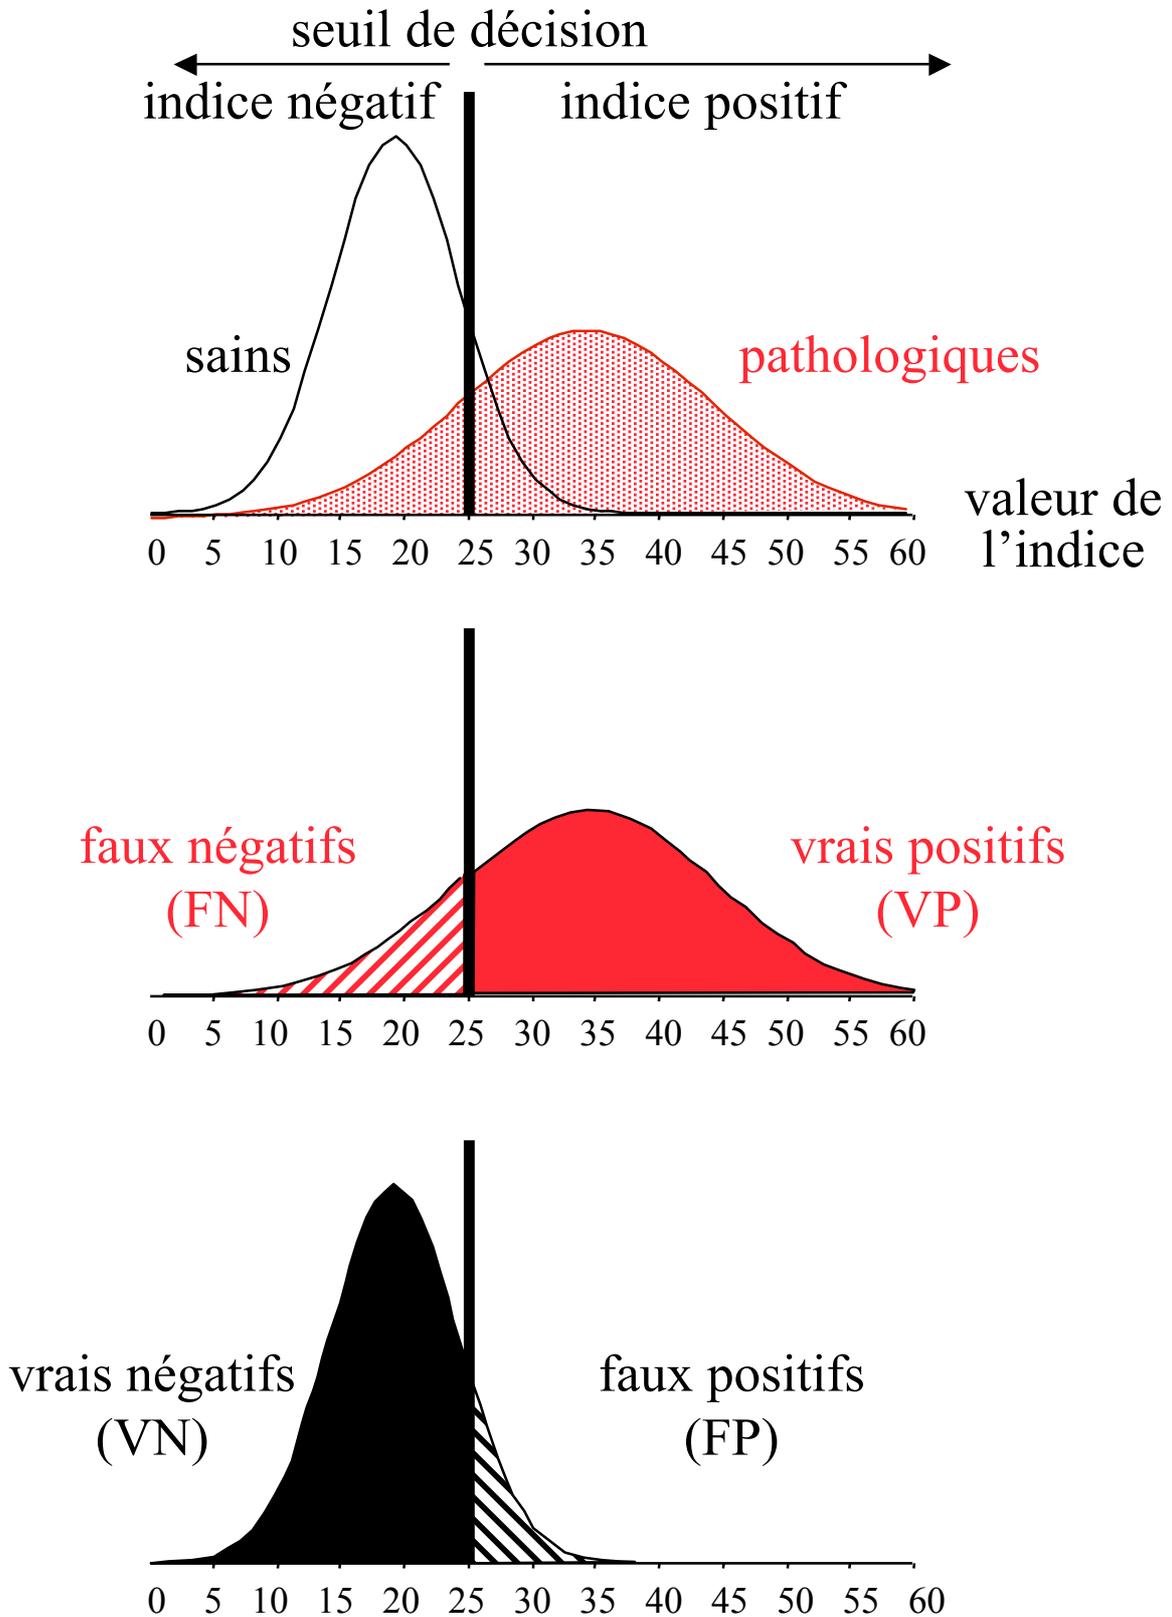
↑  
valeur de l'indice = 20  
sain ou pathologique ?



**nécessité de choisir un seuil de décision**

➔ les performances diagnostiques de l'indice dépendent du seuil de décision

# Seuil de décision et classification des sujets



# Définitions pour l'évaluation diagnostique

---

		PATHOLOGIE	
		absente	présente
INDICE	négatif	vrais négatifs VN	faux négatifs FN
	positif	faux positifs FP	vrais positifs VP

- Fraction de vrais positifs  $FVP = \frac{VP}{VP + FN} = \text{sensibilité}$
- Fraction de vrais négatifs  $FVN = \frac{VN}{VN + FP} = \text{spécificité}$
- Fraction de faux positifs  $FFP = \frac{FP}{FP + VN} = 1 - FVN$
- Fraction de faux négatifs  $FFN = \frac{FN}{FN + VP} = 1 - FVP$
- Valeur prédictive positive  $VPP = \frac{VP}{VP + FP}$
- Valeur prédictive négative  $VPN = \frac{VN}{VN + FN}$

# Equivalence avec les probabilités conditionnelles

---

P = statut réel de la pathologie

T = résultat issu de l'indice

quand  
↓

- Fraction de vrais positifs  $FVP = \frac{VP}{VP + FN} = \text{Prob}(T+ | P+)$
- Fraction de vrais négatifs  $FVN = \frac{VN}{VN + FP} = \text{Prob}(T- | P-)$
- Fraction de faux positifs  $FFP = \frac{FP}{FP + VN} = \text{Prob}(T+ | P-)$
- Fraction de faux négatifs  $FFN = \frac{FN}{FN + VP} = \text{Prob}(T- | P+)$
- Valeur prédictive positive  $VPP = \frac{VP}{VP + FP} = \text{Prob}(P+ | T+)$
- Valeur prédictive négative  $VPN = \frac{VN}{VN + FN} = \text{Prob}(P- | T-)$
- Prévalence de la pathologie  $Prév = \text{Prob}(P+)$



# Exemple

---

Population de 1200 sujets

		PATHOLOGIE	
		absente	présente
INDICE	négatif	vrais négatifs 900	faux négatifs 60
	positif	faux positifs 100	vrais positifs 140

- sensibilité ?
- spécificité ?
- FFP ?
- FFN ?
- VPP ?
- VPN ?
- Prévalence ?

# Solution

---

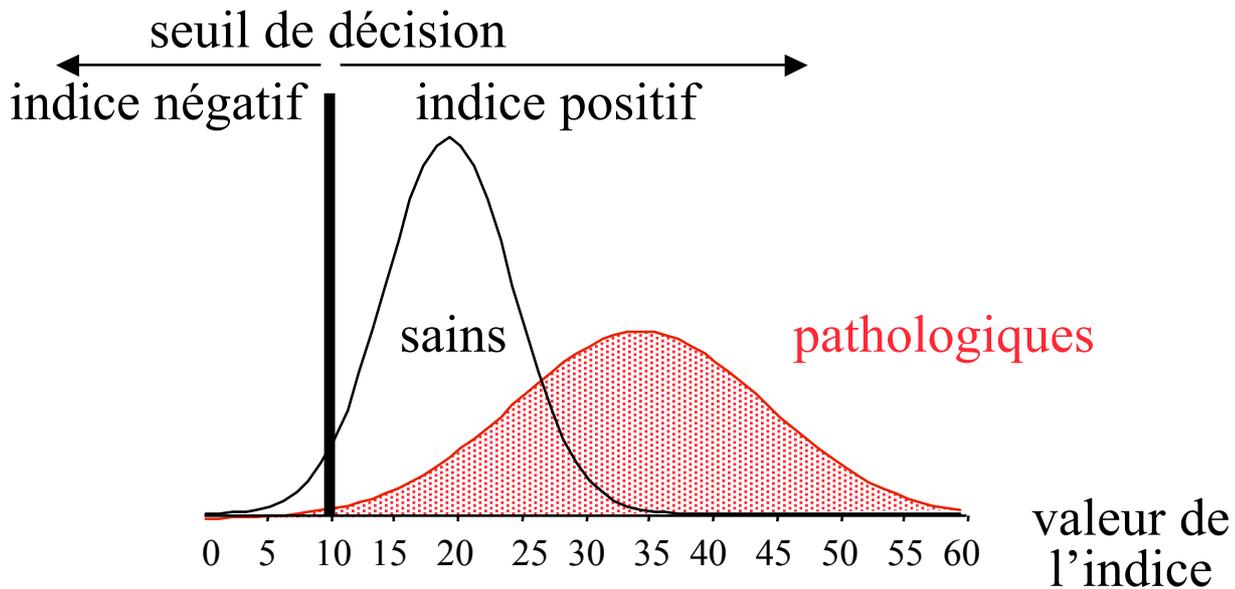
Population de 1200 sujets

		PATHOLOGIE	
		absente	présente
INDICE	négatif	vrais négatifs 900	faux négatifs 60
	positif	faux positifs 100	vrais positifs 140

- sensibilité = FVP =  $140 / 200 = 0.70 = 70\%$
- spécificité = FVN =  $900 / 1000 = 0.90 = 90\%$
- FFP =  $100 / 1000 = 0.1 = 10\%$
- FFN =  $60 / 200 = 0.3 = 30\%$
- VPP =  $140 / 240 = 0.58 = 58\%$
- VPN =  $900 / 960 = 0.94 = 94\%$
- Prévalence =  $200 / 1200 = 0.17 = 17\%$

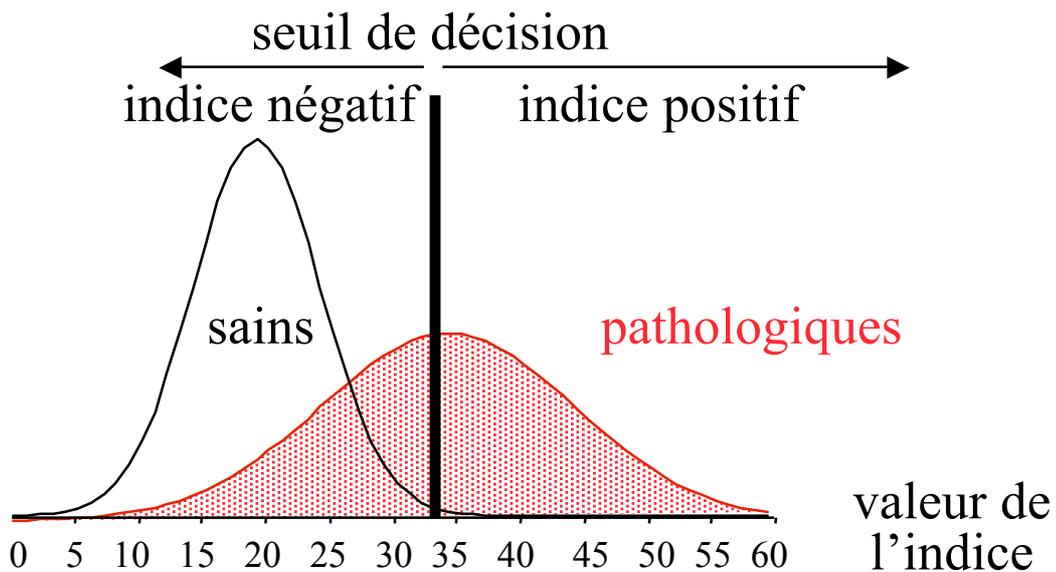
# Sensibilité, spécificité et seuil de décision

- Comment choisir le seuil de décision pour maximiser la sensibilité d'un indice ?



➔ chute dramatique de la spécificité

- Comment choisir le seuil de décision pour maximiser la spécificité d'un indice ?

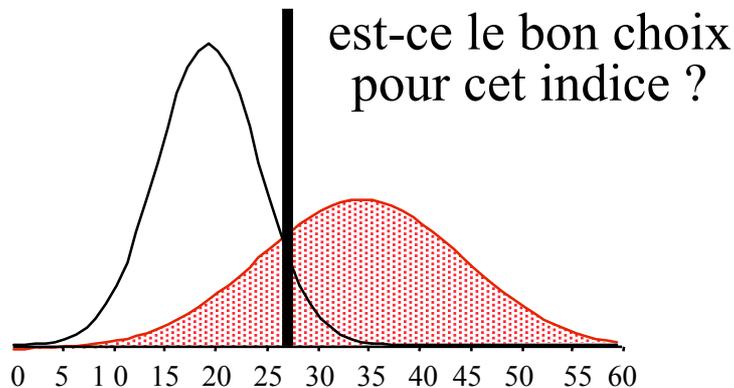


➔ chute dramatique de la sensibilité

# Insuffisance des sensibilités et spécificités

---

- Valeurs dépendant du choix du seuil de décision



- Comment comparer deux indices A et B ?

Le seuil de décision optimal pour un indice n'est pas nécessairement optimal pour l'autre

- Comment comparer deux indices A et B ?

indice A : sensibilité = 80% spécificité = 65%

indice B : sensibilité = 90% spécificité = 50%

Quel est le meilleur ?

- Contrôle du seuil de décision

indice = valeur numérique

➡ aisé

indice = diagnostic posé à partir d'une image

➡ seuil subjectif, difficilement contrôlable

# Indice composite ?

- Combiner sensibilité et spécificité en un nouveau critère ?

$$\text{exactitude} = \frac{VP + VN}{VP + VN + FP + FN}$$

		PATHOLOGIE			
		absente	présente		
INDICE A	negatif	vrais négatifs 900	faux négatifs 60	sensibilité = 70%	spécificité = 90%
	positif	faux positifs 100	vrais positifs 140		
INDICE B	negatif	vrais négatifs 960	faux négatifs 120	sensibilité = 40%	spécificité = 96%
	positif	faux positifs 40	vrais positifs 80		

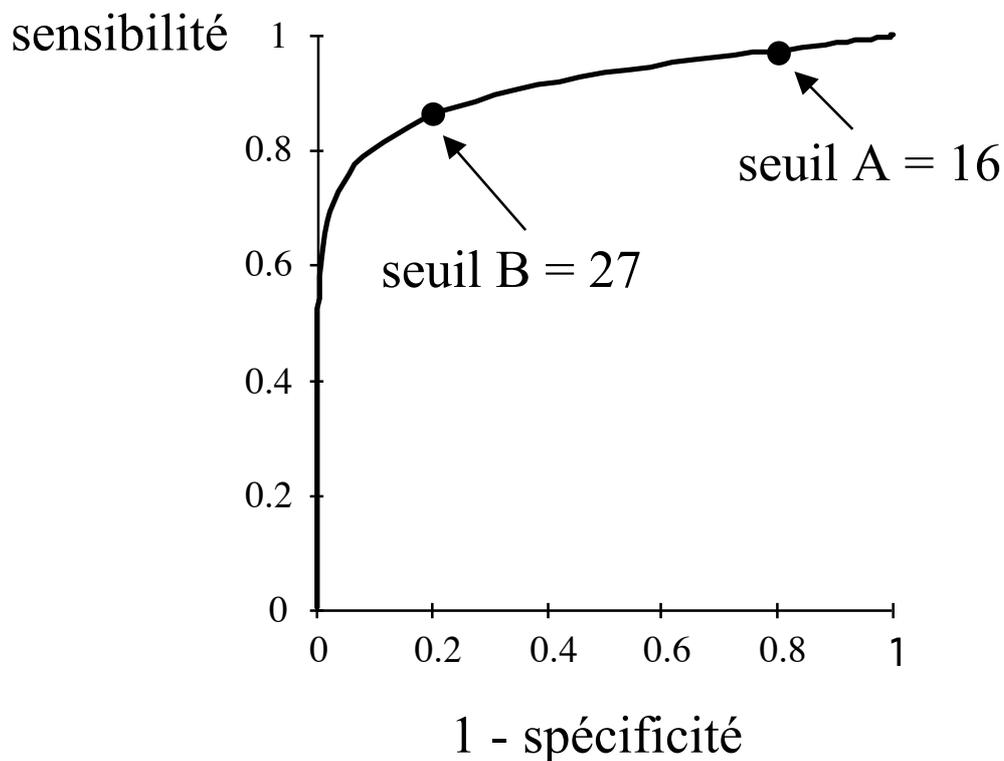
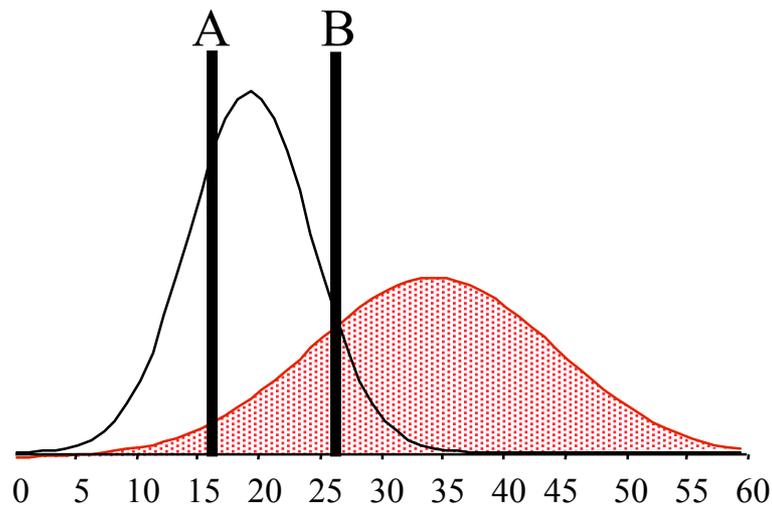
➡ même exactitude pour des performances différentes

- peu affectée par les valeurs de sensibilité dans certains cas (faible ou forte prévalence) :  
e.g., si prévalence = 5% et tous les cas diagnostiqués négatifs

➡ exactitude = 95% !

# Quelle solution ? Courbes ROC

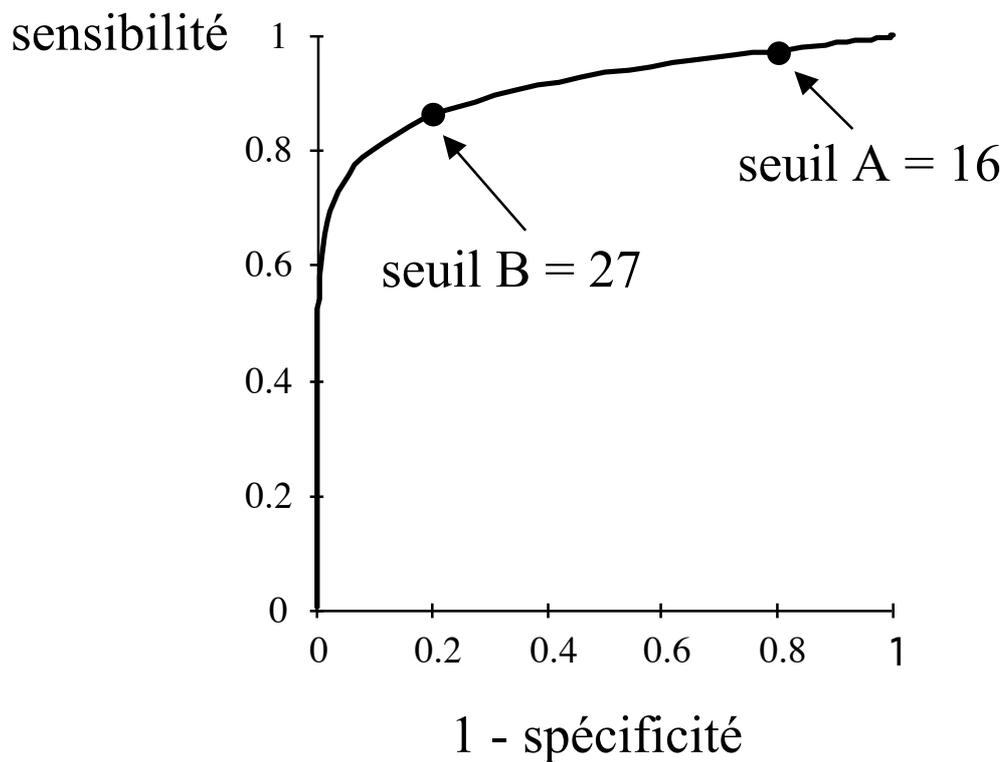
- Prend en compte la variabilité des performances de classification en fonction de la valeur du seuil de décision



# Origine de la terminologie

---

- Receiver : du récepteur (observateur)
- Operating : pour n'importe quel point d'opération
- Characteristic : caractéristiques de détection de l'indice

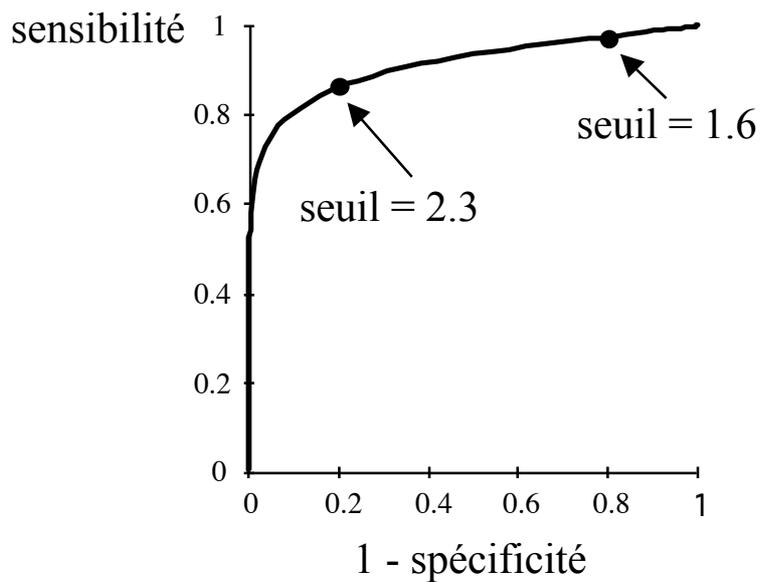


# Construction d'une courbe ROC (1)

---

- Indice correspondant à des valeurs numériques

individu	1	2	3	4	5	....	N
nature de l'individu (S ou P)	S	P	S	S	P	....	P
valeur de l'indice	1.8	2.3	2.1	1.7	2.1		1.9



➡ variation quasi-continue du seuil de décision

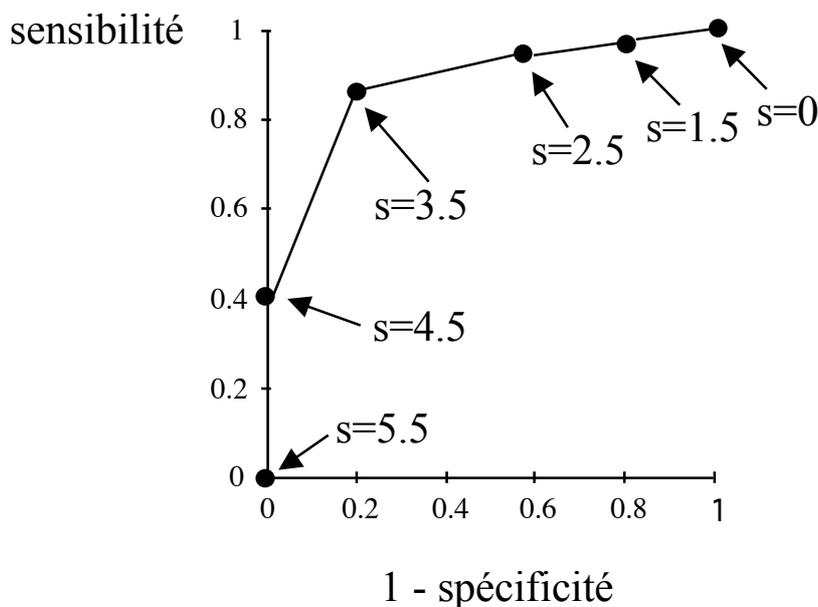
## Construction d'une courbe ROC (2)

- Indice correspondant à une interprétation subjective

image	1	2	3	4	5	....	N
nature de l'image (S ou P)	S	P	S	S	P	....	P
score attribué par un observateur	3	4	2	1	3		2

échelle de scores :

- |                                 |        |           |
|---------------------------------|--------|-----------|
| 1. lésion certainement absente  | .....> | seuil 0   |
| 2. lésion probablement absente  | .....> | seuil 1.5 |
| 3. lésion possiblement présente | .....> | seuil 2.5 |
| 4. lésion probablement présente | .....> | seuil 3.5 |
| 5. lésion certainement présente | .....> | seuil 4.5 |
|                                 | .....> | seuil 5.5 |

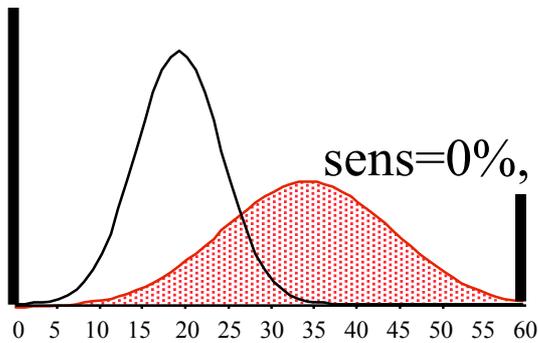


➡ variation discrète du seuil de décision

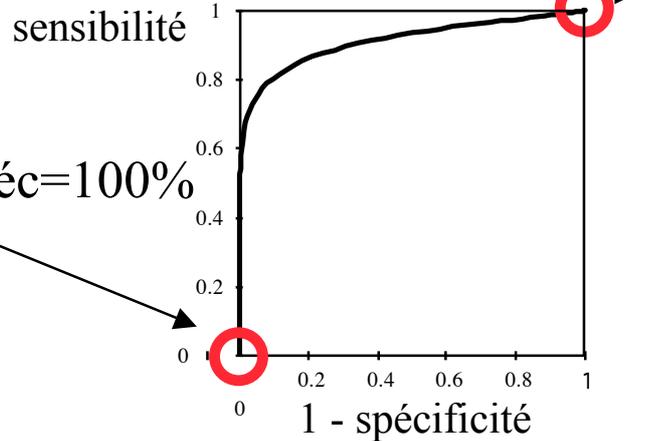
# Caractéristiques d'une courbe ROC

- Passe par les points (0,0) et (1,1)

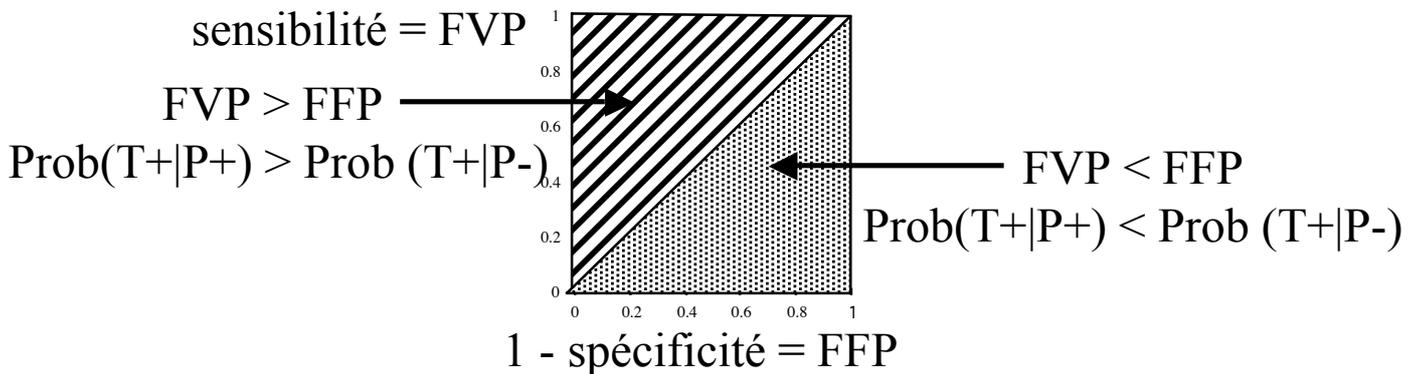
sens=100%, spéc=0%



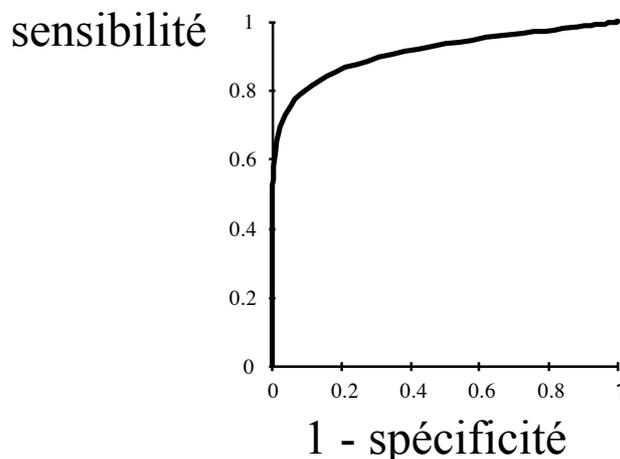
sens=0%, spéc=100%



- Courbe ROC au dessus de la diagonale

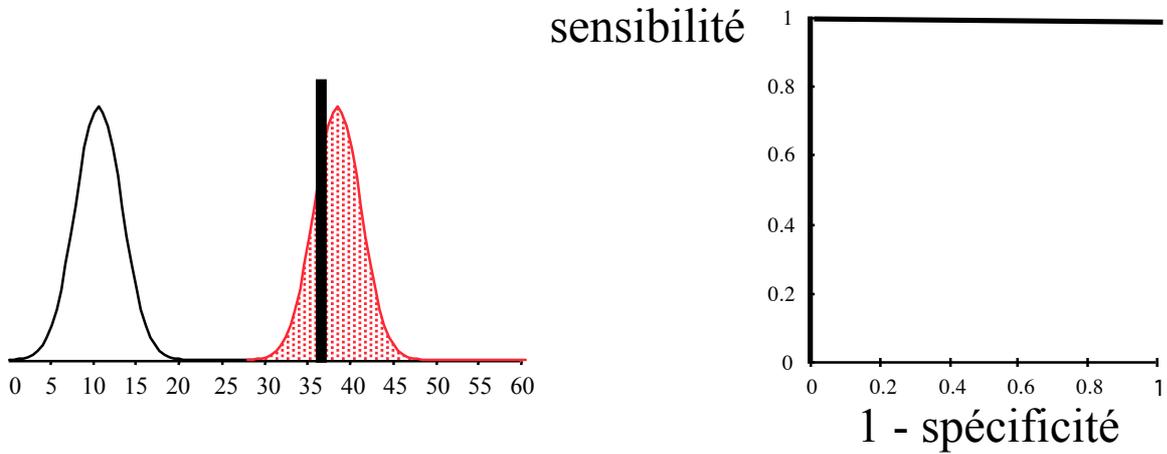


- Pente décroissante de (0,0) à (1,1)

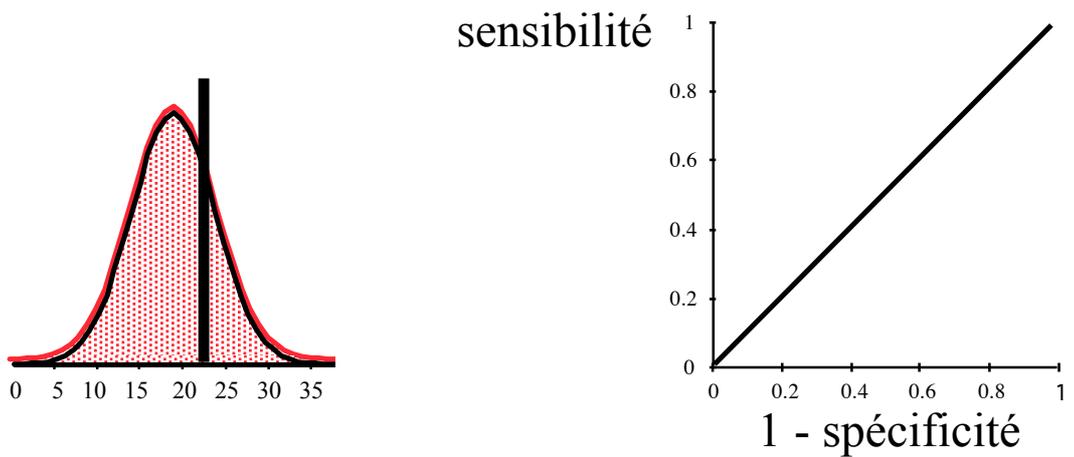


# Interprétation d'une courbe ROC

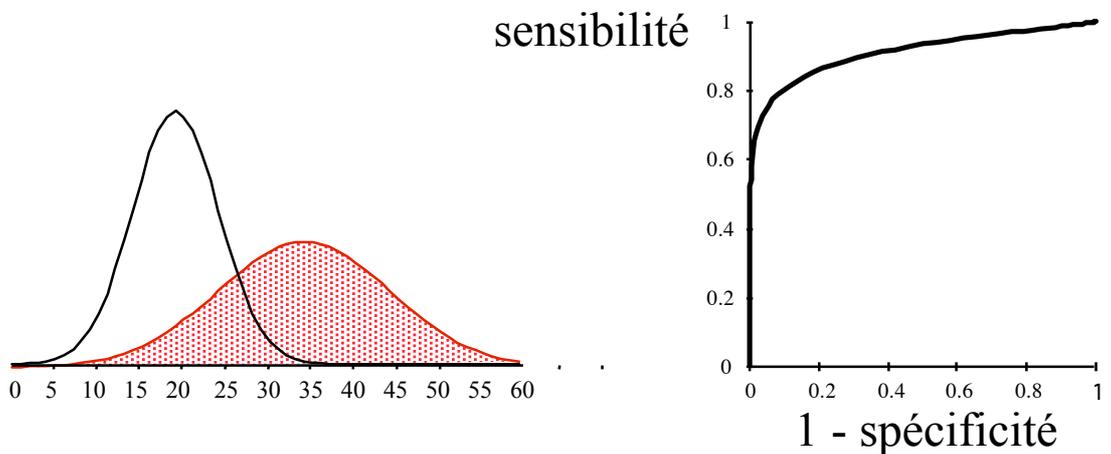
- Indice idéal



- Indice non informatif



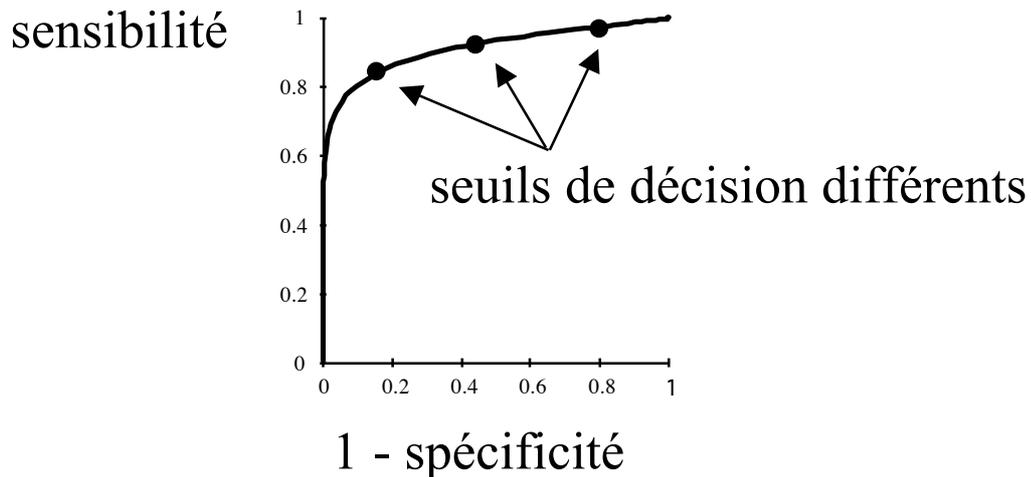
- Indice courant



# Propriétés d'une courbe ROC

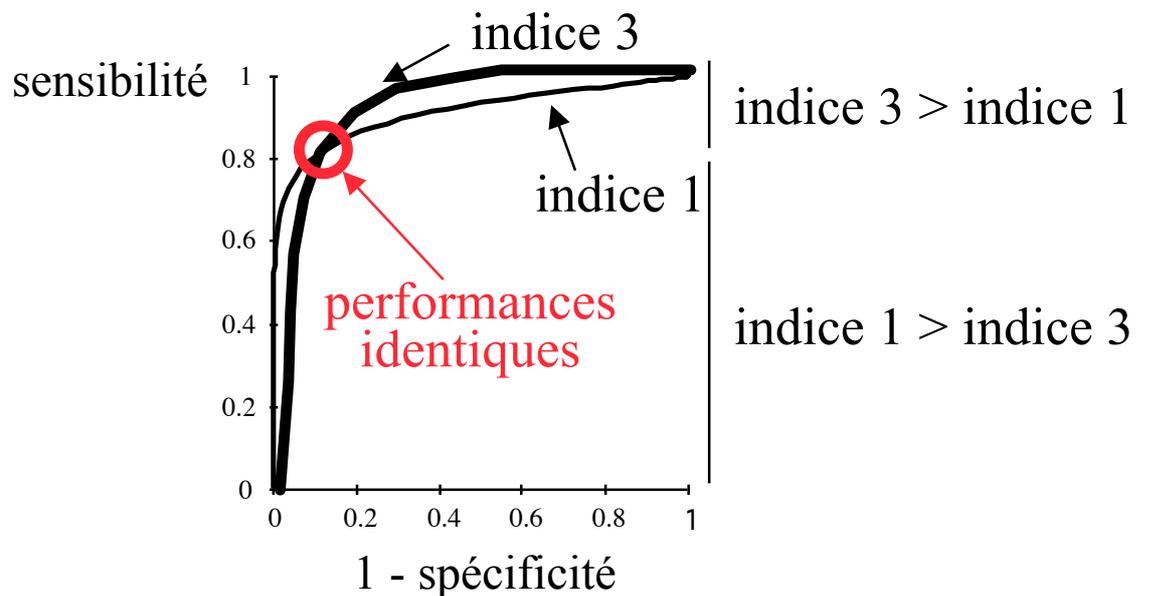
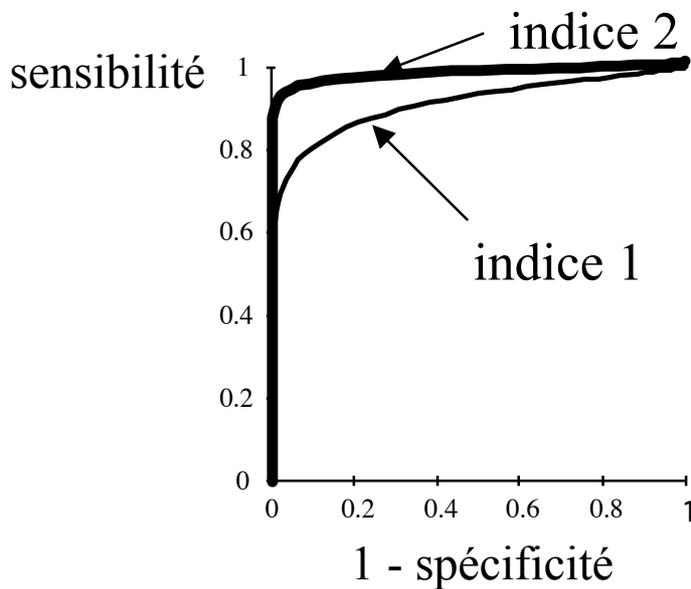
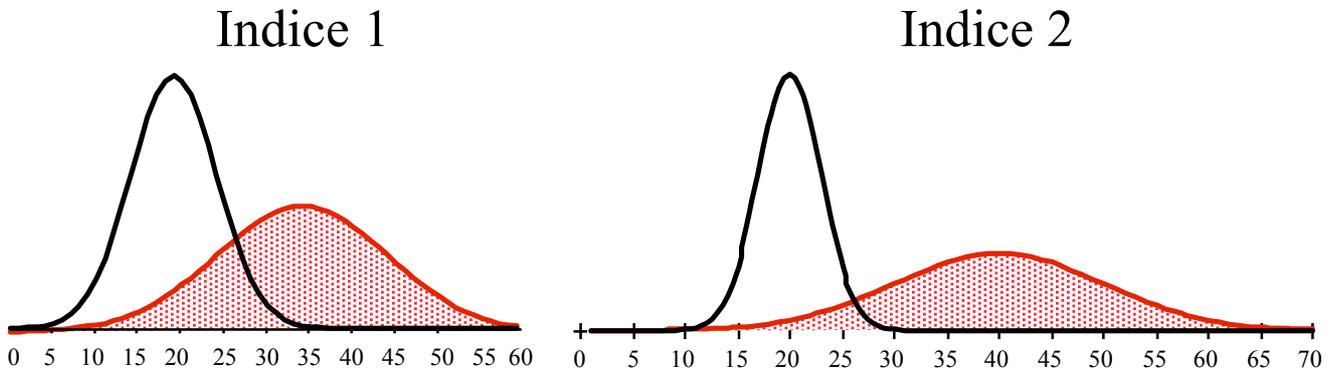
---

- Ne dépend pas de la valeur du seuil de décision



- Ne dépend pas de la prévalence
- Pour un indice quantitatif :  
caractérise les performances de l'indice
- Pour un diagnostic posé à partir de l'observation d'une image :  
caractérise la combinaison (image ; observateur)  
➡ intérêt des observateurs multiples

# Comparaison subjective de deux courbes ROC

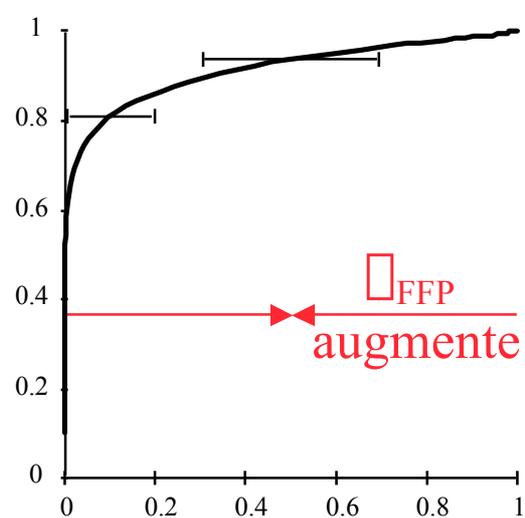
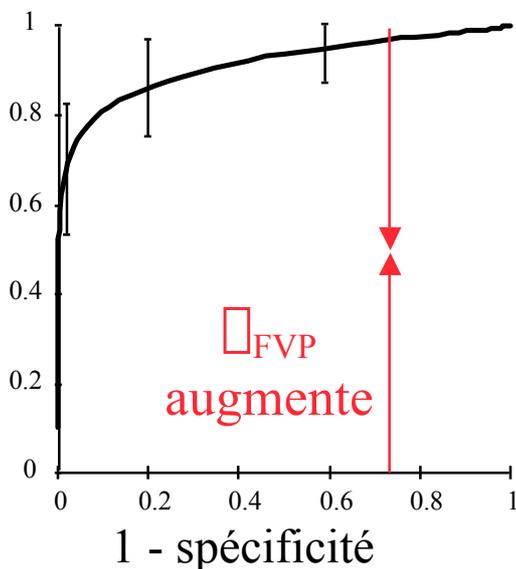


# Fiabilité d'une courbe ROC

$$\square_{FVP} = \sqrt{\frac{FVP (1 - FVP)}{n_{p+} - 1}}$$

$$\square_{FFP} = \sqrt{\frac{FFP (1 - FFP)}{n_{p-} - 1}}$$

sensibilité



- $\square_{FVP}$  augmente quand on se rapproche de  $FVP = 0.5$
- $\square_{FFP}$  augmente quand on se rapproche de  $FFP = 0.5$
- $\square_{FVP}$  varie inversement avec le nombre de sujets pathologiques ( $n_{p+}$ )
- $\square_{FFP}$  varie inversement avec le nombre de sujets sains ( $n_{p-}$ )  
**➡** choisir plutôt  $n_{p+} \sim n_{p-}$

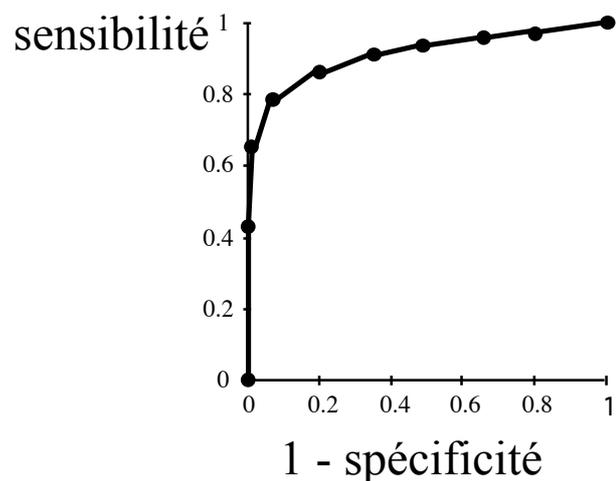
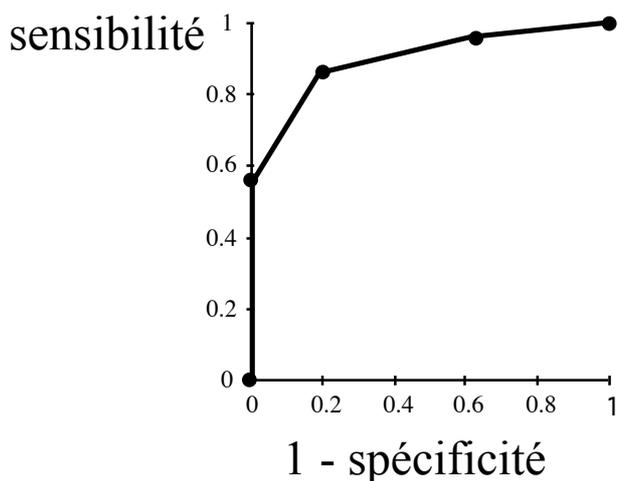
# Tracé d'une courbe ROC : approche non paramétrique

---

- Approche ne reposant pas sur un modèle statistique sous-jacent

ligne brisée reliant les points de mesure

➡ aucun modèle sous-jacent



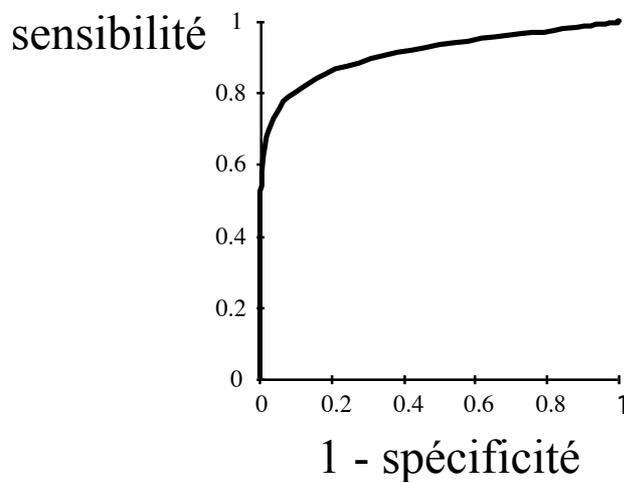
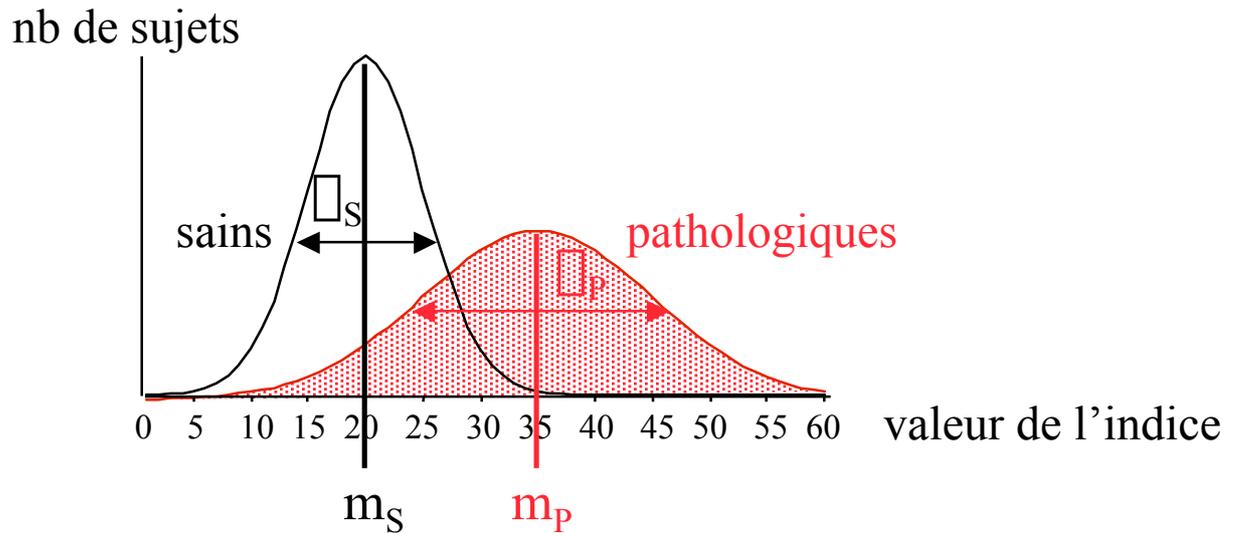
➡ courbe d'autant plus lisse que le nombre de points de mesure est élevé

➡ courbe caractérisée par l'ensemble des triplets (seuil, 1-spécificité, sensibilité)

## Tracé d'une courbe : approche paramétrique (2)

- Modèle binormal sous-jacent

Hypothèse : chaque population suit une loi normale



$$A = \frac{m_P - m_S}{\sigma_S}$$



$$B = \frac{\sigma_S}{\sigma_P}$$

- ➔ détermination des paramètres A et B à partir des triplets (seuil, 1- spécificité, sensibilité) par ajustement maximisant la vraisemblance (i.e., la probabilité que les observations soient « expliquées » par le modèle)  
e.g., programme ROCKIT

# Justification du modèle binormal (1)

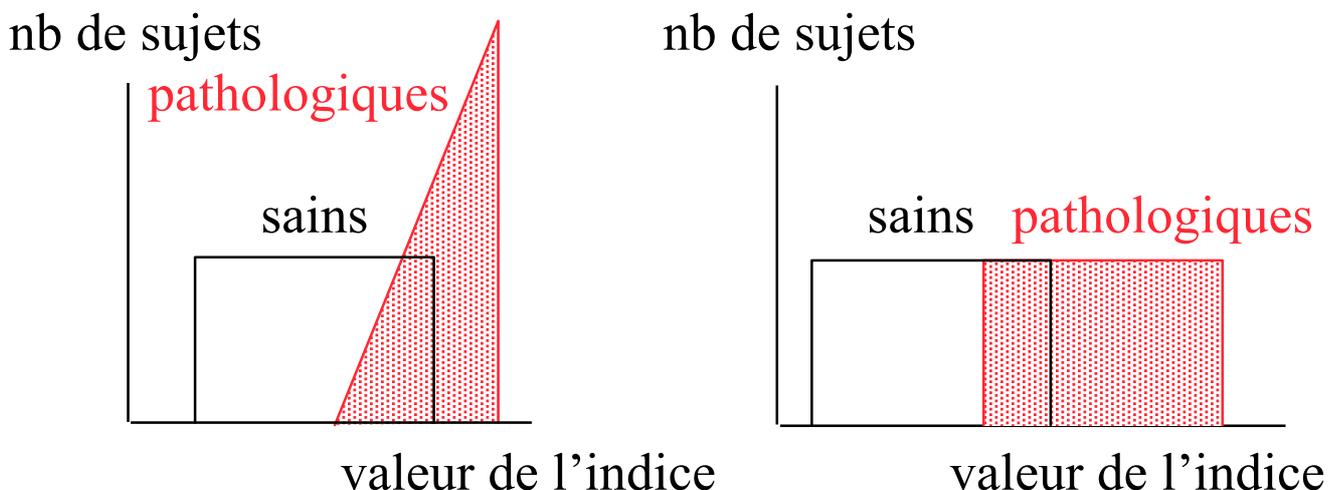
---

- Modèle bien adapté lors de jugements subjectifs par un observateur exprimés sur une échelle comportant un petit nombre de catégories, même pour :

- distributions binomiales
- distributions de Poisson
- distributions du Chi-2
- distributions gamma

- Problèmes possibles avec :

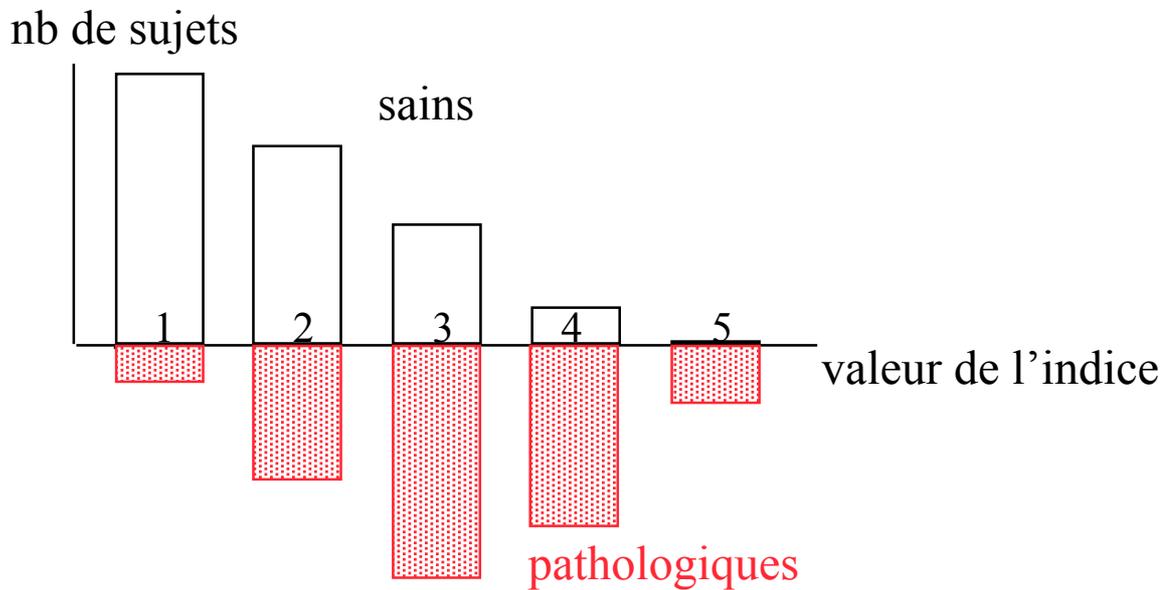
- distributions puissance :  $FVP = FFP^k$
- distributions triangulaire ou rectangulaire



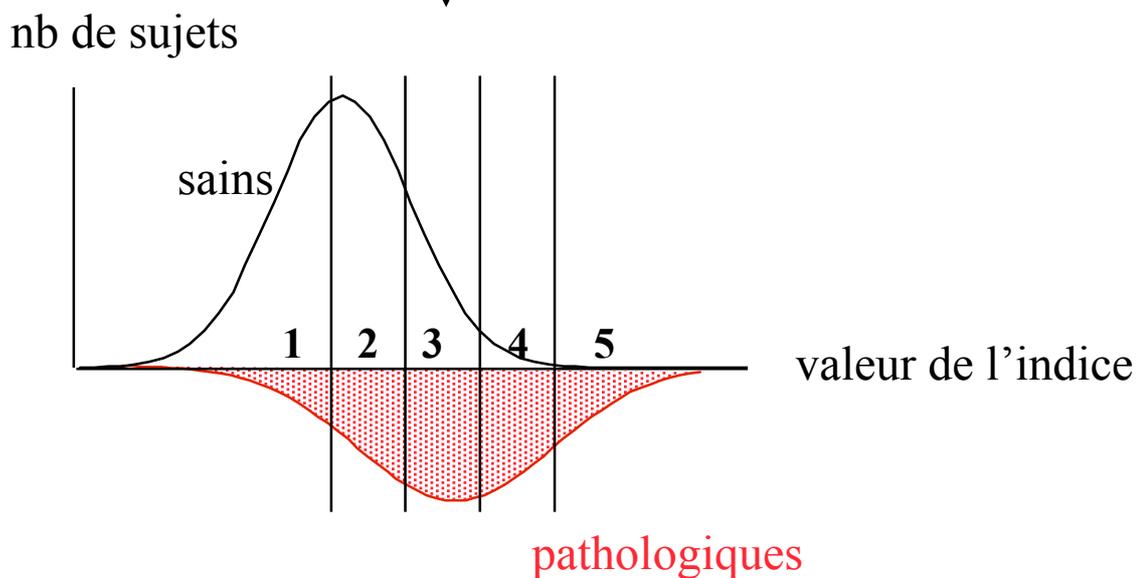
## Justification du modèle binormal (2)

---

- Faible nombre de catégories dans l'échelle des scores



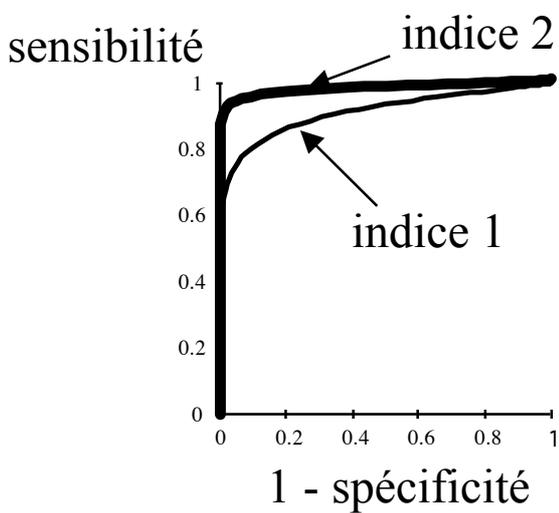
ajustement par deux lois normales



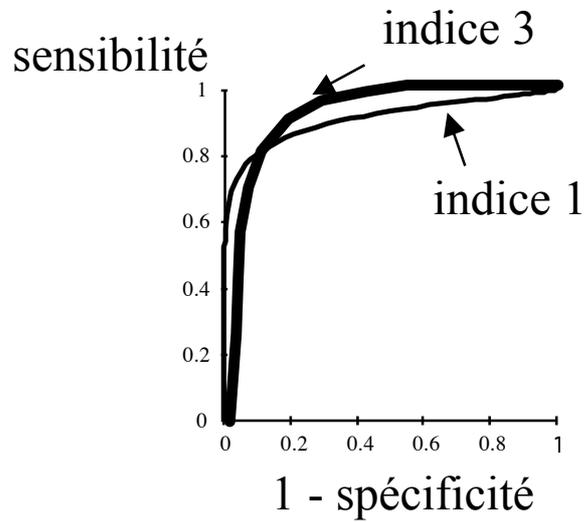
# Comparaison de 2 courbes ROC

---

- Comparaison subjective (visuelle)



**indice 2 > indice 1**



**indice 3 > indice 1  
ou indice 3 ≤ indice**

- Comparaison objective : réalisation d'un test d'hypothèse

# Comparaison objective de 2 courbes ROC

---

- Hypothèses H0 possibles :

- équivalence stricte entre les 2 indices à comparer, i.e., même sensibilité pour chaque spécificité

- même sensibilité pour une valeur de spécificité donnée ou inversement

- en moyenne, même sensibilité pour des spécificités variant entre 0 et 100%

**ATTENTION** : les trois hypothèses ne sont pas équivalentes !

## H0 : équivalence stricte de deux courbes ROC

---

- Ajuster chaque courbe ROC par une loi binormale (logiciel ROCKIT)

➔ Courbe 1 : A1, B1  
Courbe 2 : A2, B2

- Tester :

$$A1 = A2$$
$$B1 = B2$$

➔ test du Chi-2 bivarié (logiciel ROCKIT)



## H0 : même FVP pour une FFP donnée

---

- Pour la FFP d'intérêt :

calculer FVP1 pour l'indice 1

calculer  $\sigma_{\text{FVP1}}$  pour l'indice 1

calculer FVP2 pour l'indice 2

calculer  $\sigma_{\text{FVP2}}$  pour l'indice 2

- Tester :

➔ test z univarié entre

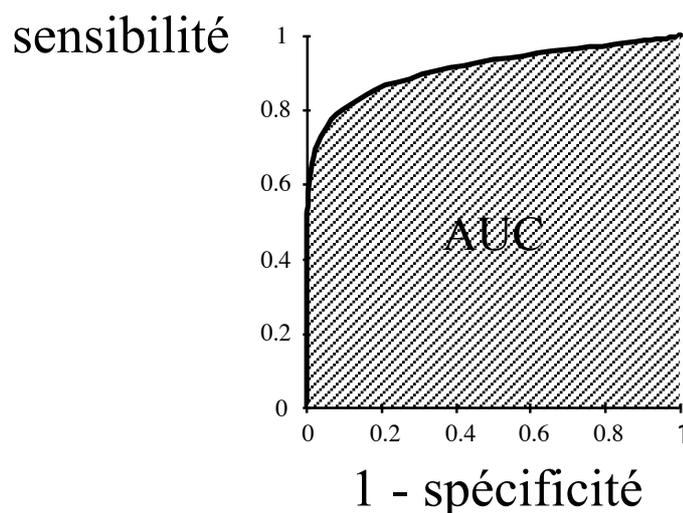
$$\text{FVP1} \pm \sigma_{\text{FVP1}} \text{ et } \text{FVP2} \pm \sigma_{\text{FVP2}}$$



## H0 : même FVP quelle que soit FFP

---

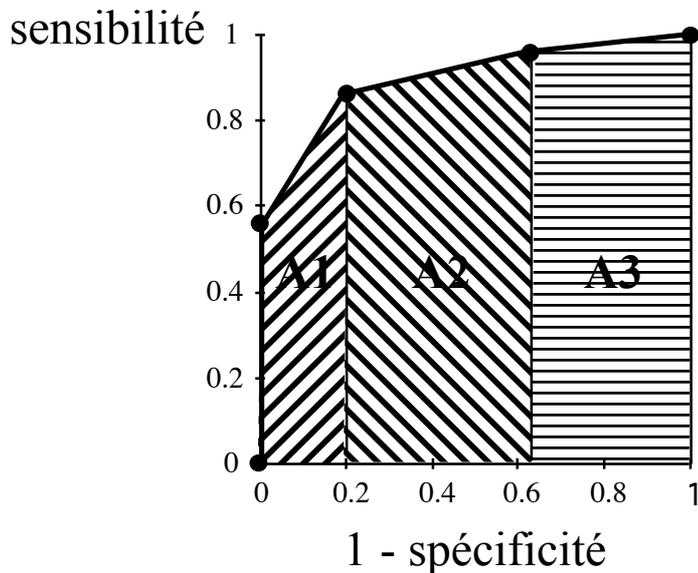
- Caractérisation de chaque courbe par son aire AUC
- Comparaison statistique des AUC



AUC = probabilité d'identifier correctement l'image avec anomalie quand une image avec et une image sans anomalie sont présentées simultanément à un observateur

# Estimation de AUC : approche non paramétrique

- Approche trapézoïdale



$$W = \widehat{\text{AUC}} = A1 + A2 + A3$$

- $W = \text{statistique de Wilcoxon} = \frac{1}{n_{p+} \cdot n_{p-}} \sum_{i=1}^{n_{p+}} \sum_{j=1}^{n_{p-}} S(t_{p+}, t_{p-})$

$$\text{avec } S(t_{p+}, t_{p-}) = \begin{cases} 1 & \text{si } t_{p+} > t_{p-} \\ 0.5 & \text{si } t_{p+} = t_{p-} \\ 0 & \text{si } t_{p+} < t_{p-} \end{cases}$$

- $W = \text{AUC}$  si l'échelle de cotation présente un grain infini

$$\bullet \text{SE}(W) = \sqrt{\frac{W(1-W) + (n_{p+} - 1)(Q_1 - W^2) + (n_{p-} - 1)(Q_2 - W^2)}{n_{p+} \cdot n_{p-}}}$$

avec

$$Q_1 = \text{Prob}(t_{p+} > t_{p-} \text{ et } t'_{p+} > t_{p-})$$

$$Q_2 = \text{Prob}(t_{p+} > t_{p-} \text{ et } t_{p+} > t'_{p-})$$

# Estimation de AUC : approche paramétrique

---

- Modèle binormal :

AUC = Az estimé à partir de l'ajustement des paramètres du modèle par maximisation de la vraisemblance

estimation conjointe de SE(Az)

Condition 1: rating

Total number of actually-negative cases = 58.

Total number of actually-positive cases = 51.

Data effectively collected in 5 categories.

Category 5 represents the strongest evidence of positivity.  
(e.g., that the disease is present)

Response Data:

Category	1	2	3	4	5
Actually-Negative Cases	33	6	6	11	2
Actually-Positive Cases	3	2	2	11	33

[...]

=====  
Final Estimates of the Binormal ROC Parameters  
=====

Binormal Parameters and Area Under the Estimated ROC :

a = 1.6568

b = .7130

Area (Az) = .9113

Estimated Standard Errors of these Values:

Std. Err. (a) = .3121

Std. Err. (b) = .2162

Std. Err. (Az) = .0296

# Approche non paramétrique vs paramétrique

---

Scores t attribués	1	2	3	4	5
P-	33	6	6	11	2
P+	3	2	2	11	33

- Approche non paramétrique

$$W = 0.893$$

$$SE(W) = 0.032$$

- Approche paramétrique

```
=====
Final Estimates of the Binormal ROC Parameters
=====
```

Area Under the Estimated ROC :

$$\text{Area (Az)} = .9113$$

Estimated Standard Error :

$$\text{Std. Err. (Az)} = .0296$$

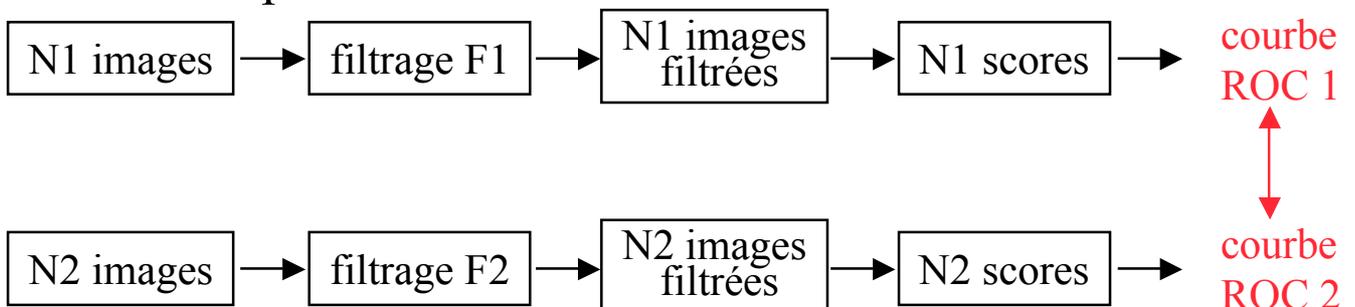
- $W < Az$  car échelle de cotation discrète
- $SE(W) > SE(Az)$ , i.e.  $SE(W)$  conservatif

# Comparaison de 2 courbes ROC

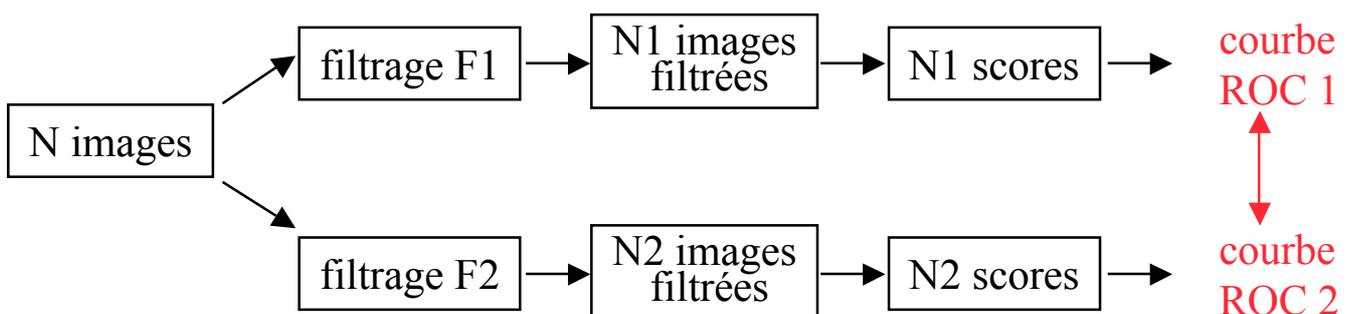
		<u>APPROCHE</u>	
<u>COURBES ROC</u>		non paramétrique	paramétrique
indépendantes	test z entre $W_1$ et $W_2$	test z entre $Az_1$ et $Az_2$	
appariées	test z intégrant la corrélation entre $W_1$ et $W_2$	test z apparié entre $Az_1$ et $Az_2$	

## Comparaison de deux méthodes de filtrage F1 et F2

### Indépendance



### Appariement

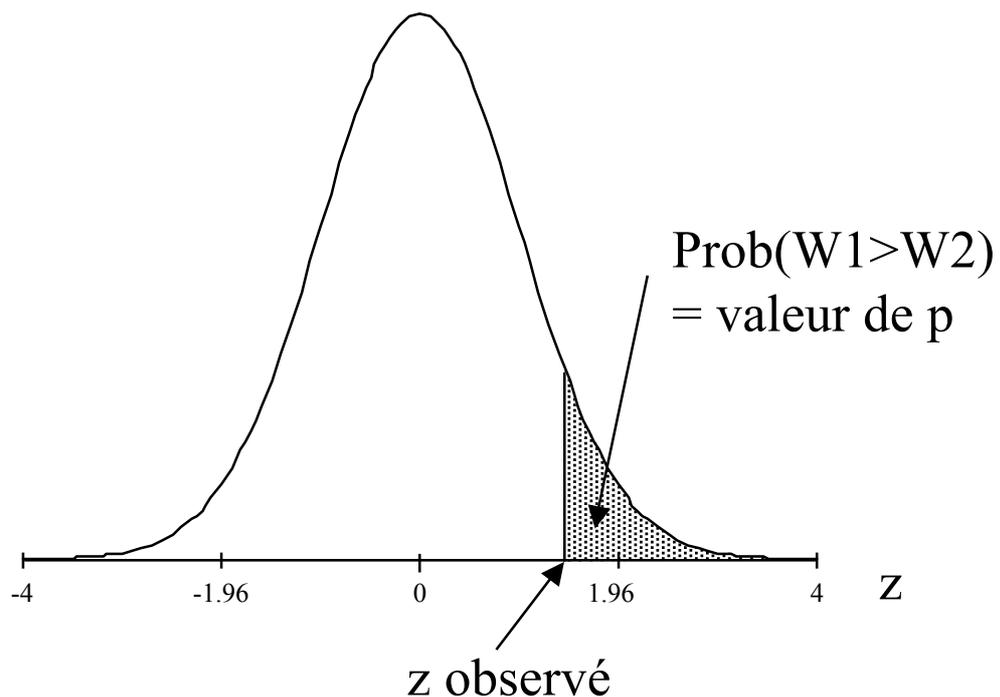


## Cas indépendant - non paramétrique

---

$$z = \frac{W1 - W2}{\sqrt{SE(W1)^2 + SE(W2)^2}}$$

puis référence à une table de loi normale :



p correspond à la probabilité que l'on ait observé les données que l'on a (au travers de la valeur de z calculée) si H0 est vraie

## Cas apparié - non paramétrique

---

$$z = \frac{W1 - W2}{\sqrt{SE(W1)^2 + SE(W2)^2 - 2 r SE(W1)SE(W2)}}$$

avec  $r$  = corrélation entre  $W1$  et  $W2$

- $r = f(r_+, r_-)$  avec
  - $r_+$  : corrélation des scores correspondant aux cas P+
  - $r_-$  : corrélation des scores correspondant aux cas P-
- $r_+$  et  $r_-$  calculés par :
  - coefficient de corrélation de Pearson  
si les indices  $t_{p+}$  et  $t_{p-}$  sont des valeurs quantitatives variant continument
  - coefficient tau de Kendall  
si les indices  $t_{p+}$  et  $t_{p-}$  sont des scores
- $r$  donné par la table (annexe 1) :

	$(W1+W2)/2$		
$(r_+ + r_-)/2$	0.700	...	0.975
0.02			
⋮			
0.90			

## Cas indépendant - paramétrique

---

$$z = \frac{Az1 - Az2}{\sqrt{SE(Az1)^2 + SE(Az2)^2}}$$

Hypothèses :

- Sujets choisis aléatoirement parmi la population d'intérêt
- Sujets assignés aléatoirement à l'estimation d'un seul des deux indices t1 ou t2
- Indices 1 et 2 interprétés indépendamment
- Lois binormales sous-jacentes pour chaque indice
  - Maximisation d'une fonction de vraisemblance
  - Estimation de Az1, Az2, SE(Az1) et SE(Az2)
  - Test z

## Cas apparié - paramétrique

---

$$z = \frac{Az1 - Az2}{\sqrt{SE(Az1)^2 + SE(Az2)^2 - 2 \text{Covar}(Az1, Az2)}}$$

Hypothèses :

- Sujets choisis aléatoirement parmi la population d'intérêt
- Indices t1 et t2 calculés systématiquement pour tous les sujets
- Indices 1 et 2 interprétés indépendamment
- lois binormales sous-jacentes pour chaque indice
  - Maximisation d'une fonction de vraisemblance
  - Estimation de Az1, Az2, SE(Az1), SE(Az2), Covar(Az1, Az2)
  - Test z intégrant la corrélation entre les deux ensembles de scores

# Impact de la technique de comparaison

---

## Sujets sains

---

Scores t avec la modalité 1	Scores t avec la modalité 2					
	1	2	3	4	5	6
1	9	3	-	-	-	-
2	17	9	2	-	-	-
3	3	4	1	-	-	-
4	1	2	2	1	-	-
5	1	1	-	2	-	-
6	-	-	-	-	-	-

## Sujets pathologiques

---

Scores t avec la modalité 1	Scores t avec la modalité 2					
	1	2	3	4	5	6
1	-	-	1	-	-	-
2	1	-	2	-	-	-
3	1	1	1	3	-	-
4	1	1	1	9	1	-
5	-	-	-	7	10	5
6	-	-	-	-	4	5

Test	AUC1	AUC2	r	z
NP, Ind	.883±.033	.932±.026	0	1.181
NP, App	.883±.033	.932±.026	.531	1.550
P, Ind	.895±.030	.941±.025	0	1.165
P, App	.897±.030	.940±.027	.537	1.571

## Cas partiellement apparié

---

Sujets 1 à $n_1$	indice $t_1$ seulement
Sujets $(n_1+1)$ à $n_2$	indice $t_2$ seulement
Sujets $(n_2+1)$ à $N$	indices $t_1$ et $t_2$

Alternatives :

- considérer uniquement les sujets  $(n_2+1)$  à  $N$ 
  - ➡ gaspillage et perte de puissance
- considérer tous les sujets mais ignorer

l'appariement

➡ perte de puissance

- utiliser un test gérant les données partiellement

appariées

➡ test paramétrique seulement

Hypothèses :

- Echantillons appariés et non appariés issus de la même population
- Echantillons appariés et non appariés indépendants
- Indices 1 et 2 interprétés indépendamment
- lois binormales sous-jacentes pour chaque indice
  - ➡ maximisation d'une fonction de vraisemblance
  - ➡ estimation de  $Az_1$ ,  $Az_2$ ,  $SE(Az_1)$ ,  $SE(Az_2)$ , covariance
  - ➡ test  $z$  intégrant la corrélation entre les données corrélées

## Comparaison de plus de 2 courbes ROC

---

Situations possibles :

Nb d'indices à comparer	Nb d'observateurs	Nb de lectures par observateur
2	1	>1
2	>1	1
2	>1	>1
>2	1	1
>2	>1	1
>2	1	>1
>2	>1	>1

➡ A chaque situation, une procédure de test !

➡ Pas de consensus sur les procédures les plus appropriées

## 2 indices, plusieurs observateurs, 1 lecture (1)

---

Nb d'indices à comparer	Nb d'observateurs	Nb de lectures par observateur
2	$K > 1$	1

- Pour chaque observateur  $k$  :  
calculer  $Az1_k$  et  $Az2_k$  (ou  $W1_k$  et  $W2_k$ )
- Pour chaque observateur  $k$  :  
calculer  $\square_k = Az1_k - Az2_k$  (ou  $\square_k = W1_k - W2_k$ )
- Réaliser un test t de Student testant :  
 $H_0 : \text{moyenne}(\square_k) = 0$

➡ Beaucoup de lecteurs nécessaires pour atteindre une puissance statistique correcte (test t)

➡ La conclusion est valable pour l'échantillon étudié seulement, donc s'assurer de la représentativité de l'échantillon : attention aux petits échantillons !

➡ Une courbe ROC moyenne pour chaque méthode peut être obtenue en moyennant (sur les observateurs) les valeurs  $A1_k$  et  $B1_k$  estimées par le modèle binormal :

$$A1 = \square_k A1_k / K, \quad B1 = \square_k B1_k / K,$$
$$A2 = \square_k A2_k / K, \quad B2 = \square_k B2_k / K,$$

Réf : Metz, 1989, exemple dans La Croix et al, 2000

## 2 indices, plusieurs observateurs, 1 lecture (2)

---

Nb d'indices à comparer	Nb d'observateurs	Nb de lectures par observateur
2	$K > 1$	1

- Pour chaque observateur  $k$  :
    - ➔ calculer  $Az1_k$  et  $Az2_k$  (ou  $W1_k$  et  $W2_k$ )
  - Pour chaque observateur  $k$  :
    - tester  $H0 : Az1_k = Az2_k$  (ou  $H0 : W1_k - W2_k$ )
    - ➔ valeur de  $p$  pour chaque observateur  $k$
  - Conclure :
    - Avec  $K$  observateurs, la différence moyenne entre  $Az1$  et  $Az2$  vaut ...
    - L'indice 1 s'est avéré significativement meilleur que l'indice 2 avec  $p < 0.05$  pour ... observateurs sur  $K$
- ➔ Pas de conclusion générale

Réf : Metz, 1989, exemple dans La Croix et al, 2000

## M indices, 1 observateur, 1 lecture

---

Nb d'indices à comparer	Nb d'observateurs	Nb de lectures par observateur
M	1	1

- Utilisation de la statistique de Wilcoxon pour calculer  $W_1, W_2, \dots, W_M$

- Calcul analytique de la matrice variance-covariance ( $M \times M$ )  $\mathbf{S}$  du vecteur  $\mathbf{W} = (W_1, \dots, W_M)$

- Expression d'une matrice  $\mathbf{L}$  de contraste linéaire correspondant à l'hypothèse à tester

exemples :

- indice 1 meilleur que la moyenne des indices 2 et 3 ?

$$\mathbf{L} = (1 \quad -0.5 \quad -0.5)$$

- indice 1 meilleur que indice 2 ou meilleur que indice 3 ?

$$\mathbf{L} = \begin{pmatrix} 1 & -1 & 0 \\ 1 & 0 & -1 \end{pmatrix}$$

- Calcul d'une statistique du  $\text{Chi-2} = f(\mathbf{L}, \mathbf{S})$  et comparaison à la valeur critique

➡ approche non paramétrique, test apparié

Réf et exemple : De Long et al, 1988

## M indices, K observateurs, 1 lecture (1)

---

Nb d'indices à comparer	Nb d'observateurs	Nb de lectures par observateur
M	K	1

- pour chaque observateur k :  
calculer les  $Az_{m_k}$  (ou  $W_{m_k}$ )
- pour chaque observateur k :  
tester  $H_0 : Az_{m_k} = Az_{m'_k}$  (ou  $H_0 : W_{m_k} - W_{m'_k}$ ) pour  
les couples de méthodes m et m' d'intérêt  
➔ valeur de p pour chaque observateur k et chaque  
couple (m, m')

OU

- pour chaque observateur k :  
calculer les  $Az_{m_k}$  (ou  $W_{m_k}$ )
- pour chaque observateur k :  
calculer  $\square_{mm'_k} = Az_{m_k} - Az_{m'_k}$  (ou  $\square_k = W_{m_k} - W_{m'_k}$ )
- réaliser des tests t de Student testant :  
 $H_0 : \text{moyenne}(\square_{mm'_k}) = 0$

Réf et exemple : Gilland et al, 1992

## M indices, K observateurs, 1 lecture (2)

---

Nb d'indices à comparer	Nb d'observateurs	Nb de lectures par observateur
M	K	1

- pour chaque observateur  $k$  :  
calculer les  $A_{zm_k}$  (ou  $W_{m_k}$ )
- analyse de variance à 2 critères de classification (2-way ANOVA) pour tester  $H_0$  :  
tous les  $A_{zm}$  sont équivalentes ( $H_1$  : les indices diffèrent entre eux)
- si  $H_0$  est rejeté :  
test de Scheffé de comparaisons multiples appariées

Réf et exemples : de Vries et al, 1999, Gifford et al, 2000

## Considérations pratiques : check-list

---

- Nombre de cas à inclure
- Sélection des cas
- Ordre de lecture
- Gold standard imparfait
- Echelle de cotation
- Paramétrique ou non paramétrique ?
- Lectures multiples

## Considérations pratiques : nombre de cas à inclure

---

Combien de cas nécessaire pour mettre en évidence une différence significative entre AUC1 et AUC2 ?

### Hypothèses

- Connaissance approximative de AUC1 et AUC2
- Optionnellement, connaissance approximative du rapport des écarts types  $\sigma_S$  et  $\sigma_P$  entre les deux lois normales sous-jacentes

➡ si indice continu :  
SE(AUC) donnée par Hanley et McNeil, 1992

➡ si indice = score sur échelle discrète :  
SE(Az) donnée par Obuchowski, 1994



déduction de  $n_{p+}$  et  $n_p$   
pour un niveau de signification  $\alpha$  donné

## Considérations pratiques : sélection des cas

---

2 stratégies possibles :

- Mesure des performances absolues de deux indices dans les configurations où ils sont appliqués

  - ➡ très difficile car très nombreux paramètres à contrôler

- Comparaison des performances des deux indices

  - ➡ plus de souplesse dans la conception de l'étude

  - ➡ s'assurer que si t1 meilleur que t2 dans les conditions de l'étude, t1 sera également meilleur que t2 dans les conditions d'utilisation générale

  - ➡ pour maximiser la puissance des tests, choisir des cas de difficulté intermédiaire :

$$\text{AUC} \sim 0.75 - 0.80$$

  - ➡ conduire éventuellement une étude pilote pour identifier les cas de difficulté intermédiaire

## Considérations pratiques : ordre de lecture

---

- Image indice 1 présentée systématiquement avant image indice 2

➡ biais potentiel

- Deux alternatives

➡ 1 avant 2 pour la moitié des observateurs  
2 avant 1 pour l'autre moitié

➡ pour chaque observateur :  
- 1 avant 2 pour la moitié des images  
- 2 avant 1 pour l'autre moitié  
- éloignement maximal des images

correspondant aux mêmes cas vues par les 2 indices  
- ordre différent pour chaque observateur

Exemple : 2 indices 1 et 2, 4 observateurs

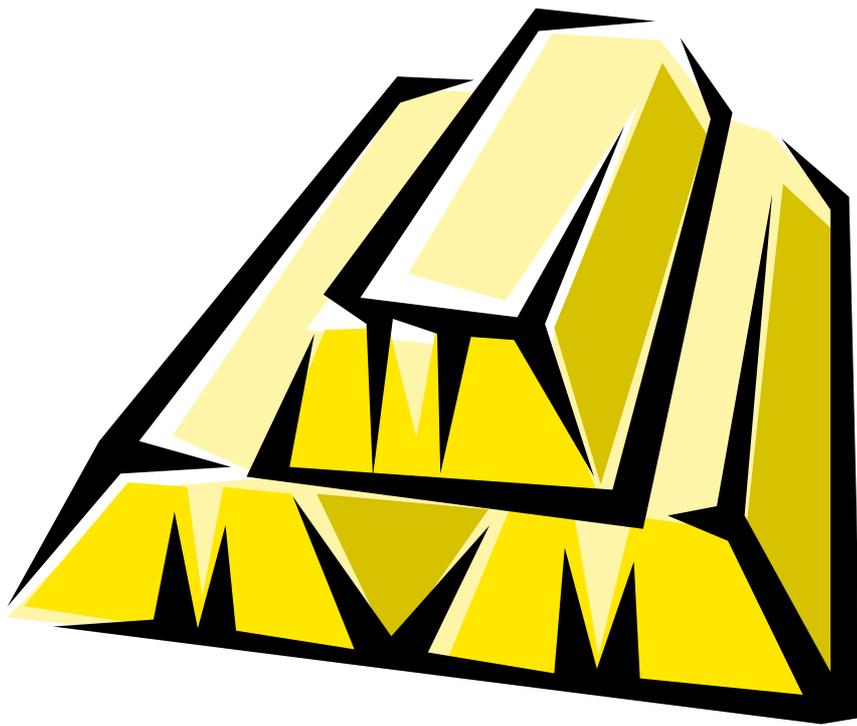
➡ diviser les images en deux sous-groupes A et B de même effectif

➡ assigner un ordre pour chaque observateur :  
(A1, B2, A2, B1)  
(A2, B1, A1, B2)  
(B1, A2, B2, A1)  
(B2, A1, B1, A2)

# Considérations pratiques : gold standard

---

- Gold standard :
  - la bonne réponse
  - référence
  - ground truth
  - vérité terrain



# Considérations pratiques : gold standard imparfait

---

- Deux cas
  - erreur gold standard non corrélée à l'erreur indice
  - erreur gold standard corrélée à l'erreur indice
- Non corrélation des erreurs :
  - ➡ courbe ROC comprimée vers la diagonale
  - ➡ AUC sous-estimée
  - ➡ sensibilité et spécificité systématiquement sous-estimées
- Corrélation des erreurs :
  - ➡ courbe ROC optimiste
  - ➡ AUC surestimée
  - ➡ sensibilité et spécificité systématiquement surestimées
- Que faire ?
  - ➡ utiliser une définition très stricte pour estimer la sensibilité
  - ➡ utiliser une définition moins rigoureuse pour estimer la spécificité
  - ➡ considérer des populations différentes pour estimer les sensibilité (forte prévalence) et spécificité (faible prévalence)
  - ➡ possible correction des biais a posteriori si on sait si les erreurs gold standard - indice sont corrélées

## Considérations pratiques : échelle de cotation

---

- Nombre de catégories ?
  - ➡ précision accrue lorsqu'on passe de 5 à 10
  - ➡ au delà de 10, plus de gain substantiel
- Format de cotation si plusieurs (A) types d'anomalies ?
  - format général : 1 score par image  
absence ou présence d'une anomalie (avec degré de confiance associé) quelle qu'elle soit  
exemple : anomalie 1 ou 2 ou 3 est :
    1. très certainement absente
    2. probablement absente
    3. possiblement absente
    4. probablement présente
    5. très certainement présente
  - format spécifique :  
pour chaque type d'anomalie, absence ou présence cotée sur l'échelle de 1 à 5, d'où A scores par image  
score le plus élevé retenu, d'où 1 score par image
    - ➡ pas de différence significative entre les 2 formats si on s'intéresse seulement à la présence d'une anomalie, et pas à sa nature.
    - ➡ si on limite l'analyse ROC aux images présentant un type d'anomalie, influence du format plus ambiguë

Réf : Rockette et al, 1990

# Considérations pratiques : paramétrique ou non ?

---

## REGLES

- indice résultant de jugements d'observateurs et exprimé sur une échelle de cotation discrète
  - ➡ modèle binormal bien adapté
- indice continu
  - ➡ approche non paramétrique plus générale si les distributions sous-jacentes sont inconnues
- approche non paramétrique moins puissante que l'approche paramétrique

## EN PRATIQUE

- données effectivement binormales
    - ➡ Az et SE pratiquement non biaisées que l'approche soit paramétrique ou non
  - données non binormales
    - ➡ estimées très fiables des AUC par les 2 approches (biais < 1% en NP, <2.5% en P)
    - ➡ tendance à surestimer SE avec les deux approches
- ➡ **CHOISIR LE PLUS PRATIQUE !**

Réf : Hajian-Tilaki et al, 1997

## Considérations pratiques : lectures multiples

---

### REGLES POUR AMELIORER L'ESTIMATION ROC

- Si les observateurs présentent des performances voisines, plusieurs observateurs préférables à plusieurs lectures par un même observateur
- Réduction des variabilités d'autant plus importantes que les résultats issus des différents observateurs ou observations sont peu corrélés.
- Combinaison des scores puis estimation ROC

Exemple :

obs 1 :	scores	1	2	3	4	5					
obs 2 :	scores	1	2	3	4	5					
obs "1 et 2" :	scores	2	3	4	5	6	7	8	9	10	

analyse ROC à partir des scores combinés

Gains à espérer :

1 obs :  $Az = 0.836$

obs "1 et 2" :  $Az = 0.860$

Réf : Metz et Shen, 1992

## Variantes de l'approche ROC

---

- LROC : Localized Response Operating Characteristic
  - 1 anomalie par image
  - détecter ET localiser l'anomalie dans une image
  - ordonnée : FVP (bien détectés et localisés),  
abscisse : FFP (pour les images sans anomalie)
- FROC : Free Response Operating Characteristic
  - plusieurs anomalies possibles par image
  - ordonnée : FVP (bien détectés et localisés)  
abscisse : FFP (nb moyen de FP par image)
  - potentiellement plus puissant que ROC ou LROC pour quantifier des performances de détection
- AFROC : Alternative FROC
  - plusieurs anomalies possibles par image
  - ordonnée : FVP (bien détectés et localisés) =  
ordonnée de FROC  
abscisse : fraction d'images contenant au moins  
un FP = abscisse de ROC

Limite majeure :

Modèles complexes pour ajuster les observations  
➡ pas de test statistique adapté à la comparaison  
de deux courbes LROC ou de deux courbes FROC

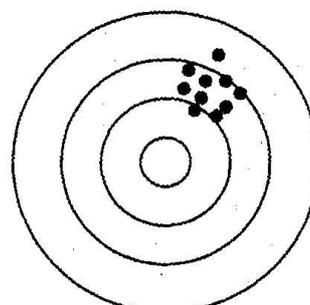
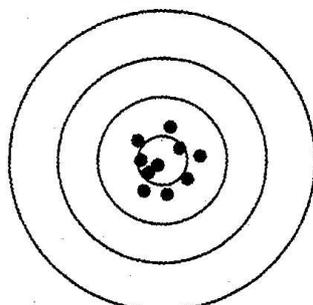
Réf : Swensson RG, 1996

# Evaluation de la qualité d'une mesure

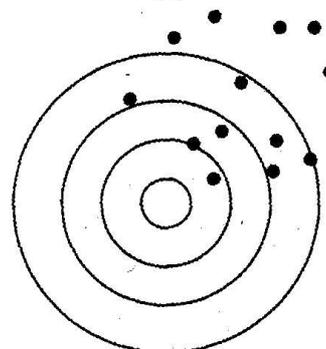
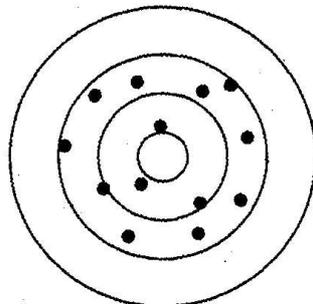
---

- Contexte : on cherche à savoir les performances d'une méthode pour estimer un paramètre  $x$
- Ces performances doivent être décrites par 2 grandeurs : le biais d'estimation, et la variabilité
- Biais : caractérise la distance moyenne entre la valeur estimée du paramètre et sa vraie valeur
- Variabilité : caractérise la dispersion des valeurs estimées pour une même valeur vraie

faible variabilité



forte variabilité



non biaisé

biaisé

# Annexe 1 : table des coefficients r entre W1 et W2

Corrélation moyenne	AUC moyenne											
	.700	.725	.750	.775	.800	.825	.850	.875	.900	.925	.950	.975
.02	.02	.02	.02	.02	.02	.02	.02	.01	.01	.01	.01	.01
.04	.04	.04	.03	.03	.03	.03	.03	.03	.03	.02	.02	.02
.06	.05	.05	.05	.05	.05	.05	.05	.04	.04	.04	.03	.02
.08	.07	.07	.07	.07	.07	.06	.06	.06	.06	.05	.04	.03
.10	.09	.09	.09	.09	.08	.08	.08	.07	.07	.06	.06	.04
.12	.11	.11	.11	.10	.10	.10	.09	.09	.08	.08	.07	.05
.14	.13	.12	.12	.12	.12	.11	.11	.11	.10	.09	.08	.06
.16	.14	.14	.14	.14	.13	.13	.13	.12	.11	.11	.09	.07
.18	.16	.16	.16	.16	.15	.15	.14	.14	.13	.12	.11	.09
.20	.18	.18	.18	.17	.17	.17	.16	.15	.15	.14	.12	.10
.22	.20	.20	.19	.19	.19	.18	.18	.17	.16	.15	.14	.11
.24	.22	.22	.21	.21	.21	.20	.19	.19	.18	.17	.15	.12
.26	.24	.23	.23	.23	.22	.22	.21	.20	.19	.18	.16	.13
.28	.26	.25	.25	.25	.24	.24	.23	.22	.21	.20	.18	.15
.30	.27	.27	.27	.26	.26	.25	.25	.24	.23	.21	.19	.16
.32	.29	.29	.29	.28	.28	.27	.26	.26	.24	.23	.21	.18
.34	.31	.31	.31	.30	.30	.29	.28	.27	.26	.25	.23	.19
.36	.33	.33	.32	.32	.31	.31	.30	.29	.28	.26	.24	.21
.38	.35	.35	.34	.34	.33	.33	.32	.31	.30	.28	.26	.22
.40	.37	.37	.36	.36	.35	.35	.34	.33	.32	.30	.28	.24
.42	.39	.39	.38	.38	.37	.36	.36	.35	.33	.32	.29	.25
.44	.41	.40	.40	.40	.39	.38	.38	.37	.35	.34	.31	.27
.46	.43	.42	.42	.42	.41	.40	.39	.38	.37	.35	.33	.29
.48	.45	.44	.44	.43	.43	.42	.41	.40	.39	.37	.35	.30
.50	.47	.46	.46	.45	.45	.44	.43	.42	.41	.39	.37	.32
.52	.49	.48	.48	.47	.47	.46	.45	.44	.43	.41	.39	.34
.54	.51	.50	.50	.49	.49	.48	.47	.46	.45	.43	.41	.36
.56	.53	.52	.52	.51	.51	.50	.49	.48	.47	.45	.43	.38
.58	.55	.54	.54	.53	.53	.52	.51	.50	.49	.47	.45	.40
.60	.57	.56	.56	.55	.55	.54	.53	.52	.51	.49	.47	.42
.62	.59	.58	.58	.57	.57	.56	.55	.54	.53	.51	.49	.45
.64	.61	.60	.60	.59	.59	.58	.58	.57	.55	.54	.51	.47
.66	.63	.62	.62	.62	.61	.60	.60	.59	.57	.56	.53	.49
.68	.65	.64	.64	.64	.63	.62	.62	.61	.60	.58	.56	.51
.70	.67	.66	.66	.66	.65	.65	.64	.63	.62	.60	.58	.54
.72	.69	.69	.68	.68	.67	.67	.66	.65	.64	.63	.60	.56
.74	.71	.71	.70	.70	.69	.69	.68	.67	.66	.65	.63	.59
.76	.73	.73	.72	.72	.72	.71	.71	.70	.69	.67	.65	.61
.78	.75	.75	.75	.74	.74	.73	.73	.72	.71	.70	.68	.64
.80	.77	.77	.77	.76	.76	.76	.75	.74	.73	.72	.70	.67
.82	.79	.79	.79	.79	.78	.78	.77	.77	.76	.75	.73	.70
.84	.82	.81	.81	.81	.81	.80	.80	.79	.78	.77	.76	.73
.86	.84	.84	.83	.83	.83	.82	.82	.81	.81	.80	.78	.75
.88	.86	.86	.86	.85	.85	.85	.84	.84	.83	.82	.81	.79
.90	.88	.88	.88	.88	.87	.87	.87	.86	.86	.85	.84	.82

## Annexe 2 : références bibliographiques

---

- Berbaum KS, Dorfman DD, Franken EA. Measuring observer performance by ROC analysis: indications and complications. *Invest Radiol*, 1989; 24: 228-233
- DeLong ER, DeLong DM, Clarke-Pearson DL. Comparing the areas under two or more correlated Receiver Operating Characteristic curves: a nonparametric approach. *Biometrics*, 1988; 44: 837-845
- de Vries DJ, King MA, Soares EJ, Tsui BMW, Metz CE. Effects of scatter subtraction on detection and quantitation in hepatic SPECT. *J Nucl Med*, 1999; 40: 1011-1023
- Gifford HC, King MA, de Vries DJ, Soares EJ. Channelized Hotelling and human observer correlation for lesion detection in hepatic SPECT imaging. *J Nucl Med*, 2000; 41: 514-521
- Gilland DR, Tsui BMW, Metz CE, Jaszczak RJ, Perry JR. An evaluation of maximum likelihood-expectation maximization reconstruction for SPECT by ROC analysis. *J Nucl Med*, 1992; 33: 451-457
- Gur D, King JL, Rockette HE, Britton CA, Thaete FL, Hoy RJ. Practical issues of experimental ROC analysis: selection of controls. *Invest Radiol*, 1990; 25: 583-586
- Hajian-Tilaki KO, Hanley JA, Joseph L, Collet JP. A comparison of parametric and nonparametric approaches to ROC analysis of quantitative diagnostic tests. *Med Decis Making*, 1997; 17: 94-102
- Hanley JA. The robustness of the “binormal” assumptions used in fitting ROC curves. *Med Decis Making*, 1988; 8: 197-203
- Hanley JA, McNeil BJ. The meaning and use of the area under a Receiver Operating Characteristic (ROC) curve. *Radiology*, 1982; 143: 29-36
- Hanley JA, McNeil BJ. A method of comparing the areas under Receiver Operating Characteristic curves derived from the same cases. *Radiology*, 1983; 148: 839-843
- Henkelman RM, Kay I, Bronskill MJ. Receiver Operating Characteristic (ROC) analysis without truth. *Med Decis Making*, 1990; 10: 24-29
- LaCroix KJ, Tsui BMW, Frey EC, Jaszczak RJ. Receiver Operating Characteristic evaluation of iterative reconstruction with attenuation correction in <sup>99m</sup>Tc-sestamibi myocardial SPECT images. *J Nucl Med*, 2000; 41: 502-513
- Metz CE. Some practical issues of experimental design and data analysis in radiological ROC studies. *Invest Radiol*, 1989; 24: 234-245
- Metz CE, Herman BA, Roe CA. Statistical comparison of two ROC-curve estimates obtained from partially paired datasets. *Med Decis Making*, 1998; 18: 110-121
- Metz CE, Shen JH. Gains in accuracy from replicated readings of diagnostic images: prediction and assessment in terms of ROC analysis. *Med Decis Making*, 1992; 12: 60-75
- Obuchowski NA. Computing sample size for Receiver Operating Characteristic studies. *Invest Radiol*, 1994; 29: 238-243
- Rockette HE, Gur D, cooperstein LA, Obuchowski NA, King JL, Fuhrman CR, Tabor EK, Metz CE. Effect of two rating formats in multi-disease ROC study of chest images. *Invest Radiol*, 1990; 25: 225-229
- Swensson RG. Unified measurement of observer performance in detecting and localizing target objects on images. *Med Phys*, 1996; 23: 1709-1725
- Thibodeau LA. Evaluating diagnostic tests. *Biometrics*, 1981; 37: 801-804
- logiciel rockit : site [www-radiology.uchicago.edu/sections/roc](http://www-radiology.uchicago.edu/sections/roc)