

# Epidémiologie

## Plan

---

1. Introduction
2. Enquête de cohorte
3. Enquête cas-témoins
4. Mesures de risques
5. Mesures d'association
6. Biais de sélection
7. Biais de classement
8. Biais de confusion
9. Stratégie d'analyse
10. Puissance
11. Modèles multivariés
12. Régression logistique

**Philippe SAINT PIERRE**

Université Paul Sabatier – Toulouse III

Institut de Mathématiques de Toulouse

[philippe.saint-pierre@math.univ-toulouse.fr](mailto:philippe.saint-pierre@math.univ-toulouse.fr)

# Epidémiologie

## 4. Mesures de risques

**Philippe SAINT PIERRE**

Université Paul Sabatier – Toulouse III

Institut de Mathématiques de Toulouse

[philippe.saint-pierre@math.univ-toulouse.fr](mailto:philippe.saint-pierre@math.univ-toulouse.fr)

# 4. Mesures de risques

---

## I. Prévalence

## II. Taux d'incidence

- Personnes-temps
- Enquêtes de cohorte
- Enquêtes transversale répétées
- Données de surveillance épidémiologique

## III. Risque de la maladie

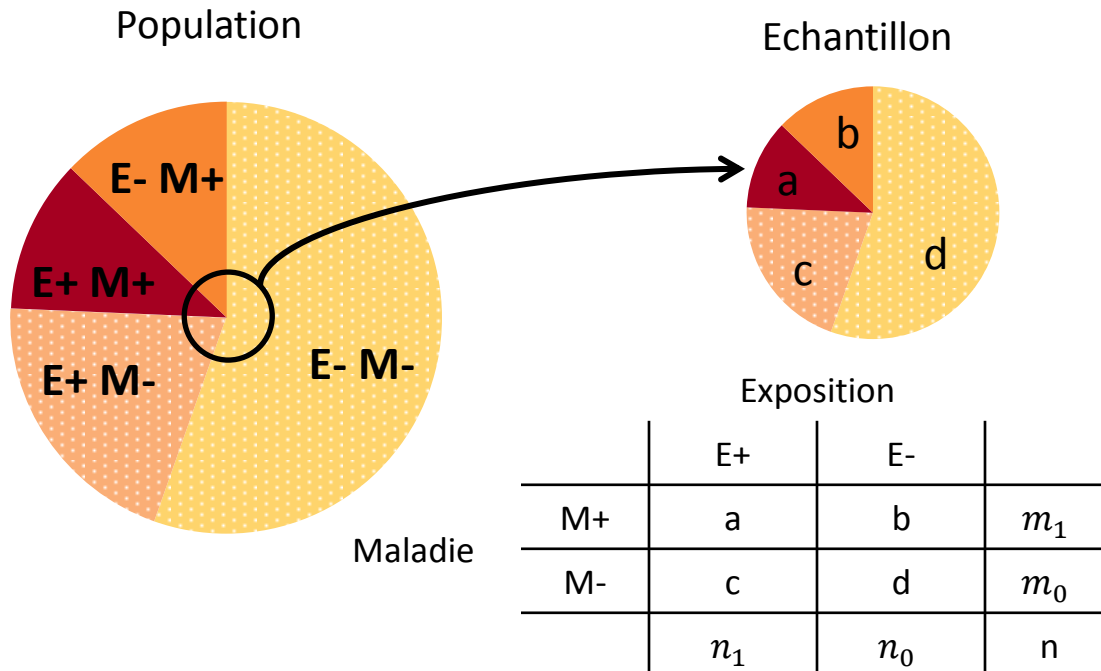
- $TI$  constant
- $TI$  variables

# I. Prévalence

- Proportion de malades  $M+$  dans une population de taille  $N$ , à un instant donné

$$P = \frac{M_1}{N} = \frac{M_1}{M_0 + M_1}$$

- Probabilité :  $P \in [0,1]$
- Estimation dans les enquêtes transversales (échantillon représentatif)



Prévalence de la maladie

$$\hat{P}(M+) = \frac{m_1}{n} = \frac{a + b}{n}$$

Prévalence de l'exposition

$$\hat{P}(E+) = \frac{n_1}{n} = \frac{a + c}{n}$$

# Prévalence

---

- Prévalence de la maladie

$$P(M+) = \frac{M_1}{N} = \frac{M_1}{M_0 + M_1}$$

- Estimation de la prévalence dans un échantillon représentatif

$$\hat{P} = \frac{m_1}{n}$$

- Intervalle de confiance de niveau  $\alpha$

$$IC_\alpha(P) = [P_{inf}; P_{sup}] = \left[ \hat{P} - z_{\frac{\alpha}{2}} \sqrt{Var(\hat{P})}; \hat{P} + z_{\frac{\alpha}{2}} \sqrt{Var(\hat{P})} \right] \quad \text{avec} \quad Var(\hat{P}) = \frac{\hat{P}(1-\hat{P})}{n}$$

## Conditions d'applications

- approximation de la loi Normale par la loi Binomiale :  $B(n, p) \xrightarrow[n \rightarrow \infty]{} N(np, np(1-p))$
- en pratique,  $nP_{inf} \geq 5, nP_{sup} \geq 5, nQ_{inf} \geq 5, nQ_{sup} \geq 5$  ( $Q = 1 - P$ )

# Prévalence : exemple

---

- Echantillon de 100 travailleurs d'une usine

Cancer	M+	20
	M-	80
		100

- Estimation de la prévalence  $\hat{P} = \frac{m_1}{n} = \frac{20}{100} = 0.2$
- Intervalle de confiance à 95%

$$IC_{0.05}(P) = \left[ 0.2 \pm 1.96 \sqrt{\frac{0.2 \times (1 - 0.2)}{100}} \right] = [0.12 ; 0.28]$$

- Conditions d'applications :
  - $100 \times 0.12 = 12 \geq 5$ ;  $100 \times 0.28 = 28$
  - $100 \times 0.88 = 88 \geq 5$ ;  $100 \times 0.72 = 72$

# Prévalence

---

- Pas toujours un bon indicateur :
  - dépend de la **durée de la maladie**  
durée augmente → prévalence augmente
  - dépend de la **vitesse d'apparition** des nouveaux cas de la maladie  
vitesse augmente → prévalence augmente
  - Ex : prévalence d'une maladie chronique et d'une infection aigue
  - Ex : augmentation de la prévalence lié à des améliorations de santé
- **Photographie à un moment donné** : introduction d'un nouvel indicateur

→ Taux d'incidence

## II. Taux d'incidence

---

- Taux d'incidence représente la **vitesse d'apparition de nouveaux** (vitesse moyenne)

$$TI = \frac{I}{PT} = \frac{\text{Nbre de nouveaux cas de la maladie}}{\text{Nbre de "personnes - temps"}}$$

- $PT$  est la **somme des temps d'exposition de chaque sujet** pendant la période de suivi
  - Ex: 20 sujets suivis pendant 2 ans correspondent à 40 personnes-année
- Unité du taux d'incidence : **nombre de nouveaux cas par "personnes - temps"**
- Intervalle de confiance de niveau  $\alpha$

$$IC_{\alpha}(TI) = [TI_{inf} ; TI_{sup}] = \left[ \widehat{TI} - z_{\frac{\alpha}{2}} \sqrt{\text{Var}(\widehat{TI})} ; \widehat{TI} + z_{\frac{\alpha}{2}} \sqrt{\text{Var}(\widehat{TI})} \right]$$

avec

$$\text{Var}(\widehat{TI}) = \frac{I}{PT^2}$$



# Taux d'incidence : personnes-temps

---

- **Sujet à risque** : sujet non malade susceptible de devenir malade
- "**personnes – temps**" d'un sujet à risque
  - **Temps d'exposition** = durée pendant laquelle un sujet peut être enregistré comme cas s'il développe la maladie étudiée
  - Le nombre de "**personnes – temps**" est **spécifique à chaque individu** et dépend de
    - la date de **début du suivi** :  $t_{0i}$
    - la date de **fin du suivi** :  $t_{fi}$

$$PT_i = \Delta t_i = t_{0i} - t_{fi}$$

- La **date de fin de suivi** peut être due à
  - La survenue de la maladie M
  - La **censure à droite**
    - Exclu-vivant : fin de l'étude et du suivi
    - Perdu de vue (déménagement, décès, arrêt volontaire du suivi, ...)

# Taux d'incidence : estimation

---

- Estimation du taux d'incidence

- a. Les enquêtes de cohorte

- ➔ population fermée et suivi individuel des sujets

- a. Les enquêtes transversales répétées

- ➔ population fermée mais dates d'évènement inconnues

- a. Les données de surveillance épidémiologique

- ➔ population ouverte et données groupées

# Taux d'incidence : enquête de cohorte

---

## a) Taux d'incidence à partir d'une enquête de cohorte

- On connaît les **temps d'exposition individuel**

$$\Delta t_i = t_{0i} - t_{fi}$$

$$PT = \sum_{i=1}^n \Delta t_i$$


- On connaît le **nombre de nouveau cas  $I$**  sur la période de suivi
- Le **taux d'incidence** peut être estimé par

$$\widehat{TI} = \frac{I}{\sum_{i=1}^n \Delta t_i}$$

# Taux d'incidence : enquête de cohorte

Début de l'étude

Fin de l'étude



- $PT = 13 + 10 + 20 + 14 + 10 + 15 + 7 = 89$  *personnes – année*
- **2 malades** pendant la période de l'étude (1990-2010)
- Taux d'incidence entre 1990 et 2010 :  $TI = \frac{2}{89} = 0.0224$  *cas pour 1 personne – année*


# Taux d'incidence : enquête de cohorte

---

- $PT = 89 \text{ personnes} - \text{année}$ 
  - = 89 sujets suivi pendant 1 année
  - = 1068 sujet suivi pendant 1 mois
  - = 1 sujet suivi pendant 89 années
  - = 0.89 sujet suivi pendant 1 siècle
- $TI = \frac{2}{89} = 0.0224 \text{ cas pour 1 personne} - \text{année} = 0,0224 \text{ cas/PA}$ 
  - = 22,4 cas pour 1000 personnes – année
- $TI = \frac{2}{1068} = 0.0019 \text{ cas pour 1 personne} - \text{mois} = 0,0019 \text{ cas/PM}$ 
  - = 1.9 cas pour 1000 personnes – mois

# Taux d'incidence : enquête de cohorte

- Calcul des personnes-temps par intervalle de temps



## Nombre de personnes-année par tranche d'âge

- $Age \in [15 - 20[ \rightarrow 3 \text{ PA}$
  - $Age \in [20 - 30[ \rightarrow 10 \text{ PA}$
  - $Age \in [30 - 40[ \rightarrow 2 \text{ PA}$
- Taux d'incidence en fonction de l'âge** (Maladie coronarienne et contraception orale)

Age	I	PA	TI $\times 10^3$
[15 - 20[	40	9228	4.3
[20 - 30[	88	8376	10.5
[30 - 40[	130	7092	18.3
	258	24696	10.4

Augmentation du taux d'incidence avec l'âge

# Taux d'incidence : enquêtes transversales répétées

---

b) Taux d'incidence à partir d'une enquête transversale recontactée après une période  $\Delta t$

- On dispose de l'informations sur
  - Le nombre de sujets  $N$  inclus dans l'étude et recontactés après une période  $\Delta t$
  - Le nombre de perdus de vue  $PDV$  sur la période  $\Delta t$
  - Le nombre de décès  $D$  sur la période  $\Delta t$
  - Le nombre sujets  $I$  qui ont développés la maladie sur la période  $\Delta t$
- Le nombre de personnes-temps peut être estimé par

$$\widehat{PT} = N \times \Delta t - \left[ (I + PDV + D) \times \frac{\Delta t}{2} \right] = \left[ N - \frac{(I + PDV + D)}{2} \right] \times \Delta t$$

- en supposant que la survenue des décès, des cas et des PDV est uniforme, c'est-à-dire qu'elle se produit en moyenne au milieu de l'intervalle

- Le taux d'incidence :  $\widehat{TI} = \frac{I}{\widehat{PT}}$

# Taux d'incidence : données de surveillance

---

## c) Taux d'incidence à partir des données de surveillance épidémiologique

- Population ouverte (Ex: une ville, une région, ...), on dispose de l'informations sur
  - Une estimation du **nombre moyen de sujets  $N$**  de la population sur la **période  $\Delta t$** 
    - ↳ obtenu à partir d'un ou plusieurs recensements ou estimations intercensitaires
  - Le **nombre sujets  $I$**  qui ont développés la maladie sur la **période  $\Delta t$** 
    - ↳ obtenu à partir d'un système d'enregistrement des cas (registre, ...)
- On suppose un **renouvellement constant de la population** (autant d'entrées que de sorties : naissances, décès, immigrations, émigrations)
  - ➔ Le nombre de personnes-temps peut être estimé par  $\widehat{PT} = N \times \Delta t$
- En supposant que la **survenue de la maladie est uniforme**, le taux d'incidence peut être estimé

$$\widehat{TI} = \frac{I}{\widehat{PT}}$$



# III. Risque de la maladie

---

- Le risque de la maladie représente la probabilité de devenir malade au cours d'une période de temps  $\Delta t$
- Soit  $X$  le temps écoulé avant l'apparition de la maladie

$$R(\Delta t) = P(X < t) = 1 - P(X \geq t) = 1 - \exp\left(-\int_0^{\Delta t} TI dt\right)$$

$$R(\Delta t) = 1 - \exp(-TI \times \Delta t)$$

- Le risque sur une période  $\Delta t$  peut être estimé par

$$\hat{R}(\Delta t) = 1 - \exp(-\widehat{TI} \times \Delta t)$$

- Hypothèse :  $TI$  est constant sur la période  $\Delta t$

# Risque de la maladie

---

- Intervalle de confiance de niveau  $\alpha$  de R

$$IC_{\alpha}(R) = [R_{inf} ; R_{sup}] = [1 - \exp(-TI_{inf} \times \Delta t) ; 1 - \exp(-TI_{sup} \times \Delta t)]$$

$$IC_{\alpha}(TI) = [TI_{inf} ; TI_{sup}] = \left[ \widehat{TI} - \frac{z_{\alpha}}{2} \sqrt{Var(\widehat{TI})} ; \widehat{P} + \frac{z_{\alpha}}{2} \sqrt{Var(\widehat{TI})} \right] \quad \text{avec} \quad Var(\widehat{TI}) = \frac{I}{PT^2}$$

- Si  $\widehat{TI} \times \Delta t$  est petit alors  $\widehat{R}(\Delta t) \approx \widehat{TI} \times \Delta t$
- Remarque : **concordance des unités**
  - Si  $\Delta t$  en années utiliser un  $TI$  annuel (cas/PA)
  - Si  $\Delta t$  en mois utiliser un  $TI$  mensuel (cas/PM)

# Risque de la maladie : exemple

---

- 1200 sujets inclus dans une étude
- Au bout de 5 ans, on observe 65 cas de maladie, 50 perdus de vue et 10 décès
- Taux d'incidence  $TI$

$$\widehat{TI} = \frac{I}{PT} = \frac{65}{\left[1200 - \frac{50+10+65}{2}\right] \times 5} = 0.0114 = 114 \text{ cas pour } 10\,000 \text{ PA}$$

$$IC_{95\%}(TI) = [TI_{inf}; TI_{sup}] = \left[ \widehat{TI} - 1.96 \sqrt{\frac{I}{PT^2}} ; \widehat{TI} + 1.96 \sqrt{\frac{I}{PT^2}} \right] = [0.086 ; 0.142]$$

- Risque de développer la maladie dans les 5 ans

$$\widehat{R}(\Delta t) = 1 - \exp(-\widehat{TI} \times \Delta t) = 1 - \exp(-0.0114 \times 5) = 5.54 \times 10^{-2} \quad \longrightarrow \quad 5.54\%$$


$$IC_{95\%}(R) = [1 - \exp(-TI_{inf}); 1 - \exp(-TI_{sup})] = [4.2 \times 10^{-2} ; 6.9 \times 10^{-2}]$$

- Risque de développer la maladie dans les 3 ans

$$\widehat{R}(\Delta t) = 1 - \exp(-\widehat{TI} \times \Delta t) = 1 - \exp(-0.0114 \times 3) = 3.4 \times 10^{-2} \quad \longrightarrow \quad 3.4\%$$

# Risque de la maladie : TI variables

Taux d'incidence variables sur la période  $\Delta t$



$$\Delta t = t - t_0$$

$$\Delta t_i = t_i - t_{i-1}$$

$$\Delta t = \sum_k \Delta t_k$$

- Soit  $TI_i$  le taux d'incidence sur  $[t_{i-1}, t_i[$ ,  $TI_i$  supposé constant sur  $[t_{i-1}, t_i[$
- Le risque sur une période  $\Delta t$  est

$$R(\Delta t) = 1 - \exp\left(-\sum_k TI_k \times \Delta t_k\right)$$

- Le risque sur une période  $\Delta t$  peut être estimé par

$$\hat{R}(\Delta t) = 1 - \exp\left(-\sum_k \hat{TI}_k \times \Delta t_k\right)$$

# Risque de la maladie : TI variables

---

- Intervalle de confiance de niveau  $\alpha$  de  $A = \sum_k TI_k \times \Delta t_k$

$$IC_{\alpha}(A) = [A_{inf} ; A_{sup}] = \left[ \hat{A} - \frac{z_{\alpha}}{2} \sqrt{Var(\hat{A})} ; \hat{A} + \frac{z_{\alpha}}{2} \sqrt{Var(\hat{A})} \right]$$

$$\hat{A} = \sum_k \widehat{TI}_k \times \Delta t_k \quad \text{et} \quad Var(\hat{A}) = \sum_k Var(\widehat{TI}_k) \times \Delta t_k^2 = \sum_k \frac{I_k}{PT_k^2} \times \Delta t_k^2$$

- Intervalle de confiance de niveau  $\alpha$  de R

$$IC_{\alpha}(R) = [R_{inf} ; R_{sup}] = [1 - \exp(-A_{inf}) ; 1 - \exp(-A_{sup})]$$

- Si  $\widehat{TI}_k \times \Delta t_k$  est petit alors  $\hat{R}(\Delta t) \approx \sum_k \widehat{TI}_k \times \Delta t_k$
- Remarque : concordance des unités

# Risque de la maladie : TI variables

---

- **Décès par maladie coronarienne** : 343 hommes d'une entreprise de sulfure de carbone suivis pendant 10 ans

Age	Décès	PA	<i>TI</i> pour 1000 PA
[25 – 40[	0	480	0
[40 – 45[	1	587	1.7
[45 – 50[	3	680	4.4
[50 – 55[	5	541	9.2
[55 – 60[	8	479	16.7
[60 – 65[	8	356	22.5
[65 – 70[	4	157	25.5
	29	3280	8.8

- **Risque de décéder pendant une période donnée ?**
- **Hypothèses** : - *TI* constant dans chaque tranche d'âge
  - Pas d'effet génération (risque de décéder entre 50 et 55 ans est une bonne estimation pour un individu de 30 ans)

# Risque de la maladie : TI variables

---

- Risque de décéder entre 25 et 55 ans

$$\begin{aligned}R(25 - 55) &= 1 - \exp(-\sum_k TI_k \times \Delta t_k) \\ &= 1 - \exp(-[0 \times 15 + 5 \times (0.0017 + 0.0044 + 0.0092)]) \\ &= 1 - \exp(-0.0765) = 0,0736\end{aligned}$$

Le risque de décéder entre 25 et 75 ans est de 7.36%

- Intervalle de confiance

- $\hat{A} = \sum_k \widehat{TI}_k \times \Delta t_k = 0.0765$

- $Var(\hat{A}) = \sum_k \frac{I_k}{PT_k^2} \times \Delta t_k^2 = \frac{0}{480^2} \times 15^2 + \frac{1}{587^2} \times 5^2 + \frac{3}{680^2} \times 5^2 + \frac{5}{541^2} \times 5^2 = 0.0007$

$$IC_{95\%}(A) = [A_{inf}; A_{sup}] = [0.0765 \pm 1.96\sqrt{0.0007}] = [0.026; 0.127]$$

$$IC_{95\%}(R) = [1 - \exp(-0.026); 1 - \exp(-0.127)]$$

$$IC_{95\%}(R) = [0.025; 0.119]$$

# Taux d'incidence et prévalence

---

- Relation entre le taux d'incidence et la prévalence

$$P = \frac{TI \times d}{1 + TI \times d}$$

- $d$  est la durée moyenne de la maladie
  - $TI$  le taux d'incidence
  - $P$  la prévalence
- 
- Hypothèse : population stable
  - Si  $TI$  est petit alors  $P \approx TI \times d$



# Epidémiologie

## 5. Mesures d'association

**Philippe SAINT PIERRE**

Université Paul Sabatier – Toulouse III

Institut de Mathématiques de Toulouse

[philippe.saint-pierre@math.univ-toulouse.fr](mailto:philippe.saint-pierre@math.univ-toulouse.fr)

# 5. Mesures d'association

---

## I. Mesures d'association

- Estimation du risque relatif et de l'odds ratio
- Intervalles de confiance et test d'une association
- Mesures d'association et types d'enquêtes

## II. Notion de causalité

- Critères de Bradford Hill

## III. Mesures d'impact potentiel

- Intervalles de confiance

		Exposition		
		E+	E-	
Maladie	M+	A	B	$M_1$
	M-	C	D	$M_0$
		$N_1$	$N_0$	

- Exposition est t'elle associée à la maladie ?
  - Mesures d'association : Risque relatif, Odds ratio
- Est-ce une relation causale ?
  - Critères de causalité, faisceau d'arguments
- Si relation causale, quelle est la proportion de cas attribuable à l'exposition ?
  - Mesures d'impact potentiel

# I. Mesures d'association

		Exposition		
		E+	E-	
Maladie	M+	A	B	M <sub>1</sub>
	M-	C	D	M <sub>0</sub>
		N <sub>1</sub>	N <sub>0</sub>	

$$P_1 = P(M+ | E+) = \frac{A}{N_1}$$

$$P_0 = P(M+ | E-) = \frac{B}{N_0}$$

• **Modèle additif**  $\longrightarrow$  Différence de risque :  $\Delta = P_1 - P_0$

• **Modèle multiplicatif**  $\longrightarrow$  Risque relatif :  $RR = \frac{P_1}{P_0}$

$\longrightarrow$  Odds ratio :  $OR = \frac{P_1 / (1 - P_1)}{P_0 / (1 - P_0)}$

• **Absence d'association** :  $\Delta = 0$      $RR = 1$      $OR = 1$

# Estimation des mesures d'association

		Exposition		
		E+	E-	
Maladie	M+	a	b	$m_1$
	M-	c	d	$m_0$
		$n_1$	$n_0$	$n$

$$\hat{P}_1 = \hat{P}(M+ | E+) = \frac{a}{n_1}$$

$$\hat{P}_0 = \hat{P}(M+ | E-) = \frac{b}{n_0}$$

- Différence de risque :  $\hat{\Delta} = \hat{P}_1 - \hat{P}_0 = \frac{a}{n_1} - \frac{b}{n_0}$

- Risque relatif :  $\widehat{RR} = \frac{\hat{P}_1}{\hat{P}_0} = \frac{a/n_1}{b/n_0}$

- Odds ratio :  $\widehat{OR} = \frac{\hat{P}_1 / (1 - \hat{P}_1)}{\hat{P}_0 / (1 - \hat{P}_0)} = \frac{ad}{bc}$

# Exemple 1

---

		Alcool (consommation quotidienne)		
		≥ 40 cl	<40 cl	
Hypotrophie foétale	M+	20	189	209
	M-	392	7372	7764
		412	7561	

$$\widehat{RR} = \frac{20/412}{189/7561} = 1.94$$

$$\widehat{OR} = \frac{20 \times 7372}{189 \times 392} = 1.99$$

# Exemple 2

		Accouchement prématuré			$\widehat{RR}$	$\widehat{OR}$
		M-	M+	P(M+ E)		
Durée de scolarisation des parents	> 12 ans	243	7	2.8%	1	1
	9 - 12 ans	412	16	3.7%	1.34	1.35
	≤ 9 ans	181	9	4.7%	1.69	1.73

	9 - 12 ans	> 12 ans
M+	16	7
M-	412	243
	428	250

$$\widehat{RR} = \frac{16/428}{7/250} = \frac{3.7}{2.8} = 1.34 ; \quad \widehat{OR} = \frac{16 \times 243}{412 \times 7} = 1.35$$

	≤ 9 ans	> 12 ans
M+	9	7
M-	181	243
	190	250

$$\widehat{RR} = \frac{9/190}{7/250} = \frac{4.7}{2.8} = 1.69 ; \quad \widehat{OR} = \frac{9 \times 243}{181 \times 7} = 1.73$$

# Intervalles de confiance

	E+	E-	
M+	a	b	$m_1$
M-	c	d	$m_0$
	$n_1$	$n_0$	$n$

$$\widehat{RR} = \frac{a/n_1}{b/n_0}$$

$$\widehat{OR} = \frac{ad}{bc}$$

- $\ln(\widehat{RR})$  et  $\ln(\widehat{OR})$  convergent vers des lois normales quand  $n \rightarrow \infty$

$$IC_\alpha(\ln(RR)) := [B_{inf}; B_{sup}] = \ln(\widehat{RR}) \pm z_{\frac{\alpha}{2}} \sqrt{Var(\ln(\widehat{RR}))} \quad \text{et} \quad Var(\ln(\widehat{RR})) = \frac{c}{a \times n_1} + \frac{d}{b \times n_0}$$

$$IC_\alpha(\ln(OR)) := [L_{inf}; L_{sup}] = \ln(\widehat{OR}) \pm z_{\frac{\alpha}{2}} \sqrt{Var(\ln(\widehat{OR}))} \quad \text{et} \quad Var(\ln(\widehat{OR})) = \frac{1}{a} + \frac{1}{b} + \frac{1}{c} + \frac{1}{d}$$

- Intervalle de confiance de niveau  $\alpha$  pour RR et OR

$$IC_\alpha(RR) := [e^{B_{inf}}; e^{B_{sup}}]$$

$$IC_\alpha(OR) := [e^{L_{inf}}; e^{L_{sup}}]$$



# Exemple 1 (suite)

		Alcool (consommation quotidienne)		
		≥ 40 cl	<40 cl	
Hypotrophie foetale	M+	20	189	209
	M-	392	7372	7764
		412	7561	

$$\widehat{RR} = \frac{20/412}{189/7561} = 1.94; \quad \ln(\widehat{RR}) = 0.67$$

$$\begin{aligned} \text{Var}(\ln(\widehat{RR})) &= \frac{392}{20 \times 412} + \frac{7372}{189 \times 7561} \\ &= 0.053 \end{aligned}$$

$$\begin{aligned} IC_{95\%}(\ln(RR)) &:= 0.67 \pm 1.96\sqrt{0.053} \\ &[ 0.219; 1.121 ] \end{aligned}$$

$$\begin{aligned} IC_{95\%}(RR) &:= [ e^{0.219}; e^{1.121} ] \\ &[ 1.25; 3.07 ] \end{aligned}$$

$$\widehat{OR} = \frac{20 \times 7372}{189 \times 392} = 1.99; \quad \ln(\widehat{OR}) = 0.69$$

$$\begin{aligned} \text{Var}(\ln(\widehat{OR})) &= \frac{1}{20} + \frac{1}{189} + \frac{1}{392} + \frac{1}{7372} \\ &= 0.058 \end{aligned}$$

$$\begin{aligned} IC_{95\%}(\ln(OR)) &:= 0.69 \pm 1.96\sqrt{0.058} \\ &[ 0.218; 1.162 ] \end{aligned}$$

$$\begin{aligned} IC_{95\%}(OR) &:= [ e^{0.218}; e^{1.162} ] \\ &[ 1.24; 3.20 ] \end{aligned}$$

# Test d'une association : test du Chi-2

	E+	E-	
M+	a	b	$m_1$
M-	c	d	$m_0$
	$n_1$	$n_0$	$n$

Test de l'hypothèse  $H_0$  contre  $H_1$

$$H_0: P(M+ | E+) = P(M+ | E-)$$

$$\Leftrightarrow H_0: RR = 1 \quad (\text{ou } OR = 1)$$

$$H_1: P(M+ | E+) \neq P(M+ | E-)$$

$$\Leftrightarrow H_1: RR \neq 1 \quad (\text{ou } OR \neq 1)$$

- Test d'indépendance du Chi-2 : sous  $H_0$ ,  $C_{ij} = \frac{n_i m_j}{n}$

$$X_a = \sum_{\substack{i=0,1 \\ j=0,1}} \frac{(O_{ij} - C_{ij})^2}{C_{ij}} = \frac{n(ad - bc)^2}{n_1 n_0 m_1 m_0} \quad \text{et} \quad X_a \equiv \chi^2(1)$$

$$X_b = \frac{\left[ a - \frac{n_1 m_1}{n} \right]^2}{\frac{n_1 n_0 m_1 m_0}{n^2 (n-1)}} = \frac{n}{(n-1)} X_a \quad \text{et} \quad X_b \equiv \chi^2(1)$$

- Conditions d'application :  $C_{ij} \geq 5$  pour tout  $i$  et  $j$ .

# Test d'une association : test du Chi-2

---

- Au niveau  $\alpha$ ,  $H_0 : RR = 1$  (ou  $OR = 1$ )
  - Rejet de  $H_0$  si  $X_a \geq \chi^2_\alpha$  où  $\chi^2_\alpha$  est le quantile de niveau  $\alpha$  d'une  $\chi^2(1)$
  - $p = P(\chi^2(1) > X_a)$   $p$  degrés de signification
  - Rq : Rejet de  $H_0$  si l'IC du RR ou de l'OR ne contient pas la valeur 1
- Test unilatéral  $H_0 : RR = 1$  contre  $H_1 : RR > 1$ 
  - Rejet de  $H_0$  si  $X_a \geq \chi^2_{2\alpha}$  et si  $\widehat{RR} > 1$
  - $p = \frac{1}{2}P(\chi^2(1) > X_a)$   $p$  degrés de signification

# Test d'une association : test du Chi-2

---

- Si  $3 \leq C_{ij} < 5$  : Test du Chi-2 corrigé de Yates

$$X_c = \sum_{\substack{i=0,1 \\ j=0,1}} \frac{(|O_{ij} - C_{ij}| - 0,5)^2}{C_{ij}} = \frac{n \left( |ad - bc| - \frac{n}{2} \right)^2}{n_1 n_0 m_1 m_0} \quad \text{et} \quad X_c \equiv \chi^2(1)$$

- Si  $C_{ij} < 3$  : Test exact de Fisher



Consiste à calculer les p-values exactes en calculant les probabilités d'obtenir chacun des tableaux possibles

# Exemple 1 (suite)

		Alcool (consommation quotidienne)		
		≥ 40 cl	<40 cl	
Hypotrophie fœtale	M+	20	189	209
	M-	392	7372	7764
		412	7561	7973

- Test de l'association

$$X_a = \frac{7973 \times (20 \times 7372 - 189 \times 392)^2}{412 \times 7561 \times 209 \times 7764} = 8.49$$

$$8.49 = X_a > \chi^2_{0.05} = 3.84 \longrightarrow \text{Rejet de } H_0$$

$$P(\chi^2(1) > 8.49) = p < 0.01$$

- Mesures d'association

$$\widehat{RR} = 1.94$$

$$IC_{95\%}(RR) : [ 1.25 ; 3.07 ]$$

$$\widehat{OR} = 1.99$$

$$IC_{95\%}(OR) : [ 1.24 ; 3.20 ]$$

# Mesures d'association et type d'enquête

		Exposition		
		E+	E-	
Maladie	M+	a	b	$m_1$
	M-	c	d	$m_0$
		$n_1$	$n_0$	$n$

$$\hat{P}_1 = \hat{P}(M+ | E+) = \frac{a}{n_1}$$

$$\hat{P}_0 = \hat{P}(M+ | E-) = \frac{b}{n_0}$$

$$\hat{P}_{E1} = \hat{P}(E+ | M+) = \frac{a}{m_1}$$

$$\hat{P}_{E0} = \hat{P}(E+ | M-) = \frac{c}{m_0}$$

- Risque relatif :

$$\widehat{RR} = \frac{\hat{P}_1}{\hat{P}_0} = \frac{a/n_1}{b/n_0} \neq \frac{\hat{P}_{E1}}{\hat{P}_{E0}}$$

- Odds ratio :

$$\widehat{OR} = \frac{\hat{P}_1 / (1 - \hat{P}_1)}{\hat{P}_0 / (1 - \hat{P}_0)} = \frac{ad}{bc} = \frac{\hat{P}_{E1} / (1 - \hat{P}_{E1})}{\hat{P}_{E0} / (1 - \hat{P}_{E0})}$$

# Enquête transversale

---

		Exposition		
		E+	E-	
Maladie	M+	a	b	$m_1$
	M-	c	d	$m_0$
		$n_1$	$n_0$	$n$

- Prévalence de M+ chez les E+ et les E- **estimables** :  $\hat{P}_1 = \frac{a}{n_1}$  et  $\hat{P}_0 = \frac{b}{n_0}$
- Prévalence de E+ chez les M+ et les M- **estimables** :  $\hat{P}_{E1} = \frac{a}{m_1}$  et  $\hat{P}_{E0} = \frac{c}{m_0}$
- Risque relatif et odds ratio sont **estimables**

$$\widehat{RR} = \frac{\hat{P}_1}{\hat{P}_0} = \frac{a/n_1}{b/n_0} \qquad \widehat{OR} = \frac{\hat{P}_1 / (1 - \hat{P}_1)}{\hat{P}_0 / (1 - \hat{P}_0)} = \frac{\hat{P}_{E1} / (1 - \hat{P}_{E1})}{\hat{P}_{E0} / (1 - \hat{P}_{E0})} = \frac{ad}{bc}$$

# Enquête exposé – non exposé

		Exposition		
		E+	E-	
Maladie	M+	a	b	$m_1$
	M-	c	d	$m_0$
		$n_1$	$n_0$	$n$

**Fixes**

- Prévalence de M+ chez les E+ et les E- **estimables** :  $\hat{P}_1 = \frac{a}{n_1}$  et  $\hat{P}_0 = \frac{b}{n_0}$
- Prévalence de E+ chez les M+ et les M- **non estimables**
- Risque relatif et odds ratio sont **estimables**

$$\widehat{RR} = \frac{\hat{P}_1}{\hat{P}_0} = \frac{a/n_1}{b/n_0} \qquad \widehat{OR} = \frac{\hat{P}_1 / (1 - \hat{P}_1)}{\hat{P}_0 / (1 - \hat{P}_0)} = \frac{ad}{bc}$$



# Enquête cas-témoins

		Exposition			
		E+	E-		
Maladie	M+	a	b	$m_1$	} <b>Fixes</b>
	M-	c	d	$m_0$	
		$n_1$	$n_0$	$n$	

- Prévalence de M+ chez les E+ et les E- **non estimables**
- Prévalence de E+ chez les M+ et les M- **estimables** :  $\hat{P}_{E1} = \frac{a}{m_1}$  et  $\hat{P}_{E0} = \frac{c}{m_0}$
- Risque relatif **non estimable**
- Odds ratio **estimable** par l'intermédiaire de  $\hat{P}_{E1}$  et  $\hat{P}_{E0}$

$$\widehat{OR} = \frac{\hat{P}_{E1} / (1 - \hat{P}_{E1})}{\hat{P}_{E0} / (1 - \hat{P}_{E0})} = \frac{ad}{bc}$$

# Choix des mesures d'association

---

- Risque relatif
  - Interprétation simple
  - Non estimable dans les enquêtes cas-témoins
- Odds ratio
  - Estimable dans tous les types d'enquêtes
  - Interprétation :  $OR \approx RR$  quand la maladie est rare dans la population
- Relation entre risque relatif et odds ratio

$$RR = \frac{OR}{1 + P_0(OR - 1)} \quad \text{et} \quad OR = \frac{RR(1 - P_0)}{1 - P_0 \times RR}$$

Si  $P_0 = P(M + | E -)$  et  $P_1 = P(M + | E +) = P_0 \times RR$  petits alors  $OR \approx RR$

## II. Notion de causalité

---

- Enquêtes expérimentales randomisées
  - difficultés pratiques

 Preuve de causalité

- Enquêtes observationnelles
  - Enquête transversale, cas-témoins, cohorte
  - Souvent les seules possibles
  - Pas d'interprétation causale

 Présomption de causalité

# Critères de présomption causale de Bradford Hill

---

## Critères internes à l'étude

1. Force de l'association
2. Relation dose- effet
3. Pas d'ambiguïté sur la chronologie
4. Spécificité de l'association

# Critères internes à l'étude

---

## 1. Force de l'association « strength »

Type de cancer	Facteur de risque	Risque Relatif
Sein	Radiations > 100 rad	3
Poumon	Cigarette > 25 cig/ j	10
Oesophage	Alcool > 100g/ j	17.5
Mésothéliome	Amiante (exp. prof.)	>200
Vessie	Benzidine (exp. Prof.)	500

## 2. Relation dose- effet « biologic gradient »

	Nb de cigarettes fumées par jour	Risque Relatif
Relation tabac – cancer de la vessie	Non fumeur	1
	1 - 19 cig/ j	2.9
	20 - 39 cig/ j	3.5
	>= 40 cig/ j	4


# Critères internes à l'étude

---

## 3. Chronologie « temporality » : l'exposition (la cause) doit précéder l'effet

- Problème si enquête transversale ou cas-témoins
- Ex : Lien entre cancer du pancréas et diabète

		Diabète	
		oui	non
Cancer pancréas	oui	a	b
	non	c	d



## 4. Spécificité des associations : la cause doit conduire à un seul effet

- Critère critiqué
- Par exemple: Tabac associé au cancer du poumon et aux pathologies cardio-vasculaires
- Ex : Exposition au Benzène associée à un type bien particulier de leucémie

# Critères de présomption causale de Bradford Hill

---

## Critères externes à l'étude

5. **Constance des résultats** dans diverses études (reproductibilité)
6. **Plausibilité biologique** de l'hypothèse
7. **Cohérence des résultats** avec les hypothèses qui ont conduit à la mise en œuvre de l'étude (cohérence interne des résultats d'un sous-groupe à l'autre)

### III. Mesures d'impact potentiel

---


- Exemple : Amiante est la cause de la maladie
- Quelle est la proportion de cas attribuables au l'amiante ?

- Nombre de malade :  $M = P(M+) \times N$

Prévalence de la maladie   taille de l'échantillon

- Nombre de malades à cause de l'exposition :

$$M^* = M - P(M+ | E-) \times N$$

 prévalence de la maladie  
chez les non exposés E-



# Risque attribuable à l'exposition

---

- $P_M = P(M +)$        $P_0 = P(M + | E-)$        $P_1 = P(M + | E+)$

$$P_E = P(E+) \quad RR = \frac{P_1}{P_0}$$

$$P_M = P_E P_1 + (1 - P_E) P_0 = P_0 P_E \left( \frac{P_1}{P_0} - 1 \right) + P_0$$

- Risque attribuable à une exposition

$$RA = \frac{M^*}{M} = \frac{P_M - P_0}{P_M} = \frac{P_E(RR - 1)}{P_E(RR - 1) + 1}$$

# Exemple

---

- Risque relatif entre une maladie et l'amiante  $RR = 9.77$
- Prévalence de l'amiante dans la population  $P_E = 5\%$

$$\widehat{RA} = \frac{\widehat{P}_E(\widehat{RR} - 1)}{\widehat{P}_E(\widehat{RR} - 1) + 1} = \frac{0.05(9.77 - 1)}{0.05(9.77 - 1) + 1} = 0.30$$

30% des cas de la maladie sont attribuables à l'exposition à l'amiante

- Prévalence de l'amiante dans la population  $P_E = 10\%$

$$\widehat{RA} = \frac{\widehat{P}_E(\widehat{RR} - 1)}{\widehat{P}_E(\widehat{RR} - 1) + 1} = \frac{0.1(9.77 - 1)}{0.1(9.77 - 1) + 1} = 0.47$$

47% des cas de la maladie sont attribuables à l'exposition à l'amiante

# Risque attribuable et type d'enquête

---

**Enquête transversale et enquête de cohorte où  $P_E$  est estimable**

$$\widehat{RA} = \frac{\widehat{P}_E(\widehat{RR} - 1)}{\widehat{P}_E(\widehat{RR} - 1) + 1}$$

**Enquête cas-témoins**

$RR, P_M$  et  $P_E$  non estimables

$$P_E = P_M P(E + |M+) + (1 - P_M) P(E + |M-)$$

Si la maladie est rare dans la population,

$$\widehat{RA} = \frac{\widehat{P}_{E0}(\widehat{OR} - 1)}{\widehat{P}_{E0}(\widehat{OR} - 1) + 1}$$

Prévalence de l'exposition  
chez les témoins  $\widehat{P}(E + |M-)$



# Intervalles de confiance

	E+	E-	
M+	a	b	$m_1$
M-	c	d	$m_0$
	$n_1$	$n_0$	$n$

$$\widehat{RA} = \frac{\widehat{P}_E(\widehat{RR} - 1)}{\widehat{P}_E(\widehat{RR} - 1) + 1}$$

- $\ln(1 - \widehat{RA})$  converge vers une loi normale quand  $n \rightarrow \infty$

$$IC_\alpha(\ln(1 - RA)) := [B_{inf}; B_{sup}] = \ln(1 - \widehat{RA}) \pm z_{\frac{\alpha}{2}} \sqrt{\text{Var}(\ln(1 - \widehat{RA}))}$$

- Intervalle de confiance de niveau  $\alpha$  pour  $RA$

$$IC_\alpha(RA) := [1 - e^{B_{sup}}; 1 - e^{B_{inf}}]$$

# Intervalle de confiance

---

$$IC_{\alpha}(\ln(1 - RA)) := \ln(1 - \widehat{RA}) \pm z_{\frac{\alpha}{2}} \sqrt{\text{Var}(\ln(1 - \widehat{RA}))}$$

- Enquête transversale

$$\text{Var}(\ln(1 - \widehat{RA})) = \frac{1}{n} \left( \frac{c + \widehat{RA}(a + d)}{b} \right)$$

- Enquête cas-témoins

$$\text{Var}(\ln(1 - \widehat{RA})) = \frac{a}{b \times m_1} + \frac{c}{d \times m_0}$$

- Enquête de cohorte où  $P_E$  estimable

$$\text{Var}(\ln(1 - \widehat{RA})) = P_E^2 (1 - \widehat{RA})^4 \widehat{RR}^2 \left( \frac{c}{an_1} + \frac{c}{bn_0} \right)$$

# Exemple : enquête transversale

---

	E+	E-	
M+	15	30	15
M-	135	820	955
	150	850	1000

$$\widehat{P}_E = \frac{150}{1000} = 0.15$$

$$\widehat{RR} = \frac{15/150}{30/850} = 2.83$$

$$\widehat{RA} = \frac{0.15(2.83 - 1)}{0.15(2.83 - 1) + 1} = 0.22$$

- $Var(\ln(1 - \widehat{RA})) = \frac{1}{1000} \left( \frac{135 + 0.22(15 + 820)}{30} \right) = 0.0105$
- $IC_{95\%}(\ln(1 - RA)) := \ln(1 - 0.22) \pm 1.96\sqrt{0.0105} = [-0.444 ; -0.042]$
- $IC_{95\%}(RA) := [1 - e^{-0.042}; 1 - e^{-0.444}] = [0.04 ; 0.36]$

# Exemple : enquête cas-témoins

---

	E+	E-	
M+	70	130	200
M-	22	178	200
	92	308	400

$$\widehat{P}_{E0} = \frac{22}{200} = 0.11$$

$$\widehat{OR} = \frac{70 \times 178}{22 \times 130} = 4.36$$

$$\widehat{RA} = \frac{0.11(4.36-1)}{0.11(4.36-1)+1} = 0.27$$

- $Var(\ln(1 - \widehat{RA})) = \frac{70}{130 \times 200} + \frac{22}{178 \times 200} = 0.0033$
- $IC_{95\%}(\ln(1 - RA)) := \ln(1 - 0.27) \pm 1.96\sqrt{0.0033} = [-0.427 ; -0.202]$
- $IC_{95\%}(RA) := [1 - e^{-0.202}; 1 - e^{-0.427}] = [0.18 ; 0.35]$