

# DFGSM2

## Etudes d'évaluation des tests diagnostiques



Dr Muriel Rabilloud

UE1 – Santé Publique et LCA



Faculté de Médecine  
Lyon Est



# OBJECTIFS

---

- Connaître les méthodes de quantification des performances des tests diagnostiques
- Connaître les notions de probabilités pré et post test
- Savoir quantifier l'information apportée par un test diagnostique
- Connaître les différentes phases d'évaluation d'un test diagnostique
- Connaître la méthodologie des études d'évaluation des tests diagnostiques

# PLAN

---

- Méthodes d'évaluation d'un test diagnostique
  - Fiabilité (Reliability)
  - Exactitude (Accuracy)
- Éléments pour la lecture critique d'une étude évaluant les performances d'un test diagnostique

# CONNAISSANCES ANTERIEURES

---

- Sensibilité, spécificité
- Courbe ROC
- Ratios de vraisemblance positif et négatif
- Valeurs prédictives positive et négative
- Probabilités pré et post-test

# Test diagnostique

---

- « Un test diagnostique est une méthode d'exploration dont le but est de fournir une information pour faire progresser une démarche diagnostique à la recherche d'une maladie M dans une situation clinique déterminée » [Grenier 1994]
- Clinique ou para clinique
- Qualitatif ou quantitatif

# Tests diagnostiques et Médecine factuelle

---

- Dispose-t-on d'études ayant quantifié les performances du test diagnostique ?
- Quel est le niveau de preuve de ces études ?
- Les résultats du test permettront-ils de poser le diagnostic de la maladie ou de l'éliminer ?
- Comment utiliser ce test dans votre pratique ?

Le résultat du test est-il susceptible de modifier la prise en charge du patient ?

# Evaluation des performances d'un test diagnostique

# Fiabilité d'un test (Reliability)

---

- Un test est fiable si son résultat varie peu lorsqu'on répète la mesure
- Pour les tests quantitatifs, fiabilité classiquement quantifiée par le coefficient de variation
- Pour les tests qualitatifs, fiabilité quantifiée par un coefficient mesurant la concordance

# Evaluation de la fiabilité d'un test quantitatif

---

- Coefficient de variation
  - Mesures répétées sur un échantillon de patients
  - Calcul de l'écart type quantifiant la variabilité entre les mesures répétées
  - La variabilité est exprimée en pourcentage de la moyenne des mesures

$$CV(\%) = \frac{\text{Ecart type}}{\text{Moyenne}} \times 100$$

Quantification standardisée de la variabilité  
des mesures répétées

# Evaluation de la fiabilité d'un test quantitatif

---

- Pour un dosage biologique
  - Répétabilité (répétitions du dosage dans les mêmes conditions) jugée acceptable si  $CV < 10\%$
  - Reproductibilité (répétitions du dosage dans des conditions différentes) jugée acceptable si  $CV < 15\%$

# Evaluation de la fiabilité d'un test quantitatif

- Dosage sanguin d'une protéine par une méthode ELISA (méthode immuno-enzymatique)
  - Répétabilité (même plaque) : intraassay CV
  - Reproductibilité (plaques différentes) : interassay CV

Plate Number	Concentration Protein X (pg/mL)			Mean	Intra CV (%)
	Reading 1	Reading 2	Reading 3		
1	183.5	179.6	177.8	180.30	1.62
2	201.4	196.6	194.9	197.63	1.71
3	179.1	177.7	173.6	176.80	1.62

Inter CV (%)	6.03
--------------	------

# Evaluation de la fiabilité d'un test qualitatif

---

- Concordance entre plusieurs évaluations du résultat positif ou négatif d'un même test
- Même mammographie évaluée plusieurs fois par le même radiologue (reproductibilité intra observateur)
- Même mammographie évaluée par plusieurs radiologues (reproductibilité inter observateurs)

# Evaluation de la fiabilité d'un test qualitatif

- Concordance des résultats de mammographies évaluées par 2 radiologues

Radiologue 1

		Radiologue 1		
		Positive	Négative	
Radiologue 2	Positive	32	3	35 0,29
	Négative	8	77	85 0,71
		40 0,34	80 0,66	120

# Evaluation de la fiabilité d'un test qualitatif

---

- Concordance observée :  $C_o = \frac{32+77}{120} = 0,91$
- Concordance attendue par le simple hasard :

$$C_a = (0,34 \times 0,29) + (0,66 \times 0,71) = 0,57$$

# Evaluation de la fiabilité d'un test qualitatif

---

- Coefficient de concordance Kappa

$$Kappa = \frac{C_o - C_a}{1 - C_a}$$

- Mesure la concordance en pourcentage de la concordance maximum non liée au hasard
- Interprétation proposée par Landis-Koch (1977)
  - Kappa > 0,8 : concordance excellente
  - Kappa entre 0,6 et 0,8 : bonne concordance
  - Kappa entre 0,4 et 0,6 : concordance moyenne
  - Kappa < 0,4 : faible concordance

# Evaluation de la fiabilité d'un test qualitatif

---

- Coefficient Kappa mesurant la concordance entre les 2 radiologues

$$Kappa = \frac{0,91 - 0,57}{1 - 0,57} \approx 0,8$$

- Mesure de la reproductibilité inter observateurs
- Dans ce cas, ne permet pas de conclure à une reproductibilité excellente

# Exactitude (accuracy) d'un test diagnostique

---

- Capacité d'un test diagnostique à discriminer les malades des non malades
- Nécessite d'avoir une méthode de référence (gold standard) pour déterminer le statut réel
- Les méthodes de quantification de l'exactitude du test dépendent :
  - De la nature du test qualitative ou quantitative
  - De la phase d'évaluation du test précoce ou tardive

# Qualités intrinsèques d'un test diagnostique

---

- Sensibilité :
  - capacité du test à identifier les malades
  - Probabilité que le test soit positif chez les malades
- Spécificité :
  - capacité du test à identifier les non malades
  - Probabilité que le test soit négatif chez les non malades
- Ne dépendent pas de la prévalence de la maladie
- Peuvent dépendre des caractéristiques des sujets, des conditions de réalisation du test...

# Qualités intrinsèques d'un test diagnostique

		Etat réel des sujets	
		Malade	Non-malade
Test	Positif	VP	FP
	Négatif	FN	VN

$$\text{Sensibilité : } P(\text{Test positif} | \text{Malade}) = \frac{VP}{VP + FN}$$

$$\text{Spécificité : } P(\text{Test négatif} | \text{Non Malade}) = \frac{VN}{VN + FP}$$

# Qualités intrinsèques d'un test diagnostique

---

- Test : Dosage radio-immunologique des phosphatases acides
- Maladie : cancer de la prostate
- Type d'étude : transversale sur un échantillon de malades et un échantillon de non malades
  - Echantillon de 113 malades
  - Echantillon de 240 non malades

# Qualités intrinsèques du test pour un seuil fixé

	<b>Malades</b>	<b>Non malades</b>	
<b>Test +</b>	79	31	110
<b>Test -</b>	34	209	243
	113	240	353

Sensibilité =  $P[T+ | M] = 79/113 = 70\%$

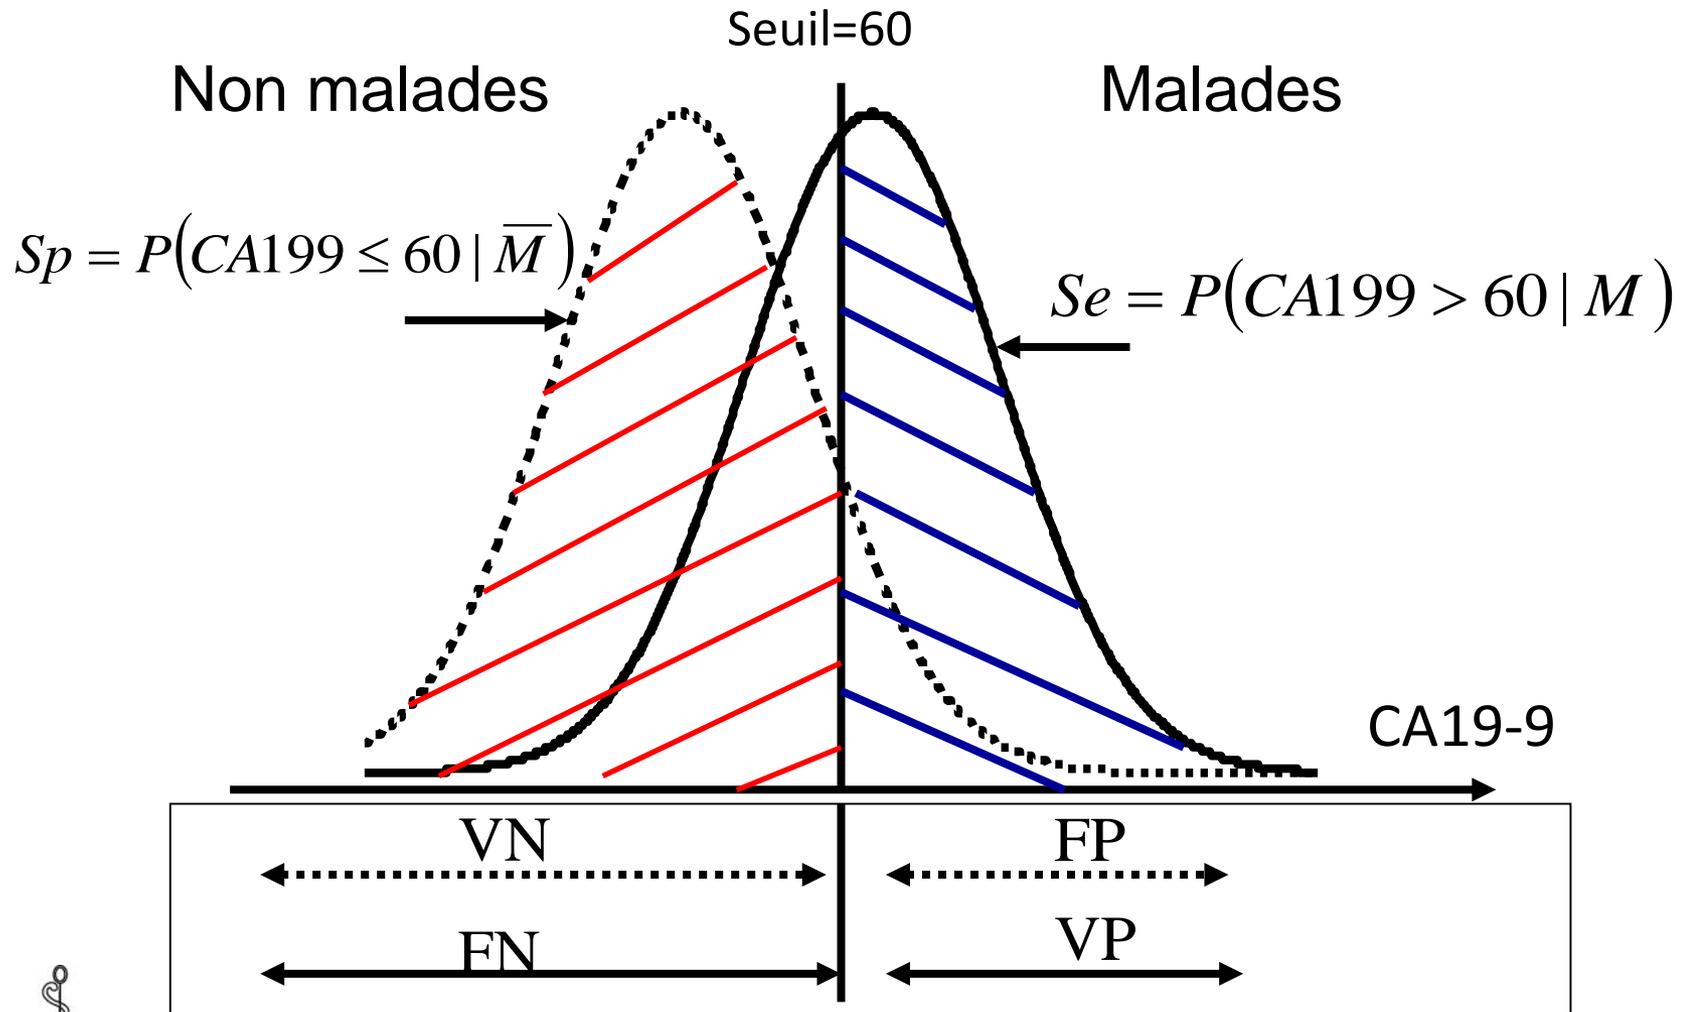
Spécificité =  $P[T- | NM] = 209/240 = 87\%$

# Capacité discriminante d'un test quantitatif

---

- A la phase précoce de l'évaluation d'un test quantitatif
  - Le seuil de positivité n'est pas encore fixé
  - Nécessité d'avoir une quantification globale de la capacité discriminante du test
- Exemple de l'évaluation du dosage du CA19-9 pour le diagnostic de cancer du pancréas
  - Echantillon de 90 sujets ayant un cancer du pancréas
  - Echantillon de 51 sujets n'ayant pas de cancer du pancréas
  - Dosage sanguin de CA19-9 chez les 141 sujets

# Capacité discriminante d'un test quantitatif



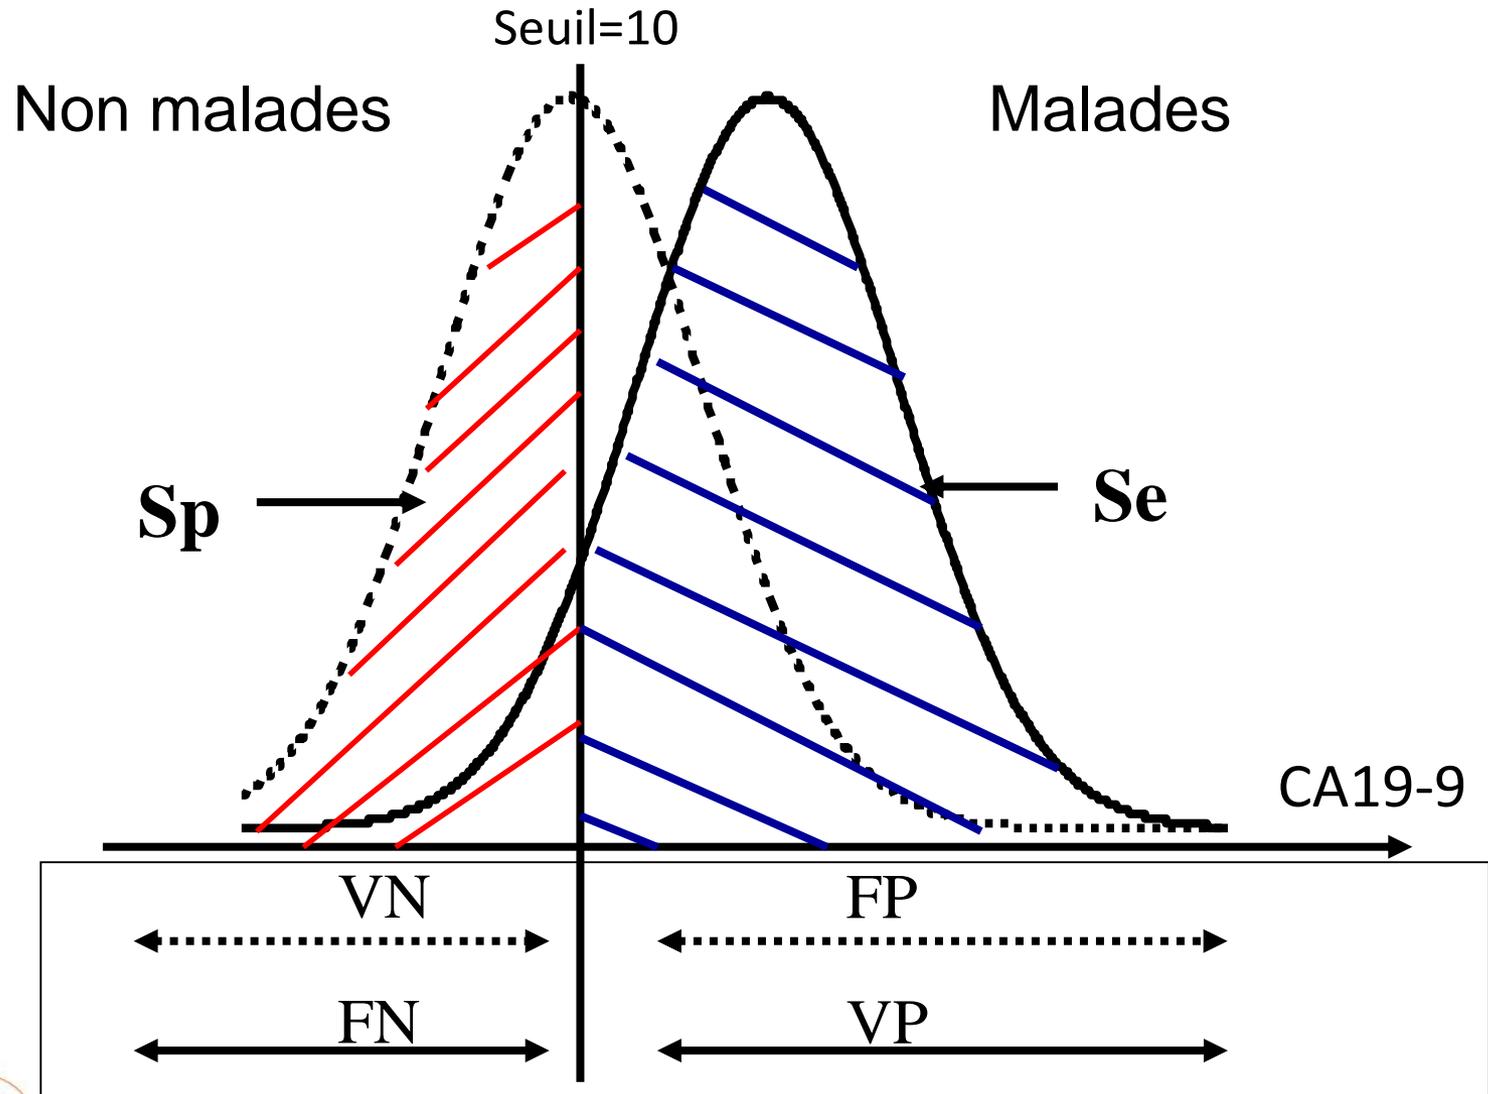
# Qualités intrinsèques pour un seuil = 60

	<b>Malades</b>	<b>Non malades</b>	
<b>Test +</b>	61	2	63
<b>Test -</b>	29	49	78
	90	51	141

Sensibilité =  $P[T+ | M] = 61/90 = 68\%$

Spécificité =  $P[T- | NM] = 49/51 = 96\%$

# Capacité discriminante d'un test quantitatif



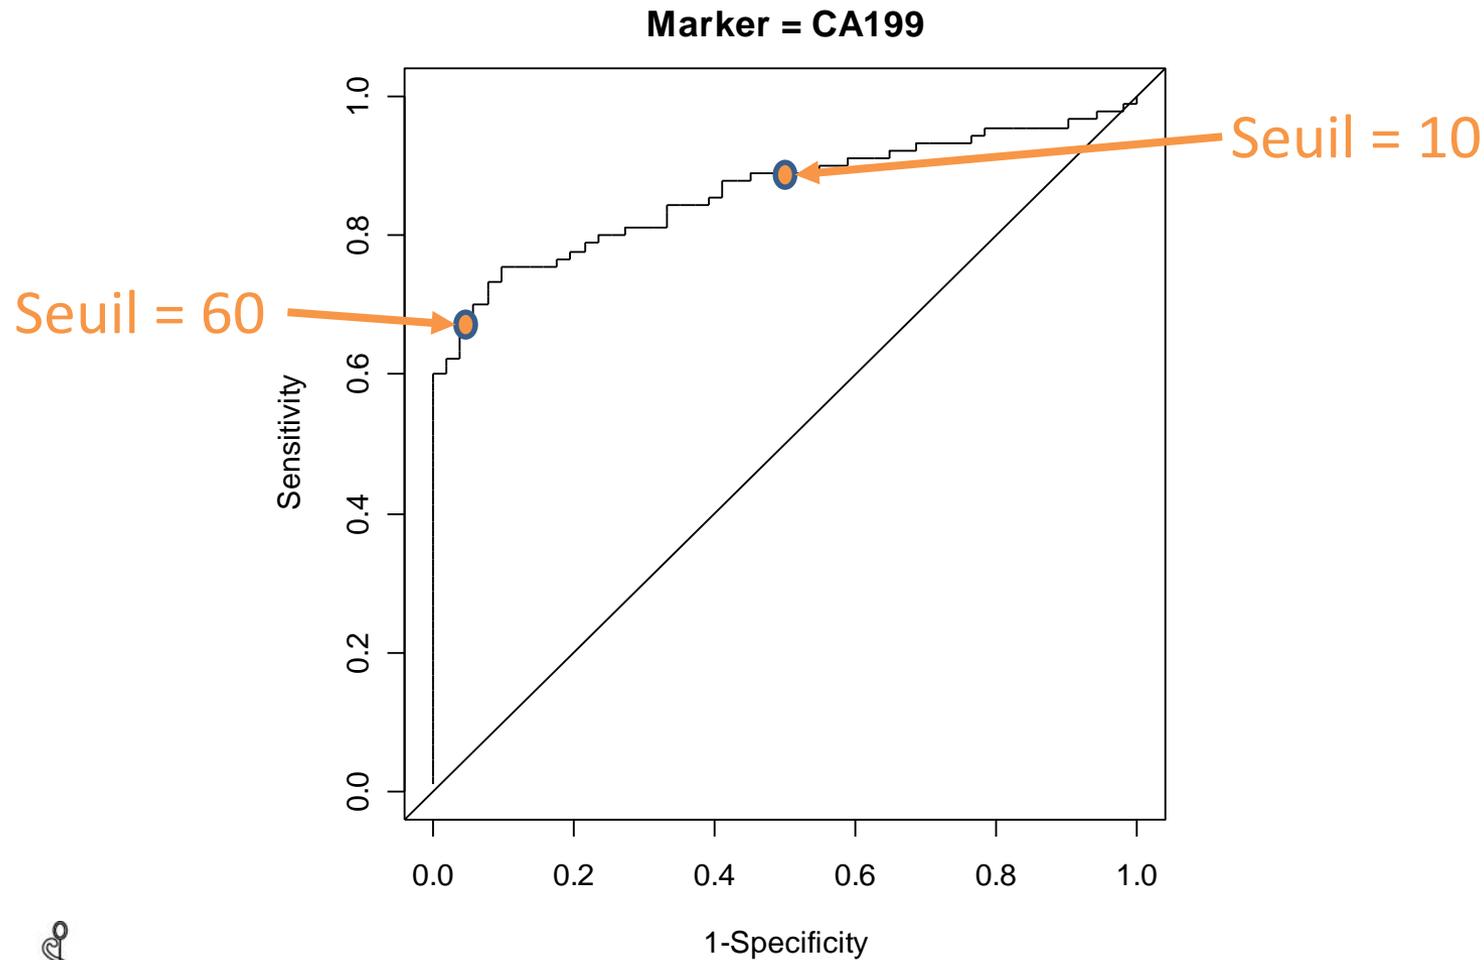
# Qualités intrinsèques pour un seuil = 10

	<b>Malades</b>	<b>Non malades</b>	
<b>Test +</b>	80	25	105
<b>Test -</b>	10	26	36
	90	51	141

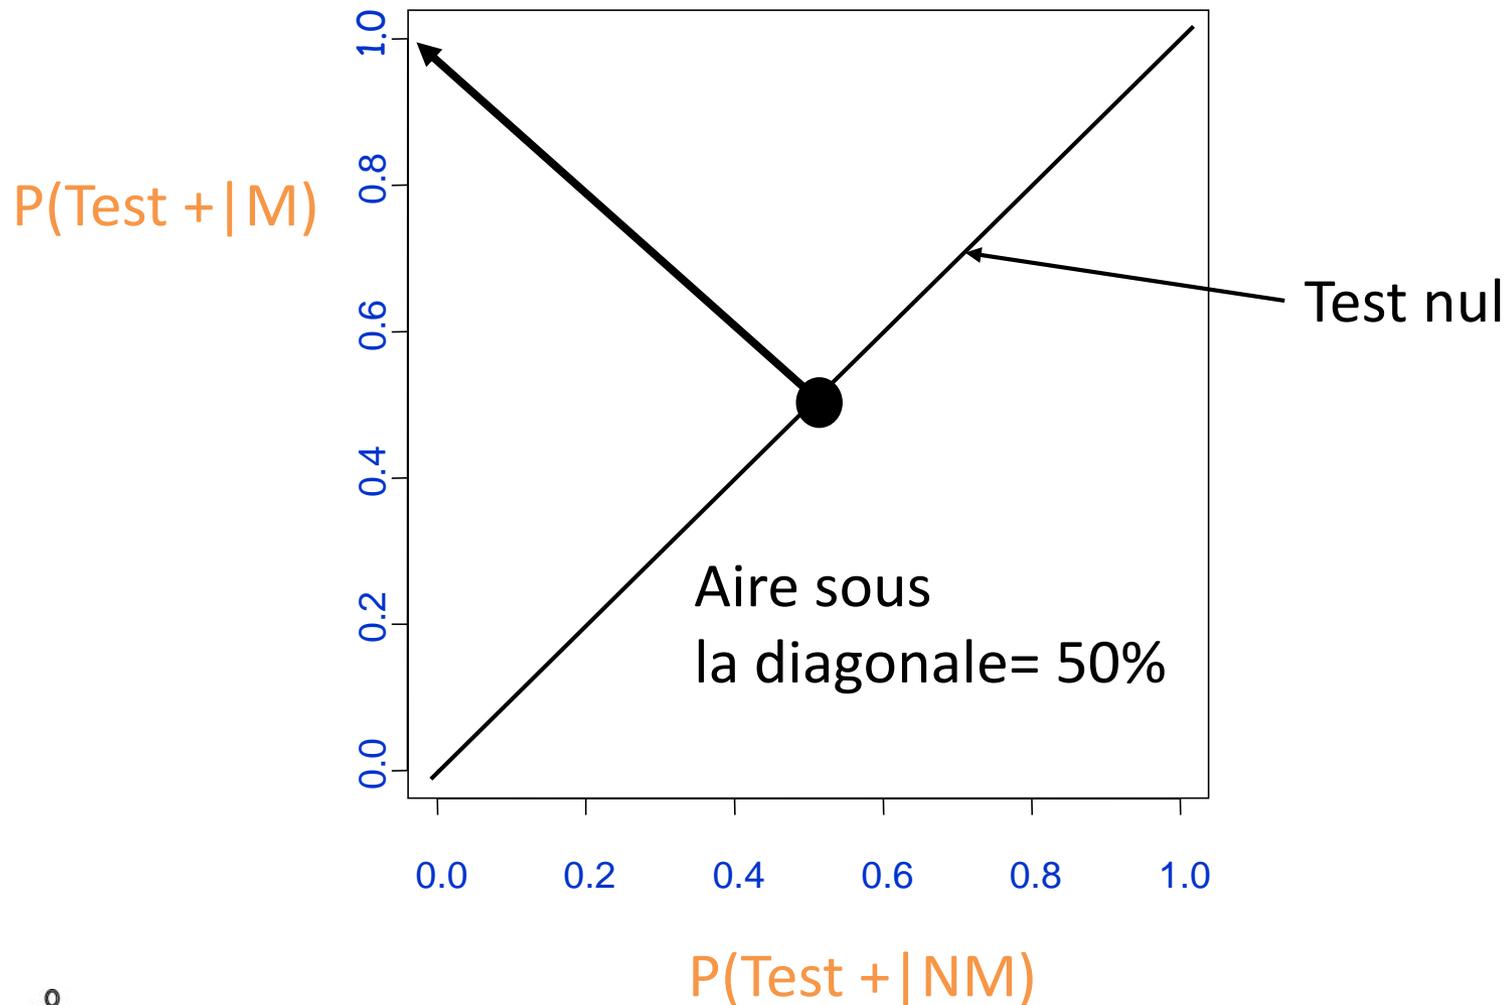
Sensibilité =  $P[T+ | M] = 80/90 = 89\%$

Spécificité =  $P[T- | NM] = 26/51 = 51\%$

# Construction de la courbe ROC empirique



# Courbe ROC



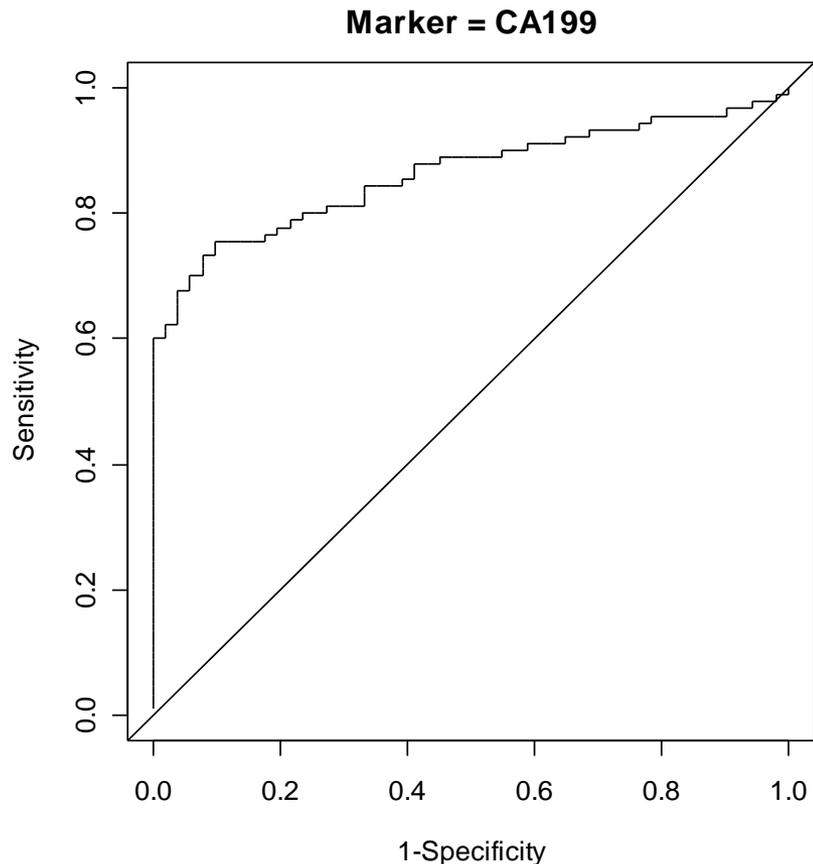
# Capacité discriminante d'un test quantitatif

---

- Construction de la courbe ROC
- Estimation de l'aire sous la courbe ROC (ASC)
- Test parfait :  $ASC = 100\%$
- Test non discriminant :  $ASC = 50\%$
- Interprétation de l'ASC :

Probabilité qu'un sujet malade est une valeur du test supérieure (inférieure) à celle d'un sujet non malade

# Aire sous la courbe ROC



Estimation de l'ASC = 86%  
Intervalle de confiance à 95% :  
[80% ; 92%]

Le test a un intérêt diagnostique

Sa capacité à discriminer les  
sujets qui ont un cancer du  
pancréas de ceux qui n'en ont  
pas est bonne

# Détermination du seuil de positivité

---

- Détermination du seuil à utiliser en pratique à la phase tardive de l'évaluation du test
- Seuil optimal dépend :
  - De la prévalence de la maladie dans la population cible
  - Des conséquences de ne pas poser le diagnostic chez un malade (traitement retardé)
  - Des conséquences de poser le diagnostic à tort chez un sujet non malade (complications des traitements)

# Qualités extrinsèques d'un test diagnostique

---

- Valeur prédictive positive (VPP) :
  - Capacité du test à affirmer la présence de la maladie en cas de test positif
  - Probabilité d'avoir la maladie lorsque le test est positif
- Valeur prédictive négative (VPN) :
  - Capacité du test à éliminer la présence de la maladie en cas de test négatif
  - Probabilité de ne pas avoir la maladie lorsque le test est négatif

# Qualités extrinsèques d'un test diagnostique

---

- VPP et VPN dépendent :
  - De la sensibilité et de la spécificité
    - Plus le test est sensible meilleure est la VPN
    - Plus le test est spécifique meilleure est la VPP
  - De la prévalence de la maladie dans la population
    - Plus la prévalence est élevée meilleure est la VPP
    - Plus la prévalence est faible meilleure est la VPN

VPP et VPN dépendent de la population dans laquelle on utilise le test

# Exemple de l'étude CASS (New England of Medicine 1979)

---

- Performances de la douleur thoracique pour faire le diagnostic de maladie coronarienne
- Echantillon de 1465 patients adressés pour suspicion de maladie coronarienne
- Gold standard = coronarographie
- Interrogatoire des patients inclus à la recherche de douleur thoracique
- En aveugle du résultat de la coronarographie

# Estimation des qualités intrinsèques du test

		Etat réel des sujets		
		M	NM	
Test	T+	969	245	1214
	T-	54	197	251
		1023	442	1465

$$\text{Sensibilité} = P[T+ | M] = \frac{969}{1023} \approx 94,7 \%$$

$$\text{Spécificité} = P[T- | NM] = \frac{197}{442} \approx 44,6 \%$$

# Estimation des qualités extrinsèques du test

		Etat réel des sujets		
		M	NM	
Test	T+	969	245	1214
	T-	54	197	251
		1023	442	1465

$$\text{Prévalence} = \frac{1023}{1465} \approx 70 \%$$

$$\text{VPP} = P[M | T +] = \frac{969}{1214} \approx 80 \%$$

$$\text{VPN} = P[NM | T -] = \frac{197}{251} \approx 78,5 \%$$

# Qualités extrinsèques du test diagnostique

---

- La prévalence (70%) = **probabilité pré-test** de maladie chez un sujet issu de la population étudiée
- VPP (80%)= **probabilité post test** de la maladie chez un sujet qui a un test positif
- 1-VPN ( 21,5%)= **probabilité post test** de la maladie chez un sujet qui a un test négatif
- **L'information apportée par le test** permet de passer de la **probabilité pré test à post test**

# Information apportée par le test diagnostique

- Ratio de vraisemblance positif de la douleur thoracique :

$$RV_{+} = \frac{P[T + | M]}{P[T + | NM]} = \frac{Se}{1 - Sp} = \frac{0,947}{1 - 0,446} = 1,7$$

Information apportée par le test quand le résultat est positif

$$RV_{+} \geq 1$$

Plus il est élevé plus il permet d'augmenter la probabilité pré test.

# Information apportée par le test diagnostique

---

- Ratio de vraisemblance négatif :

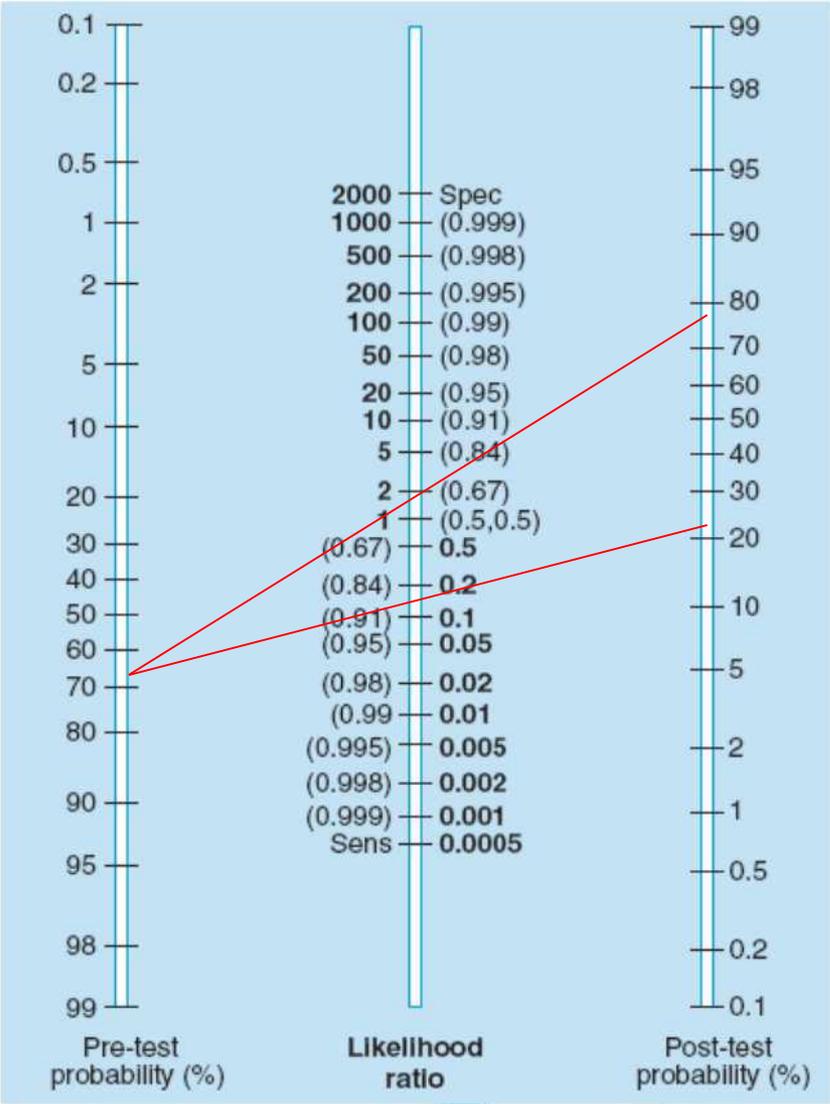
$$RV^- = \frac{P[T^- | M]}{P[T^- | NM]} = \frac{1 - Se}{Sp} = \frac{1 - 0,947}{0,446} = 0,12$$

Information apportée par le test quand le résultat est négatif

$$0 \leq RV^- \leq 1$$

Plus il est proche de 0 plus il permet de diminuer la probabilité pré test.

# Normogramme de Fagan



# Lecture critique d'une étude évaluant un test diagnostique

# Détermination de l'objectif de l'étude

---

- **Phase 1 : phase exploratoire**

Le nouveau test a-t-il un intérêt diagnostique ?

- **Phase 2 : phase de challenge**

Evaluation des performances du test dans différents sous-groupes

Comparaison aux tests existants

- **Phase 3 : phase clinique**

Evaluation des performances dans un échantillon représentatif de la population cible

Détermination du seuil pour les tests quantitatifs

# Type d'étude

---

- Etude transversale sur un échantillon de malades et un échantillon de non malades (phase 1, phase 2)
- Etude transversale ou de cohorte sur un échantillon représentatif d'une population (phase 3)
- Essai randomisé pour comparer des stratégies diagnostiques et thérapeutiques (phase 3)

# Mesure du test diagnostique

---

- En aveugle du statut vis-à-vis de la maladie
- Standardisée
- Par un échantillon de médecins représentatifs des médecins qui seront amenés à interpréter le test (phase 3)

# Choix du gold standard

---

- Gold standard parfait ou imparfait
- Définition précise de la maladie
- Détermination du statut vis-à-vis de la maladie de façon indépendante du résultat du test à évaluer
- Mesure chez tous les sujets de la même façon

# Identification de la population

---

- Déterminer les caractéristiques de la population cible
- En phase 3, privilégier les études multicentriques
- Identifier les contre-indications à la réalisation du test

# Biais potentiels

---

- Biais de sélection (échantillon non représentatif, spectre des patients insuffisants)
- Biais lié à l'utilisation d'un gold standard imparfait
- Biais lié à l'absence d'indépendance entre la détermination du statut vis-à-vis de la maladie et le résultat du test à évaluer (workup bias, incorporation bias)
- Biais de vérification (gold standard utilisé préférentiellement chez les sujets les plus à risque d'avoir la maladie)

# Analyse statistique et résultats

---

- Choix du critère de mesure de la performance diagnostique
  - Etude de phase 1 et 2 : sensibilité, spécificité, comparaison de moyennes, courbe ROC, Aire sous la courbe ROC
  - Etude de phase 3 : seuil optimal, ratios de vraisemblance, valeurs prédictives, critère de résultat clinique

# Présentation des résultats

---

- A qui généraliser les résultats ? : description de la population
- Quand estimation sensibilité, spécificité : seuil de positivité utilisé quand test quantitatif
- Quand estimation des valeurs prédictives : pour quelle prévalence de la maladie ?
- Fréquence des tests ininterprétables et causes

# STAndards for reporting of Diagnostic Accuracy (STARD)

---

- Initiative du groupe de travail de la Cochrane
- Objectif : améliorer la qualité des articles d'évaluation de méthodes diagnostiques
- Site web : [www.stard-statement.org](http://www.stard-statement.org)



## A RETENIR

- On prescrit un test diagnostique si son résultat est susceptible de modifier la prise en charge
- Un test est fiable si son résultat varie peu lorsqu'on répète la mesure
- L'exactitude d'un test dépend de sa capacité à discriminer les malades des non malades
- La sensibilité et la spécificité d'un test peuvent dépendre des caractéristiques des malades et des non malades





## A RETENIR

- Les valeurs prédictives dépendent de la prévalence de la maladie
- Les ratios de vraisemblance permettent de passer de la probabilité pré test à la probabilité post test de la maladie
- Les différentes phases d'évaluation d'un test diagnostique et les schémas d'étude associés
- Les biais potentiels spécifiques aux études d'évaluation des tests diagnostique



# MOTS EN ANGLAIS

---

- Fiabilité : reliability
- Exactitude : accuracy
- Concordance : agreement
- Sensibilité, spécificité : sensitivity, specificity
- Aire sous la courbe ROC : Area under the ROC curve
- Ratio de vraisemblance : likelihood ratio
- Valeur prédictive : predictive value

# REFERENCES

---

- Zhou XH, Obuchowski NA, McClish DK. Statistical methods in diagnostic medicine. Ed John Wiley & Sons, New York 2002.
- Sackett DL, Haynes RB. The architecture of diagnostic research. BMJ 2002; 324: 539-41
- Haynes RB, Sackett DL, Guyatt GH, Tugwell P. Clinical epidemiology. LWW, Philadelphia 2006

# Des questions

Muriel Rabilloud  
muriel.rabilloud@chu-lyon.fr