

Société de Calcul Mathématique, S. A.  
*Algorithmes et Optimisation*  
*depuis 1995*



Méthodes probabilistes pour les études épidémiologiques

Manuel pratique

*Evaluation critique d'études incorrectes*

*Essai de définition de bonnes pratiques*

Société de Calcul Mathématique SA

rédaction : Bernard Beuzamy et Manon Baradat, juillet 2009

mise à jour : Bernard Beuzamy, août 2024

## I. Introduction

En 1904, la Chambre Criminelle de la Cour de Cassation a chargé le mathématicien Henri Poincaré d'une expertise concernant le "Système Bertillon", système probabiliste de graphologie qui était à la base de l'accusation portée contre Alfred Dreyfus. Voici ce qu'écrivit Henri Poincaré dans son rapport [Poincaré] : *"le calcul des probabilités ne devrait pas empêcher les savants d'avoir du bon sens"*.

La Chambre Criminelle de la Cour de Cassation réhabilite Dreyfus et ridiculise les experts [Dreyfus] :

*"La reconstitution du Bordereau effectuée par Bertillon est fautive ; ces planches sont le résultat d'un traitement compliqué, infligé au document primitif, et d'où celui-ci est sorti altéré, après avoir subi une série d'agrandissements et de réductions photographiques, et même de calcages, recalages, découpages, collages, gouachages, badigeonnages et retouches."*

Une étude épidémiologique tend à répondre à une question du type : les lignes à haute tension favorisent-elles l'apparition de certaines maladies ? Y a-t-il davantage d'enfants autistes au voisinage des autoroutes ? Quel effet sur la santé ont les rayonnements ionisants ? Mais quelle est la valeur méthodologique de ces études ?

Les questions, en elles-mêmes, sont légitimes et raisonnables. Mais les études que nous avons examinées s'appuient sur des données brutes (des nombres de morts, dans certaines populations et dans des populations de référence) et l'examen immédiat de ces données permet de conclure immédiatement à l'inverse des auteurs : il y a moins de morts dans ces zones "à risque", proportionnellement à la population, qu'ailleurs.

Les auteurs ont-ils du bon sens ? Se sont-ils laissé abuser par ces logiciels statistiques modernes qui permettent d'obtenir n'importe quel résultat, pourvu qu'on presse le bouton approprié ? Sans doute, et l'on peut se demander, comme le fait André Aurengo [Aurengo] si l'épidémiologie est encore une science. Ou bien, comme disait plaisamment Laurent Schwartz, "quand on veut démontrer quelque chose, on y arrive toujours, même si c'est faux !".

Le principal reproche que l'on peut faire à ces études va cependant bien au-delà, et ce n'est pas seulement de manquer de bon sens. Ce n'est pas non plus la précision des calculs, la justesse des données, qui posent problème. Le problème majeur tient aux fautes de logique qui sont commises : le problème n'est pas correctement posé, et les données qui sont fournies ne peuvent permettre d'y répondre, quand bien même il y aurait dix fois plus de morts dans les zones à risque !

Henri Poincaré fait précéder son analyse critique d'un rappel des notions fondamentales des probabilités : nous suivrons son exemple – il est de plus mauvais maîtres !

Nous commençons donc par un exposé détaillé des principes probabilistes qui doivent être utilisés en épidémiologie : il s'agit de principes logiques. Après quoi, nous passons certaines études au crible des principes logiques qui viennent d'être énoncés, et les fautes apparaissent clairement.

## *A. La qualité d'une méthodologie*

Ce qu'on demande au mathématicien, c'est de se prononcer sur la qualité d'une méthodologie : nous n'avons pas à nous prononcer sur les résultats. Que les lignes HT ou les faibles doses de rayonnement soient ou non dangereuses pour la santé, ce n'est pas ce que nous examinons ici.

Les mathématiques sont de portée universelle ; elles n'obéissent qu'aux seules lois de la logique. Il n'y a pas des "mathématiques électriques" et des "mathématiques des faibles doses", il y a des mathématiques tout court, et ce sont les mêmes à Tombouctou et à Paris. Il n'y a pas non plus, comme le rappelle André Aurengo, de "mathématiques citoyennes". Si vos données au départ sont justes et si vos raisonnements sont corrects, vos conclusions auront une valeur.

La question n'est pas de savoir qui signe l'étude : une étude sur la fiabilité des chaudières, signée Landru, payée par les fabricants de chaudières, sera correcte si elle est correctement menée ; à l'inverse, une étude menée par les chercheurs de Yale, patronnée par Sainte Thérèse d'Avila, peut être sans valeur si elle comporte des fautes de logique. La question n'est pas non plus de savoir qui la finance ; ces questions : qui signe ? qui finance ? sont précisément des fautes de logique.

On nous dit souvent : mais enfin, toute une profession agit de telle manière, utilise tels tests au quotidien. Peut-être, mais cela ne lui donne pas raison pour autant. La logique n'a rien à voir avec le consensus. Des milliards de gens, tous les jours, prennent des décisions sur la foi de convictions, de croyances, que rien ne vient étayer.

Si une faute de logique est décelée, les conclusions sont sans valeur scientifique ; elles parviendront peut-être, ici ou là, à émouvoir des âmes convaincues d'avance, des journaux, des politiciens à la recherche de soutiens, tout une frange de l'humanité qui se nourrit de pseudo-science et s'y complaît, mais, encore une fois, elles sont sans valeur. Ce n'est plus notre problème ; comme disait Von Neumann, le mathématicien n'est pas responsable du monde tel qu'il est.

S'agissant de données réelles et de raisonnements en situation réelle, la notion de "donnée correcte" et de "raisonnement juste" doit être abordée avec précaution : nous ne sommes pas en présence de situations académiques, avec des tableaux bien faits et un cadre axiomatique bien défini. Toute donnée de la vie réelle est entachée d'incertitude, tout raisonnement réel fait nécessairement un certain nombre d'hypothèses, explicites ou non, qui peuvent se révéler douteuses. Et enfin, personne, et surtout pas la SCM, n'est "l'arbitre des élégances" ; nos propres raisonnements peuvent être entachés d'erreurs.

La meilleure façon de se prémunir contre ces erreurs est de tout présenter, de tout rédiger : chacun peut ainsi vérifier. Une étude scientifique n'a de valeur que si elle est intégralement vérifiable (ce qui exige que les données soient présentes). A l'inverse, un travail qui vous dit "nous sommes partis de telles données (non présentées) et nous avons fait tel test (on ne sait pas comment)" est absolument sans valeur.

C'est pourquoi, avant de présenter notre analyse critique, nous commençons par définir les règles auxquelles toute étude statistique (et notamment épidémiologique) doit se soumettre. C'est ce que nous appelons les "bonnes pratiques" ; nous les définissons de manière si explicite, si détaillée, que chacun pourra ainsi former son jugement.

Un outil très souvent utilisé est le "modèle de Cox" ; nous traitons un exemple simple (Annexe 3) : deux populations de même importance, soumises à deux traitements différents. L'un favorise la mortalité à court terme, mais garantit une certaine longévité aux survivants, et l'autre fait l'inverse, l'espérance de vie globale étant la même pour les deux. Le modèle de Cox affirme brutalement que l'une est meilleure que l'autre, ce qui est faux. Bien entendu, les hypothèses d'emploi du modèle ne sont pas respectées, mais les tests statistiques préalables à l'emploi sont cependant positifs, sans réserve !

Un autre outil souvent rencontré consiste en des études "cas-témoin" : on dispose d'une population sur laquelle on s'interroge : par exemple les enfants, vivant près d'une autoroute, sont-ils plus que les autres sujets à l'autisme ? Ou bien, ceux qui vivent près d'une ligne Haute Tension sont-ils susceptibles de développer des cancers ? On fabrique artificiellement une "population témoin", à laquelle on compare la population cible ; mais la conception arbitraire de la population témoin fait que l'étude est absolument sans valeur ; voir Annexe 3.

### *B. L'absence de danger*

On est frappé de voir que les études épidémiologiques sont incapables de conclure à l'absence de danger. On lit souvent "cette étude n'a pas pu mettre le danger en évidence" ; on ne lit jamais "cette étude montre qu'il n'y a pas de danger".

Cette incapacité est choquante à deux titres. Tout d'abord, un test, quel qu'il soit, a vocation à départager clairement entre deux situations ; on n'admettrait pas un test de grossesse qui dirait : 0 = je ne sais pas ; 1 = vous êtes enceinte.

Ensuite, on se dit, comme Poincaré, qu'un seul Bertillon manipulant un seul bordereau, ce n'est pas là le cadre adéquat pour le calcul des probabilités. Mais, s'agissant de dizaines de millions de personnes, exposées pendant des dizaines d'années, si le risque existe, on doit le voir, et s'il n'existe pas, on doit l'écrire : nous sommes là dans un cadre typique d'application de la loi des grands nombres, qui relève des sciences exactes !

En vérité, les méthodes mathématiques qui permettent de mettre en évidence le risque ou son absence existent et sont fort simples ; elles reposent d'abord sur la comparaison des cas recensés, à proportion des populations : c'est du bon sens. Nous les détaillons au Chapitre II.

Si, dans la zone à risque, il y a moins de cas (en proportion de la population) que dans la zone de référence, il faut avoir le courage de conclure : "il n'y a rien à voir", et ne pas se lancer dans l'utilisation désordonnée de tests statistiques que le premier mathématicien venu tournera en ridicule.

Mais, à l'inverse, si cette comparaison montre qu'il y a quelque chose à voir, c'est là qu'intervient l'art de l'épidémiologiste : essayer de voir si le risque est fonction de l'âge, du poids, de l'exposition au tabac, de l'usage de l'alcool, etc. Toutes ces questions sont, à l'évidence, extrêmement difficiles. Elles vont conduire à une réduction des populations prises en considération (par exemple, se limiter aux non-fumeurs, au sein de la population test et de la population de référence).

Si l'on souhaite mettre en évidence un mécanisme d'action (par exemple un champ magnétique) et pas seulement la présence d'un danger, il faut faire intervenir la physique de ce mécanisme. Un champ magnétique dépend de l'intensité du courant qui le crée et de la distance à l'observateur ; s'il est source de risque, à distance égale, il doit donc y avoir plus de cas de maladie à proximité des lignes à forte intensité que des lignes à faible intensité. Il faut avoir le courage de faire toutes les vérifications qu'implique la physique du problème et le courage de rejeter l'hypothèse faite si ces vérifications sont négatives.

Nous espérons ici que les bonnes pratiques que nous cherchons à définir permettront aux épidémiologistes une vigilance accrue quant aux outils qu'ils emploient.

## **II. Remerciements**

Nous avons rédigé et diffusé un premier document de travail ; la version 2009 tient compte :

- des commentaires du Professeur Aurengo (Hôpital de la Pitié-Salpêtrière) ;
- des documents issus du Laboratoire de Zététique, transmis par M. Aurengo ;
- du document "Revue critique des études épidémiologiques", IRSN 2008, transmis par M. Jacques Repussard ;
- des commentaires de M. Jean-Claude Barescut, IRSN.

L'analyse faite dans l'Annexe 3 (autisme et autoroutes) nous a été suggérée par David Denaux (Airbus).

Nous remercions chacun pour sa contribution.

### III. Récapitulatif des règles de bonne pratique

On dispose habituellement d'une "population-cible" : celle sur laquelle on souhaite mettre en évidence quelque chose. On veut la comparer à une "population de référence", qui devra permettre de conclure à une différence entre les deux populations.

**Règle 1.** – *La population de référence doit systématiquement être aussi vaste que possible. L'extraction aléatoire d'une population de référence représente une faute de logique, puisqu'on a extrait selon une loi de probabilité définie a priori (factice), alors que l'on ne connaît pas la vraie loi.*

**Règle 2.** - *Dans le cas de maladies liées à l'âge, analyser le nombre de morts ou de cas dans la zone test et dans la population de référence constitue une faute de logique, si l'on n'analyse pas en même temps la pyramide des âges de chaque zone.*

**Règle 3.** - *La présentation des résultats qui permet la comparaison entre la population test et la population de référence est nécessairement sous la forme d'un tableau, établissant pour chacune la probabilité de parvenir à un âge donné.*

**Règle 4.** - *La présentation par nombre de décès par tranche d'âge permet une comparaison acceptable des deux populations, si elles sont stationnaires. Si elles ne le sont pas, il faut s'assurer que les corrections nécessaires sont les mêmes pour les deux. Le résultat final doit impérativement être présenté en termes de probabilités à la naissance.*

**Règle 5.** - *La création d'un panel-témoin est une opération illicite si la loi de probabilité n'est pas connue.*

**Règle 6.** - *L'utilisation en aveugle de tests statistiques est formellement à proscrire. Il faut systématiquement s'assurer des conditions de validité du test.*

**Règle 7.** - *Toute étude statistique, et en particulier toute étude épidémiologique, dont les résultats sont basés sur des tests statistiques dont la validité n'a pas été vérifiée est absolument sans valeur.*

**Règle 8.** – *Toute étude statistique reposant sur un modèle choisi a priori est absolument sans valeur en ce qui concerne l'aide à la décision. Pour être utilisable dans l'aide à la décision, une étude statistique doit utiliser exclusivement des données brutes, sans aucune hypothèse sur les lois sous-jacentes.*

**Règle 9.** – *Il ne faut pas aborder une étude avec un présupposé idéologique quant au résultat. Il faut publier absolument tous les résultats, même ceux qui ne vont pas dans le sens que l'on espérait.*

## Table des matières

I.	Introduction.....	2
A.	La qualité d'une méthodologie.....	3
B.	L'absence de danger.....	4
II.	Remerciements.....	5
III.	Récapitulatif des règles de bonne pratique .....	6
	Chapitre I .....	9
	Les bonnes pratiques probabilistes en épidémiologie.....	9
A.	Le phénomène que l'on souhaite mettre en évidence doit être convenablement défini ...	9
B.	La population de référence doit être aussi vaste que possible.....	9
C.	Prise en compte de la mort naturelle .....	12
D.	Quelle question poser ?.....	13
E.	La présentation des résultats .....	13
F.	Utilisation des résultats du tableau.....	14
G.	Exploitation des résultats.....	14
H.	Espérance de vie .....	17
I.	Nombre de morts par tranche d'âge .....	17
J.	Facteurs externes.....	18
K.	L'effet du hasard .....	19
1.	Evaluations à probabilité fixée .....	19
2.	Evaluations à probabilité inconnue.....	21
L.	Difficultés non prises en compte par la présente analyse.....	21
M.	Méthodes probabilistes versus tests statistiques.....	22
N.	Modèles factices .....	24
	Chapitre II.....	26
	Méthodes probabilistes en pratique.....	26
	Références.....	28
	Annexe 1 .....	29
	Nombre de morts par an et probabilités de vie à la naissance.....	29
	Annexe 2 .....	32
	Utilisation inappropriée du modèle de Cox : .....	32
	un exemple simple.....	32
I.	Description de la population .....	32
II.	Utilisation du modèle de Cox.....	34
III.	Utilisation des probabilités conditionnelles .....	35

IV.	Comparaison des résultats des deux méthodes .....	36
V.	Autre remarque sur le modèle de Cox.....	36
	Annexe 3 .....	37
	Analyse critique de l'étude Autisme-Autoroutes .....	37
	Résumé .....	37
	1. Introduction.....	37
	2. Bien poser le problème.....	37
	3. Analyse critique des résultats .....	37
	4. Conclusion .....	39



# Chapitre I

## Les bonnes pratiques probabilistes en épidémiologie

Contrairement à ce que l'on croit souvent, les probabilités sont une science exacte, mais elles ont, comme toute science, un domaine d'application qu'il convient de respecter.

Une étude épidémiologique consiste généralement en la comparaison entre une "population-test" et une "population de référence", du point de vue de l'exposition à un risque. Ces "populations" peuvent être des zones géographiques, des tranches d'âge, des catégories socio-professionnelles, etc.

### *A. Le phénomène que l'on souhaite mettre en évidence doit être convenablement défini*

Le phénomène est en général caractérisé par un danger, par exemple un surcroît de mortalité, dû à telle maladie. Mais la population test et la population de référence dépendent du choix qui est fait. Voici trois exemples ; ces trois questions sont parfaitement légitimes, mais elles conduisent à des études distinctes :

*Première question : "les lignes HT sont-elles dangereuses pour la santé ?" (sans autre précision, sans savoir de quelle manière)*

Pour répondre à cette question, on comparera l'espérance de vie à la naissance des gens qui vivent à proximité des lignes et celle du pays tout entier.

*Seconde question : "favorisent-elles l'apparition de la maladie d'Alzheimer ?"*

Pour répondre à cette question, on comptera le nombre d'Alzheimer, pour 1 000 habitants, au voisinage des lignes, et on le comparera au nombre d'Alzheimer d'une population de référence de même âge. Il faudrait préciser une durée de référence : un an ? dix ans ?

*Troisième question : les champs magnétiques sont-ils dangereux pour la santé ?*

Pour répondre à cette question, on évaluera l'espérance de vie à la naissance des gens qui vivent en présence d'un fort champ magnétique (en particulier au voisinage proche d'une ligne HT de forte intensité) et on la comparera à l'espérance de vie dans l'ensemble de la population.

Comme on voit, les trois études sont différentes, et la population de référence ne sera pas la même.

### *B. La population de référence doit être aussi vaste que possible*

Supposons, comme c'est le cas ici, que l'on cherche à tester la dangerosité des lignes HT. On comparera la population vivant "près" des lignes HT à la population vivant "loin". Comme la population vivant près est minoritaire, il est légitime de prendre pour population de référence l'ensemble de la population du pays (ou de la région, ou du continent, etc.). On aura donc d'une part une "population test", qui est constituée de gens vivant près des lignes, et une "population de référence", qui est l'ensemble du pays.

Il n'est absolument pas légitime (comme le fait l'une des études) de prendre pour population de référence une population de même taille, mais située ailleurs, même si elle est extraite aléatoirement. En effet, la population test est en très petit nombre, et une extraction aléatoire peut donner des résultats faux. Une extraction aléatoire doit systématiquement être proscrite lorsque la loi du phénomène est inconnue, comme c'est le cas ici, même si la taille de l'échantillon est importante. Imaginons un explorateur qui veut s'enquérir des habitudes alimentaires des Chinois ; il interroge cent millions de personnes sur la côte et il aura toujours la même réponse : poisson.

Retenons cette règle :

**Règle 1.** – *La population de référence doit systématiquement être aussi vaste que possible. L'extraction aléatoire d'une population de référence représente une faute de logique, puisqu'on a extrait selon une loi de probabilité définie a priori (factice), alors que l'on ne connaît pas la vraie loi.*

A propos de cette règle, nous recevons le commentaire qui suit (fait à partir du document de travail du 09/06/2009) :

*Le fait que la population vivant près des lignes soit minoritaire n'a rien à voir – strictement aucun lien d'implication, contrairement à ce qui est écrit – avec la légitimité qu'il y aurait à prendre pour population de référence l'ensemble de la population du pays. La population est certes minoritaire mais les maladies (de cette population minoritaire) ne le sont peut-être pas !*

*Il y a ici à mon avis une confusion de domaine, confusion qui peut ne pas trop se remarquer dans le cas où ce que l'on recherche (ici une maladie) dans ladite population minoritaire est également minoritaire à l'intérieur de cette population.*

*La population test étant incluse dans la population totale, le problème est faussé d'entrée de jeu.*

*Pour être clair, un petit exemple chiffré : Imaginons un petit sous-groupe de personnes X représentant 1/1000 d'une population de 10 millions de personnes (donc 10.000 personnes X) mais ayant un taux d'incidence d'une maladie quelconque de 50% (donc 5000 cas de cette maladie – provoquée par ce que vous voulez, peu importe – chez les personnes X) alors que dans la population générale (population autre que les X) le taux soit de 0,1% (donc 9990 cas).*

*Moralité : les cas de maladie chez les X représentent plus de la moitié des cas totaux dans la population (hors X) et il serait, selon BB, (puisque les personnes X sont minoritaires dans la population)... légitime de prendre comme population de référence l'ensemble de la population, c'est-à-dire les 10 millions de personnes avec les... 14990 cas de maladie !*

Ce commentaire est très intéressant et mérite d'être analysé. L'auteur commet en effet plusieurs erreurs.

Tout d'abord, il n'y a évidemment rien qui interdise, sur le plan de la logique, de regarder une population de référence égale à la France entière et une population test réduite à Paris ; le fait que Paris soit en France n'invalide pas une étude. De même, on a parfaitement le droit de se demander si l'espérance de vie au sud de la Loire est supérieure ou non à celle de la France entière. On ne voit pas au nom de quel axiome universitaire les deux ensembles (référence et test) devraient être disjoints !

Que les maladies de la population test soient ou non minoritaires dans l'ensemble des maladies est absolument sans rapport avec la question. Dans l'exemple choisi par notre interlocuteur, la population totale est effectivement de 10 millions de personnes, avec 14 990 cas de maladies, et la population test de 10 000 personnes avec 5 000 malades ; la comparaison des quotients  $\frac{14\,990}{10\,000\,000}$  et  $\frac{5\,000}{10\,000}$  montre bien qu'il y a un problème dans la population test.

Notons  $N_{ref}, N_{test}$  les populations de référence et de test, et  $n_{ref}, n_{test}$  les nombres de malades. Bien entendu, si ces nombres sont connus avec exactitude, le problème ne se pose pas : dans la population "hors test" (complémentaire de la population test, par rapport à la population de référence), la population est  $N_{ref} - N_{test}$  et le nombre de cas est  $n_{ref} - n_{test}$ . On peut comparer la population test à la population de référence, ou au complémentaire de la population test : les deux sont légitimes et le passage de l'un à l'autre est immédiat.

Mais, en pratique, il y a des "incertitudes de frontière" : par exemple, pour Alzheimer, on n'est pas sûr d'avoir recensé correctement les décès vivant à proximité des lignes, tandis que, pour la population tout entière, l'incertitude est moins grande. A cause de ces "incertitudes de frontière", notre règle : "prendre une population de référence la plus large possible" est particulièrement nécessaire. En effet, si vous vous trompez de quelques unités pour les décès au sein de la population test, vous vous trompez d'autant, en sens contraire, dans la population "hors test" : l'erreur est en quelque sorte multipliée par deux. Pour bien faire comprendre ceci, prenons un exemple.

Admettons que la population test soit de 20 000 personnes, et la population hors test aussi (donc  $N_{ref} = 40\,000$ ). Nous avons un total  $n_{ref} = 50$  décès.

Admettons d'abord que 25 décès soient dans la population test, et donc 25 en dehors. Alors la probabilité que la zone test soit plus dangereuse que la zone de référence est évidemment 0.5.

Imaginons maintenant que, par suite des incertitudes de dénombrement, nous ayons attribué seulement 22 décès à la zone test. Nous comparons à la population de référence, et nous comparons le rapport  $\frac{22}{20\,000}$  au rapport  $\frac{50}{40\,000}$  ; la théorie générale (voir Appendice 2) montre alors que la probabilité que la zone test soit plus dangereuse que la référence est 0.32.

Comparons maintenant la zone test à son complémentaire, la zone hors test ; nous comparons alors le rapport  $\frac{22}{20\,000}$  au rapport  $\frac{28}{20\,000}$ , et la théorie générale montre que la probabilité que la première soit plus dangereuse que la seconde est 0.20 : le résultat est complètement différent.

Notre règle : "prendre une population de référence la plus large possible" répond donc à trois impératifs :

- C'est en général pour le pays tout entier que les chiffres sont connus ;
- Plus la population est large, et plus les conclusions sont stables ;
- Cela correspond à la véritable attente des usagers (qui se demandent par exemple : suis-je soumis à un danger si je suis au voisinage des lignes HT ? sous-entendu par rapport à un individu moyen).

### *C. Prise en compte de la mort naturelle*

Les épidémiologistes ont souvent tendance à l'oublier : les êtres humains finissent par mourir, aussi bien dans la population test que dans la population de référence. Par conséquent, la question : "combien de morts ?" a pour réponse : "tout le monde", dans les deux populations. On posera donc plutôt les questions : "de quoi", et "quand ?".

La question "de quoi ?" est naturelle : s'il apparaît qu'il y a un surcroît d'Alzheimer dans la population test, cela peut indiquer que cette population est soumise à une influence dangereuse. Il s'agit cependant d'une erreur de logique, comme nous allons le voir.

Dans notre étude pour le CEA (2007-2008), nous avons observé que le nombre de cancers en France augmentait globalement, mais diminuait pour chaque tranche d'âge, par exemple 0 – 80 ans (phénomène bien connu ; nous ne sommes pas les premiers à faire cette observation !). Ceci signifie que l'on vit de plus en plus vieux en France, et on finit par mourir d'un cancer alors que l'on mourait d'autre chose avant.

Prenons une zone dite "à risque", comme par exemple la région à proximité de lignes HT.

- Dire : "elle est dangereuse parce qu'il y a plus de morts" constitue une faute de logique : il faut au préalable avoir vérifié que la zone en question ne contenait pas, tout simplement, plus de vieux (ou moins de jeunes) que la population de référence.
- Dire "elle est dangereuse parce qu'il y a plus d'Alzheimer" constitue aussi une faute de logique, parce que si la proportion de vieux est plus élevée, il y aura mécaniquement plus d'Alzheimer, lignes HT ou pas.

**Règle 2.** - *Dans le cas de maladies liées à l'âge, analyser le nombre de morts ou de cas dans la zone test et dans la population de référence constitue une faute de logique, si l'on n'analyse pas en même temps la pyramide des âges de chaque zone.*

Sans aller jusqu'à l'analyse de toutes les tranches d'âge, il faudrait au moins vérifier que dans la population test et dans la population de référence la proportion des plus de 60 ans est la même. L'étude [Huss], dont nous parlons plus loin, commet cette faute de logique.

La question de la pyramide des âges, dans une zone donnée, n'est nullement une évidence. Les populations humaines se répartissent très diversement du point de vue de la pyramide des âges. Tout d'abord, d'un pays à l'autre (et même entre pays voisins, comme la France et l'Allemagne), il y a de fortes disparités dans les taux de naissance. A l'intérieur d'un même pays, il y a des régions plus jeunes et d'autres moins, en particulier selon le type d'emplois. Et surtout, localement, à l'intérieur d'une même ville, il y a de fortes différences : certains quartiers ont des équipements qui attirent les ménages ayant beaucoup d'enfants, ou l'inverse ; le montant des loyers, les moyens de transport, etc., sont autant de critères qui influent sur la diversité.

Ne mentionnons pas (simple question d'honnêteté intellectuelle !) le fait qu'une zone donnée peut précisément accueillir, de manière absolument factuelle, un surcroît de maladie, s'il s'y trouve précisément un hôpital, une maison de retraite, etc. L'étude [Huss] prend explicitement cette précaution.

#### *D. Quelle question poser ?*

La bonne question à poser, pour tester la dangerosité d'une zone, n'est pas "de quoi l'on meurt ?", mais "quand ?". Si je peux dire : l'espérance de vie des filles en France est 80 ans à la naissance, mais seulement 75 pour cette zone-là, je puis légitimement dire qu'il y a un problème. En fait, comme nous le verrons, le bon indicateur n'est pas l'espérance de vie (qui est trop globale, trop grossière), mais la probabilité de mourir à un âge donné.

La bonne question est celle de la probabilité, à la naissance, de vivre au moins 10, 20, 30,... années, comme nous allons maintenant l'expliquer, et toute autre présentation doit en définitive se ramener à celle-là.

#### *E. La présentation des résultats*

**Règle 3.** - *La présentation des résultats qui permet la comparaison entre la population test et la population de référence est nécessairement de la forme suivante :*

Tranche d'âge	population test	population de référence
$T_1$	$p_1$	$p'_1$
$T_2$	$p_2$	$p'_2$

$\vdots$	$\vdots$	$\vdots$
$T_K$	$p_K$	$p'_K$

Tableau 1 : la présentation des résultats

où  $T_1, T_2, \dots, T_K$  sont des tranches d'âge (par exemple : 0-10 ans, 10 – 20, ..., 110–120) et  $p_k$  la probabilité à la naissance, pour un membre de la population test, de mourir dans cette tranche-là. Par exemple,  $p_2$  est la probabilité qu'un nouveau-né de la population test ait une durée de vie entre 10 et 20 ans.

Les probabilités  $p'_k$  sont définies de manière identique, mais pour la population de référence.

Bien entendu,  $\sum_{k=1}^K p_k = \sum_{k=1}^K p'_k = 1$  : on finit par mourir un jour ou l'autre.

### F. Utilisation des résultats du tableau

Pour utiliser ces résultats, il faut tout d'abord passer aux cumulés (en terminologie probabiliste, cela s'appelle fonction de répartition), car la comparaison entre les  $p_k$  et les  $p'_k$  n'est pas possible directement.

Le cumul  $p_k + \dots + p_K$  représente, pour tout  $k$ , la probabilité de décéder au cours de l'une des tranches d'âge  $T_k, \dots, T_K$ , soit, en langage commun, la probabilité de dépasser la tranche  $k-1$  : dépasser un âge donné, et non plus mourir dans une tranche d'âge. On constitue donc le tableau suivant :

Tranche d'âge	population test	population de référence
$T_1$	$P_1$	$P'_1$
$T_2$	$P_2$	$P'_2$
$\vdots$	$\vdots$	$\vdots$
$T_K$	$P_K$	$P'_K$

Tableau 2 : les cumulés

où  $P_1 = p_1 + \dots + p_K$ ,  $P_2 = p_2 + \dots + p_K$ , ...,  $P_j = p_j + \dots + p_K$ , et de même pour les  $P'_j$ . Le cumul  $P_j$  s'entend donc comme la probabilité de dépasser une borne. Si la première tranche commence à la naissance, on a  $P_1 = 1$  et si  $K$  est la dernière tranche de vie possible,  $P_{K+1} = 0$ .

### G. Exploitation des résultats

On représente les deux fonctions de répartition sur un même graphique, et on compare. Voici quatre situations parmi toutes les situations possibles :

Cas 1 : la fonction de répartition  $F_1$  pour la population test est toujours au-dessus de la fonction  $F_2$  pour la population de référence

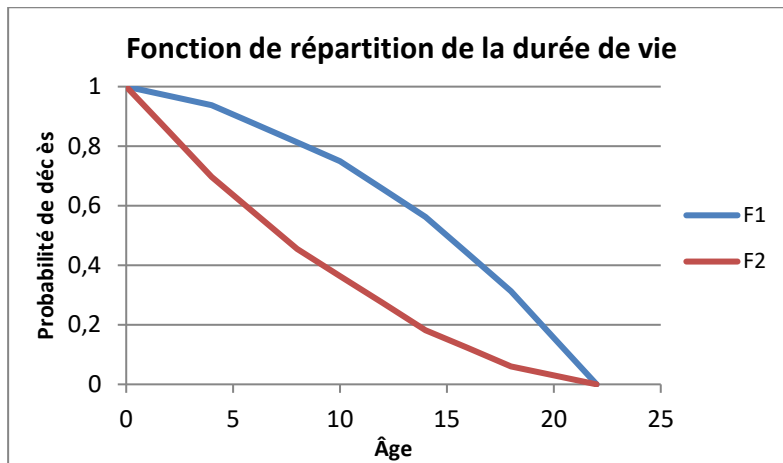


Figure 1 : Fonctions de répartition de la durée de vie

Cas 2 :  $F_1$  est toujours au dessous de  $F_2$

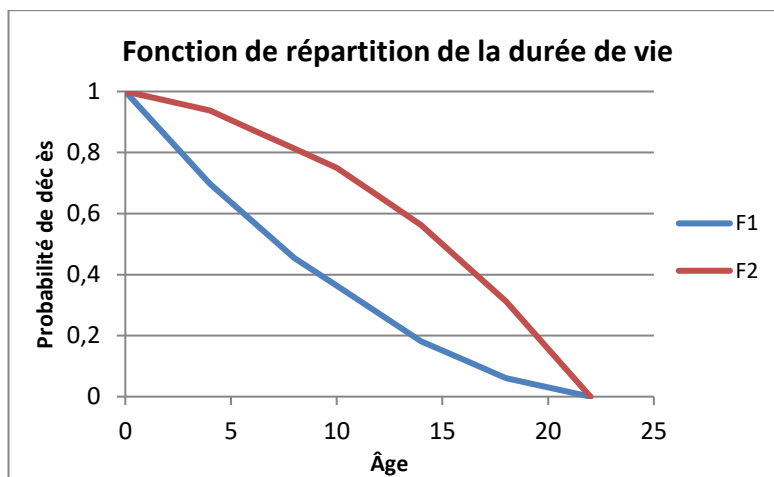


Figure 2 : Fonctions de répartition de la durée de vie

Cas 3 :  $F_1$  est d'abord au-dessus de  $F_2$ , puis au-dessous

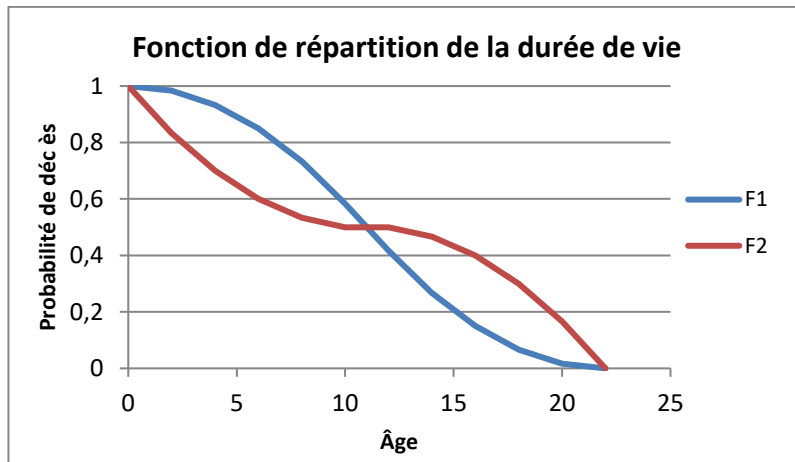


Figure 3 : Fonctions de répartition de la durée de vie

Cas 4 :  $F_1$  est d'abord au-dessous de  $F_2$ , puis au-dessus

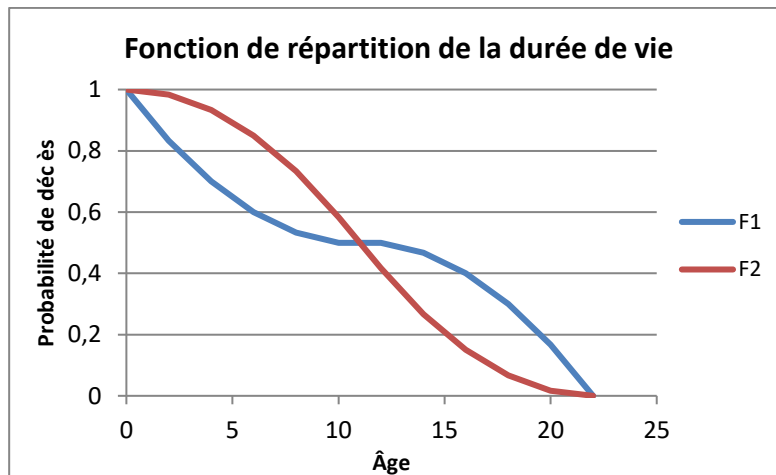


Figure 4 : Fonctions de répartition de la durée de vie

Dans le cas 1, la conclusion est claire : quel que soit l'âge  $k$ , on a moins de chances d'atteindre cet âge si l'on est dans la population test que dans la population de référence : la population test est soumise à un excès de mortalité.

Dans le cas 2, c'est l'inverse : quel que soit l'âge  $k$ , on a plus de chances de l'atteindre si on est dans la population test que dans la population de référence : la population test a une meilleure longévité.

Dans le cas 3, les choses sont moins simples. Les courbes se croisent en  $k_0$  ; pour les âges inférieurs, la population test est au-dessus, ce qui signifie qu'on a plus de chance de dépasser tout âge inférieur si l'on est dans la population test : la mortalité infantile y est plus faible. Par contre, c'est l'inverse pour les âges supérieurs à  $k_0$  : il y a moins de vieillards dans la population test que dans la population de référence.



Le cas 4 est l'opposé : la population test comprend moins de bambins (forte mortalité infantile) mais plus de vieillards que la population de référence.

Bien entendu, des cas beaucoup plus complexes peuvent se rencontrer : la présentation décrite plus haut permet de différencier les populations selon les classes d'âge.

Cette présentation est parfaitement correcte et simple à mettre en œuvre. La seule critique qu'on puisse lui faire est la suivante : elle procède par "tranches d'âge", ce qui n'est pas neutre. Si par exemple on définit une tranche 20 – 40 ans, on compte de la même manière une personne de 21 ans et une personne de 39, ce qui n'est pas forcément légitime.

### *H. Espérance de vie*

L'espérance de vie, souvent utilisée, est la moyenne des valeurs données au Tableau 1. On remplace chaque  $T_k$  par sa valeur centrale (le centre de la tranche), notée  $t_k$  et on calcule  $E = \sum_k p_k t_k$ . On procède de même pour la population de référence, avec  $E' = \sum_k p'_k t_k$  ; on peut alors comparer les espérances de vie (à la naissance) pour la population test et la population de référence : une différence significative pourra alerter. Mais nous recommandons de ne pas se limiter au calcul de l'espérance de vie, qui est un indicateur grossier : mettre en évidence les nombres du Tableau 1 est bien préférable, puisqu'alors on comprend les raisons de la différence (zone favorisant la mortalité infantile, ou l'inverse, etc.).

### *I. Nombre de morts par tranche d'âge*

Dans la pratique, déterminer la probabilité, à la naissance, de dépasser tel âge n'est pas facile, surtout pour une population de taille restreinte. On préfère donc compter le nombre de morts par tranche d'âge, ce qui est beaucoup plus facile, mais présente certains dangers.

On présente les résultats sous la forme suivante :

Tranche d'âge	population test	population de référence
$T_1$	$n_1$	$n'_1$
$T_2$	$n_2$	$n'_2$
$\vdots$	$\vdots$	$\vdots$
$T_K$	$n_K$	$n'_K$

*Tableau 3 : le nombre de morts par tranche d'âge*

où  $n_k$  est le nombre de morts dont l'âge est dans la tranche  $T_k$ , pour 1 000 habitants dans la population test (et de même pour la population de référence).

Cette phrase, souvent utilisée, n'est pas claire en pratique. Voyons ce qu'elle signifie. Nous prenons toute la population (mettons  $N$  personnes), nous prenons une année quelconque, et nous comptons combien de décès, cette année-là, se sont produits dans la tranche  $T_k$ , par exemple combien de personnes avaient, au moment de leur décès, entre 20 et 30 ans. Ensuite, ce nombre est rapporté à 1 000 personnes : on le divise par  $N$  et on le multiplie par 1 000.

Il y a une différence fondamentale avec la présentation en termes de probabilités de survie : alors que  $\sum_{k=1}^K p_k = 1$  (tout le monde finit par mourir), on n'a certainement pas  $\sum_{k=1}^K n_k = 1\,000$  (la population tout entière ne meurt pas au cours d'une année donnée).

Le passage d'une présentation à l'autre est détaillé à l'annexe 1. Il est correct, formellement, si la population est stationnaire, c'est-à-dire si les effectifs de chaque tranche d'âge ne changent pas d'une année sur l'autre. En pratique, cette assertion est fautive : la population vieillit, et il faudra faire des corrections (empiriques) pour passer des décès par tranche d'âge aux probabilités à la naissance.

Mais dans la mesure où ces corrections seront les mêmes pour la population test et la population de référence, nous considérons que la présentation par nombre de décès par tranche d'âge (tableau 3 ci-dessus) est un moyen correct pour comparer les deux populations. A condition bien sûr que le tableau soit complet : il ne faut pas se contenter du nombre de décès pour l'une des tranches d'âge. Et il ne faut pas se contenter du nombre de décès par tranche d'âge pour la population à risque : il le faut aussi pour la population de référence.

Récapitulons :

**Règle 4.** - *La présentation par nombre de décès par tranche d'âge permet une comparaison acceptable des deux populations, si elles sont stationnaires. Si elles ne le sont pas, il faut s'assurer que les corrections nécessaires sont les mêmes pour les deux. Le résultat final doit impérativement être présenté en termes de probabilités à la naissance.*

Une bonne manière de savoir si les populations sont stationnaires ou non, et de calculer les corrections nécessaires, consiste à établir le tableau 3 pour plusieurs années : si la population est stationnaire, les nombres  $n_k$  sont sensiblement constants d'une année sur l'autre.

**Remarque :** cas des données censurées

Il peut arriver que certaines données de mortalité soient "censurées" : on perd contact avec la personne suivie, et on sait seulement que sa durée de vie est supérieure ou égale à une valeur (on connaît  $P\{X \geq k\}$ , mais non  $P\{X = k\}$ , où  $X$  est la variable aléatoire indiquant la durée de vie). Les méthodes à utiliser en ce cas sont détaillées dans notre article [BB2].

## *J. Facteurs externes*

La comparaison de deux populations, si elle est faite correctement, peut évidemment montrer des probabilités de survie plus faibles chez l'une que chez l'autre ; encore faut-il savoir à quoi les attribuer. Il est possible, en particulier, que l'une des populations soit soumise à plusieurs risques simultanément ; savoir lequel est la cause principale de la moindre longévité n'est pas simple. En particulier, comme le fait remarquer André Aurengo [Aurengo], le rôle du tabac est essentiel dans certains cancers ; on ne peut mettre en évidence une autre cause (comme les radiations ionisantes) que si on a pris soin de relever l'exposition au tabac.

Il est possible aussi, comme le fait remarquer M. Barescut, qu'un biais existe, du fait de différences de catégories socio-professionnelles entre la population test et la population de référence. Typiquement, si une zone est considérée comme "à risque", ou bien souffrant d'une nuisance quelconque (réelle ou supposée), les loyers y sont plus bas ainsi que le prix des terrains. Les habitants seront alors souvent issus de catégories socio-professionnelles moins favorisées et certaines maladies pourront être plus répandues.

En tout état de cause, pour poursuivre l'étude, il faudra se ramener à des sous-populations homogènes vis-à-vis de ces facteurs externes (par exemple : même exposition au tabac dans les deux cas) ; voir chapitre II.

### *K. L'effet du hasard*

L'effet du simple hasard est bien connu des probabilistes ; il l'est manifestement beaucoup moins des épidémiologistes. Si l'on admet que le cancer est dû au simple hasard, il est normal que toutes les villes de 10 000 habitants n'aient pas le même nombre de cancers : nous allons voir en quelles proportions elles peuvent différer. Cette variabilité due au seul hasard doit être prise en compte : on ne peut affirmer qu'une ville est plus dangereuse qu'une autre (à cause d'un facteur spécifique) que si les différences sont supérieures à ce que le hasard seul donnerait.

#### **1. Evaluations à probabilité fixée**

##### **– Un cas d'école**

Commençons par un exemple d'école, pour faire comprendre les lois. Si je joue  $n = 10\,000$  fois à pile ou face (proba  $p = 1/2$ ), le nombre de "pile" ne sera pas exactement  $\frac{n}{2} = 5\,000$ . En général (95 fois sur cent), il sera compris dans l'intervalle  $I = [np - 2\sigma\sqrt{n}, np + 2\sigma\sqrt{n}]$ . Comme ici  $\sigma = \sqrt{p(1-p)} = \frac{1}{2}$  (il s'agit ici, bien sûr, de la variance du jeu de pile ou face), cet intervalle de confiance à 95 % est :

$$I = [5000 - 100, 5000 + 100] = [4900, 5100]$$

Que signifie "intervalle de confiance à 95 %" ? Cela signifie que si je répète 100 fois mon "expérience" (laquelle consiste à jouer à pile ou face 10 000 fois), 95 fois sur 100 l'intervalle ci-dessus sera respecté.

On trouvera la théorie détaillée dans le livre [BB1].

Prenons maintenant (arbitrairement) un intervalle plus petit, comme :

$$I' = \left[ np - \frac{1}{2} \sigma \sqrt{n}, np + \frac{1}{2} \sigma \sqrt{n} \right]$$

soit ici  $[5000 - 25, 5000 + 25]$  et demandons-nous quelle est la probabilité de tomber dedans. D'après le théorème central limite, elle vaut :

$$\int_{-1/2}^{1/2} \exp(-t^2 / 2) \frac{dt}{\sqrt{2\pi}} \approx 0.38$$

Autrement dit, si vous répétez 100 fois votre expérience consistant à jouer 10 000 fois, pour 72 d'entre elles vous devez vous attendre à diverger de plus de 25 par rapport à la valeur attendue 5000.

#### - Exemple en épidémiologie

Admettons ([Draper]) un chiffre précis pour  $p$  : le taux de leucémies chez l'enfant est 42 par million, par an. Cela nous donne  $p = 42 \times 10^{-6}$ . Pour une population totale de  $N = 400\,000$  personnes (population approximative à moins de 600 m des lignes, selon [Draper]), le nombre "attendu" est  $Np \approx 16.8$  et l'intervalle de confiance à 95 % est :

$$\left[ Np - 2\sqrt{Np(1-p)}, Np + 2\sqrt{Np(1-p)} \right] = [8, 25]$$

(dispersion de  $\pm 8.6$  autour de la valeur centrale).

Comme expliqué plus haut, si on prend l'intervalle plus petit :

$$\left[ Np - \frac{1}{2}\sqrt{Np(1-p)}, Np + \frac{1}{2}\sqrt{Np(1-p)} \right] = [14.7, 18.8]$$

on a 72 chances sur 100 de n'être pas dedans : la déviation due au seul hasard est supérieure à  $\pm 2$  autour de la valeur centrale attendue 16.8.

Autrement dit, dans le cadre présent (population de 400 000 personnes, risque de 42 par million et par an), seules des déviations supérieures à 8 par rapport à la valeur attendue doivent requérir attention ; des déviations de l'ordre de 2 sont normales et dues au seul hasard.

## 2. Evaluations à probabilité inconnue

Dans le cas du jeu de pile ou face, la valeur  $p = 1/2$  est claire, indiscutable. Mais en épidémiologie, l'évaluation de  $p$  (par exemple l'incidence annuelle de la maladie) est difficile en elle-même.

On peut montrer (énoncé dû à Laplace, voir Annexe 2) que la loi de probabilité de  $p$  est :

$$f(\lambda) = c\lambda^n(1-\lambda)^{N_{tot}-n}$$

où  $c$  est une constante de normalisation,  $N_{tot}$  la taille de la population et  $n$  le nombre d'accidents (ici de morts).

Il en résulte (voir l'article [BB3]) qu'une estimation du taux de risque est donnée par l'intervalle :

$$I_R = [p-\eta, p+\eta], \text{ avec } \eta = \sqrt{\frac{p(1-p)}{N_{tot}\varepsilon}}.$$

Dans le cas de l'étude [Draper],  $N_{tot} = 9.7$  millions, et  $\varepsilon = 0.05$  si nous voulons un intervalle à 95 %. La valeur de  $\eta$  calculée par la formule précédente est de  $9 \times 10^{-6}$  si l'on veut un encadrement à 95 %, et dans ces conditions  $p$  peut être n'importe où entre  $42-9=33$  et  $42+9=51$  par million. La valeur basse conduit à l'encadrement  $[5, 20]$  et la valeur haute à l'encadrement  $[11, 29]$ , si bien que l'encadrement final sera  $[5, 29]$ , ce qui est très large.

La théorie développée dans le livre [BB1], chapitre 14, permet aussi la comparaison des taux de risque entre deux situations : sachant qu'une zone 1, avec population  $N_1$ , a enregistré  $n_1$  décès par an et qu'une zone 2, avec population  $N_2$ , a enregistré  $n_2$  décès par an, quelle est la probabilité que la zone 1 soit "plus dangereuse" que la zone 2 ? Voir Annexe 2.

Bien entendu, le mot "plus dangereux" ne fait pas référence à une cause précise : il signifie simplement, comme expliqué plus haut, que l'on y meurt plus souvent, et ce peut être de mort naturelle !

La conclusion générale de ce paragraphe est qu'avec un taux de risque de l'ordre de 40 par million, une population de 400 000 personnes est trop petite pour que l'on voie quoi que ce soit.

### *L. Difficultés non prises en compte par la présente analyse*

La comparaison de deux populations, du point de vue épidémiologique, comporte bien d'autres difficultés que celles que nous avons relevées :

- Une population n'est pas un ensemble clos : il y a des entrants et des sortants (migrations) ;
- Il est difficile de chiffrer correctement l'exposition à certains dangers. Par exemple, en ce qui concerne les lignes HT, le lieu de résidence est une chose, le temps que l'on y passe en est une autre.
- L'origine des décès n'est pas souvent correctement recensée ; en particulier, concernant la maladie d'Alzheimer, il semble que seulement la moitié des cas le soient. Cette affirmation se trouve à la page 28 dans la synthèse d'une expertise collective de l'INSERM ([http://ist.inserm.fr/basisrapports/alzheimer/alzheimer\\_synthese.pdf](http://ist.inserm.fr/basisrapports/alzheimer/alzheimer_synthese.pdf)). L'extrait est le suivant :

*La maladie d'Alzheimer demeure sous-diagnostiquée en France. Selon les données épidémiologiques disponibles, la moitié des patients est aujourd'hui identifiée. Cette insuffisance de diagnostic est liée à plusieurs facteurs, en particulier au fait que nombre de médecins ne sont pas encore convaincus de l'intérêt d'une médicalisation de la maladie d'Alzheimer ni de sa prise en charge thérapeutique. Ce sous-diagnostic est principalement observé chez les patients âgés, mais concerne également les sujets les plus jeunes. Quand le diagnostic est porté, il l'est souvent avec retard. C'est ainsi que le diagnostic de maladie d'Alzheimer n'est aujourd'hui porté qu'au stade de démence avérée.*

### *M. Méthodes probabilistes versus tests statistiques*

La présentation que nous avons donnée plus haut, sous forme de tableaux, relève des probabilités : nous avons construit, séparément pour la population test et la population de référence, ce qu'on appelle un histogramme, puis une fonction de répartition (voir par exemple [BB1]). Cette façon de procéder est simple à mettre en œuvre et ne fait appel à aucune hypothèse complémentaire, à ceci près que la taille des tranches est arbitraire, comme nous l'avons déjà dit (mais on peut la faire varier, si on dispose de données en nombre suffisant).

Les méthodes à base de tests statistiques sont, au contraire, à prendre avec prudence. La statistique est une branche des probabilités, qui concerne les situations où la loi est connue et où l'on dispose d'un échantillon suffisant : aucune de ces deux conditions n'est réunie ici.

Par exemple, on peut, pour anticiper les résultats des élections présidentielles, réaliser un sondage auprès d'un panel bien choisi (par tranche d'âge, par catégorie socio-professionnelle, par région, etc.). Mais la constitution de ce panel a pris des années d'études : il faut connaître la distribution de probabilité de chacun des votes dans chacune des catégories. Nous-mêmes avons rencontré cette difficulté pour constituer un panel de consommateurs, pour Veolia Environnement, Région Ouest : il s'agissait d'anticiper les consommations d'eau potable. Il nous a fallu trois ans pour mettre au point un panel satisfaisant : les extractions aléatoires dans la base de données ne permettaient d'obtenir que des résultats très médiocres.

**Règle 5.** - *La création d'un panel-témoin est une opération illicite si la loi de probabilité n'est pas connue.*

Venons-en maintenant aux tests statistiques. Un test est une opération (souvent mécanique, c'est-à-dire effectuée par l'ordinateur) qui permet de répondre à une question, du type : deux quantités sont-elles significativement différentes ?

Les tests sont généralement basés sur le Théorème Central Limite (qui évidemment est correct !) qui dit la chose suivante : soit  $X_1, X_2, \dots$  une suite de variables aléatoires, indépendantes et de même loi, d'espérance  $m$  et d'écart-type  $\sigma$  ; posons :

$$Y_n = \frac{1}{n} \sum_{j=1}^n X_j .$$

Alors la variable "réduite" :

$$Z_n = \frac{Y_n - m}{\sigma / \sqrt{n}}$$

se comporte asymptotiquement (lorsque  $n \rightarrow +\infty$ ) comme une variable gaussienne, d'espérance nulle et d'écart-type 1.

Ce théorème, pour être applicable, requiert que les variables soient indépendantes et de même loi. Et en sortie, il ne donne qu'une indication asymptotique, valable pour  $n$  grand (sans préciser à partir de quand). On trouvera dans [BB1] des exemples d'utilisation impropre de ce théorème.

A partir du Théorème Central Limite, on trouve quantité de tests, destinés par exemple à comparer la moyenne d'une population à une autre, vérifier une linéarité, évaluer une variance, etc. Ces tests sont en général assortis d'un "niveau de confiance", établi comme suit : après modification des variables, on se retrouve avec une gaussienne, dont les propriétés sont supposées connues (par exemple centrée réduite). On dispose par ailleurs d'un nombre, associé aux résultats de l'expérience, et on vérifie si, oui ou non, le nombre tombe dans l'intervalle de confiance pour la gaussienne. Par exemple, à 95 %, l'intervalle  $[-2, 2]$  est approximativement un intervalle de confiance pour une gaussienne centrée réduite, par conséquent si le nombre est  $-1.32$  on répond "oui" et s'il est  $+2.01$  on répond "non".

Les tests statistiques sont si nombreux que l'on peut toujours en trouver un qui répond "oui" à la question posée, quelle que soit la question. Comme disait Laurent Schwartz : "Lorsqu'on veut démontrer quelque chose, on y arrive toujours, même si c'est faux."

**Règle 6.** - *L'utilisation en aveugle de tests statistiques est formellement à proscrire. Il faut systématiquement s'assurer des conditions de validité du test.*

En particulier, la notion de "taux de confiance" associé à un test, souvent utilisée, est absolument trompeuse : elle n'a de sens qu'à l'intérieur du modèle que l'on a accepté ; si la variable est gaussienne, voici l'intervalle où elle doit se trouver 95 fois sur 100. Mais rien ne dit que la variable soit réellement gaussienne !

**Règle 7.** - *Toute étude statistique, et en particulier toute étude épidémiologique, dont les résultats sont basés sur des tests statistiques dont la validité n'a pas été vérifiée est absolument sans valeur.*

Cette remarque fort simple a été faite par M. Marc Lavielle à propos des études concernant les OGM : il a observé que les études faites par les deux "camps" étaient sans valeur, car reposant toutes sur des tests statistiques factices ("Le Monde", 12.05.09). En 2007-2008, lors de notre étude pour le CEA concernant les dangers associés aux faibles doses de radiations ionisantes, nous étions parvenus aux mêmes conclusions.

### *N. Modèles factices*

Il se peut aussi qu'un auteur n'utilise pas un test, mais un modèle, c'est-à-dire une représentation de la réalité, et ce modèle peut être trompeur : il ne correspond pas à la réalité.

C'est le cas ici du "modèle de Cox", très répandu en épidémiologie, et utilisé par [Huss]. Le modèle de Cox [Cox] consiste en la représentation suivante :

On dispose d'une fonction du temps (mettons ici de l'âge), notée  $f_0(k)$  ; elle représentera par exemple le "risque instantané de décès" à l'âge  $k$ , dans une population de référence. Ce risque instantané de décès se définit comme la probabilité de mourir à l'âge  $k$ , sachant que l'on a dépassé  $k-1$  ; d'autres formulations sont possibles.

On cherche à étudier une population test, et on fait l'hypothèse que, pour cette population-là, le risque instantané sera donné par une formule du type :

$$f_1(k) = f_0(k) e^{\beta \cdot Z} \quad (1)$$

où  $\beta \cdot Z = \beta_1 Z_1 + \dots + \beta_n Z_n$  contient tous les paramètres que l'on cherche à prendre en considération (par exemple : distance aux lignes électriques, etc.).

Mais la formule (1) comporte une hypothèse très forte, à savoir que le quotient  $\frac{f_0(k)}{f_1(k)}$  est constant au cours du temps (puisque le terme  $\exp(\beta \cdot Z)$  ne contient pas  $k$ ). Si cette hypothèse est réalisée, Cox indique comment calculer les coefficients  $\beta$ . Mais il faudrait s'assurer de manière très stricte que c'est le cas, et pour cela présenter en un tableau les nombres  $f_0(k)$  et les nombres  $f_1(k)$  et vérifier qu'ils sont bien proportionnels (un simple calcul du coefficient de corrélation suffirait ici). Mais cette vérification n'est jamais faite. Le danger provient du fait que les logiciels permettent dans tous les cas le calcul des coefficients  $\beta$ , même lorsque l'hypothèse de linéarité n'est pas satisfaite : il n'y a pas de mise en garde. Nous donnons en Annexe 3 un exemple simple, tout à fait explicite, où les hypothèses du modèle ne sont pas satisfaites ; le logiciel ne le détecte pas et donne une conclusion fausse !



De manière générale, beaucoup d'études reposent sur un modèle choisi a priori : par exemple on décide que le phénomène que l'on cherche à étudier suit une loi de Poisson, ou une loi exponentielle, une loi de Gumbel, etc. (voir en particulier le document [IRSN]). Mais toutes ces lois sont purement académiques. Un phénomène naturel ne suit jamais une loi de Poisson (en 2007, nous avons réalisé pour le CEA une analyse critique des méthodes statistiques en sismologie : nous avons montré que le décalage observé entre les modèles et la réalité provenait précisément d'une hypothèse factice, selon laquelle l'apparition des séismes suivait une loi de Poisson).

**Règle 8.** – *Toute étude statistique reposant sur un modèle choisi a priori est absolument sans valeur en ce qui concerne l'aide à la décision. Pour être utilisable dans l'aide à la décision, une étude statistique doit utiliser exclusivement des données brutes, sans aucune hypothèse sur les lois sous-jacentes.*

Bien entendu, il reste tout à fait licite, dans un but d'investigation, de faire toutes les hypothèses que l'on voudra ; notre règle ne porte que sur les études supposées aider à la décision.

Une règle absolue, qui relève de la simple honnêteté intellectuelle, est la suivante :

**Règle 9.** – *Il ne faut pas aborder une étude avec un présupposé idéologique quant au résultat. Il faut publier absolument tous les résultats, même ceux qui ne vont pas dans le sens que l'on espérait.*

La partie statistique d'une étude devrait être confiée à des statisticiens, compétents évidemment, mais surtout non impliqués dans le résultat. Il faudrait avoir le courage d'anonymiser les données (par exemple parler de maladie sans dire laquelle, parler de zone sans dire laquelle, etc.) de telle sorte que le traitement statistique soit absolument honnête.

Comme le fait remarquer M. Barescut, on peut faire varier les tests, varier les questions, déplacer la limite des zones, etc. : tout ceci est licite à condition de le dire ! Si on a conduit vingt tests différents, dont 19 n'ont rien révélé d'anormal et un seul semble indiquer une déviation par rapport à la normale, il faut avoir le courage de mentionner l'ensemble, et ne pas se contenter de montrer celui qui appuie certaines thèses.

## Chapitre II

### Méthodes probabilistes en pratique

Nous présentons la mise en pratique. Comme on le constate, les outils mathématiques sont extrêmement simples et bien connus ; les difficultés viennent de la définition des risques, des données, etc.

Typiquement, on dispose d'une population test (taille  $N_{test}$ ) et d'une population de référence (taille  $N_{ref}$ ) ; dans la première on observe  $n_{test}$  cas d'un "aléa" quelconque (maladie, accident, etc.) et dans la seconde  $n_{ref}$  cas de ce même aléa. Peu importe que ce soit dans l'absolu, par seconde, par an, ou ce que l'on voudra (mais les unités doivent être les mêmes pour les deux, bien sûr !).

On forme tout d'abord les deux quotients :

$$q_{test} = \frac{n_{test}}{N_{test}} \text{ et } q_{ref} = \frac{n_{ref}}{N_{ref}} \quad (1)$$

#### Remarque

Selon la théorie générale (voir Annexe), les quotients "corrects" sont en fait :

$$q_{test} = \frac{n_{test} + 1}{N_{test} + 2} \text{ et } q_{ref} = \frac{n_{ref} + 1}{N_{ref} + 2} \quad (2)$$

Dans la pratique, cela ne fait aucune différence, sauf si les nombres  $n_{test}$  et/ou  $n_{ref}$  sont très petits (quelques unités). Le lecteur voudra bien se souvenir que, en ce cas, les rapports (2) doivent être utilisés.

On regarde si :

$$q_{test} > q_{ref}$$

Si ce n'est pas le cas, la conclusion est claire : il n'y a rien à voir, et il faut avoir le courage de le dire.

Plaçons-nous maintenant dans le cas où l'on a effectivement  $q_{test} > q_{ref}$  ; alors il y a effectivement quelque chose à voir ! On peut déjà (voir Annexe 2) calculer la probabilité que la zone test soit plus dangereuse que la zone de référence, à partir des quatre nombres  $N_{test}$ ,  $N_{ref}$ ,  $n_{test}$ ,  $n_{ref}$ . Si cette probabilité est élevée (par exemple  $\geq 0.75$ ), cela mérite assurément d'être signalé.

Maintenant, on va rechercher les causes de cette bizarrerie. Pour cela, il faut éliminer les causes naturelles et certaines causes artificielles. Tout ceci se fait au moyen de réductions successives de la population test et de la population de référence.

Par exemple, s'il s'agit d'une maladie (comme Alzheimer) qui frappe surtout les vieux, on s'efforcera de réduire les deux populations pour qu'elles aient la même pyramide des âges.

S'il s'avère que le poids est un facteur influent, on s'efforcera de travailler sur des populations homogènes de ce point de vue (par exemple, pour les deux, la tranche 70-80 kg, ou, pour les deux, la tranche 100-110, etc.).

S'il s'avère que le tabac joue un rôle, on s'efforcera de travailler sur des populations ayant la même exposition : soit qui ne fument pas (des deux côtés), soit qui fument de la même façon des deux côtés (ceci est évidemment très difficile à définir et à mesurer).

Enfin, il ne faut surtout pas oublier que, à la fin, le résultat doit être donné en termes d'espérance de vie : pas forcément à la naissance, mais au-delà d'un âge donné. Par exemple, un résultat du type suivant :

*Une personne de 50 ans (avec telles caractéristiques de poids, d'exposition au tabac, etc.) a une espérance de vie de 20 ans en général, mais seulement de 16 ans au voisinage des lignes...*

montrerait à l'évidence un danger au voisinage des lignes.

Cette identification des populations "à risque", par restriction successive, est extrêmement intéressante en soi et devrait être pratiquée systématiquement. Pour l'action des médicaments, en particulier, les laboratoires pharmaceutiques se contentent d'identification grossière des populations susceptibles de bénéficier des effets, et ne savent pas correctement identifier des sous-populations spécifiques, susceptibles de ressentir des effets secondaires.

Si l'on veut aller plus loin, et identifier la cause (et pas seulement un effet statistique), il faut s'appuyer sur la physique du phénomène. Pour les lignes HT, une étude purement statistique (comme nous venons d'expliquer) peut mettre en évidence un surcroît de mortalité au voisinage des lignes, mais si l'on veut pouvoir dire "ceci est lié au champ magnétique", alors il faut savoir que celui-ci est lié à l'intensité du courant (voir Annexe 4). Dans ces conditions, il faut se renseigner sur l'intensité des lignes, et constater que, pour une même distance, il y a plus de mortalité au voisinage des lignes à forte intensité qu'au voisinage des lignes à faible intensité. Ceci ne "prouvera" pas que le champ magnétique est responsable (bien d'autres phénomènes peuvent être liés à l'intensité du courant), mais montrera au moins que l'intensité joue un rôle.

## Références

[Aurengo] André Aurengo : L'épidémiologie environnementale est-elle encore une science? Journée RNI de la SFRP, LaTronche, 7 octobre 2008.

[BB1] Bernard Beuzamy : Méthodes Probabilistes pour l'étude des phénomènes réels. Ouvrage édité et commercialisé par la *Société de Calcul Mathématique SA*, ISBN 2-9521458-0-6. Mars 2004.

[BB2] Bernard Beuzamy : A probabilistic approach for censored data, 2009 (disponible sur le site web de la SCM, [www.scmsa.com](http://www.scmsa.com)).

[BB3] Beuzamy, Bernard : The information associated with a sample, May 2009 (disponible sur le site web de la SCM).

[Cox] D. R. Cox : Regression Models and Life-Tables, *Journal of the Royal Statistical Society. Series B (Methodological)*, Vol. 34, No. 2. (1972), pp. 187-220.

[Dreyfus] Arrêt de la Cour de cassation du 12 juillet 1906, Affaire Dreyfus, Présidence de M. Ballot-Beaupré, Premier président.

[INSERM] " Maladie d'Alzheimer : enjeux scientifiques, médicaux et sociétaux". Les éditions de l'Inserm, 2007. Voir : [http://ist.inserm.fr/basisrapports/alzheimer/alzheimer\\_synthese.pdf](http://ist.inserm.fr/basisrapports/alzheimer/alzheimer_synthese.pdf).

[IRSN] Les études épidémiologiques des leucémies autour des installations nucléaires chez l'enfant et le jeune adulte : revue critique. Rapport DRPH/SRBE n° 2008-001.

[Poincaré ] Examen critique des divers systèmes ou études graphologiques auxquels a donné lieu le bordereau. Rapport de MM. Darboux, Appell et Poincaré, 1904.

## Annexe 1

### Nombre de morts par an et probabilités de vie à la naissance

Dans ce paragraphe, nous faisons le lien entre les deux concepts suivants :

- La probabilité à la naissance, pour une personne, de décéder dans sa  $k$ -ème année ;
- Le nombre de décès pour 1 000 habitants, dans une tranche d'âge donnée.

On suppose la population stationnaire. Soit  $B$  (birth) le nombre de naissances par an. Les naissances sont comptabilisées au 1<sup>er</sup> janvier et les décès sont comptabilisés au 31 décembre suivant.

On introduit :

$p_k$ ,  $k = 1, 2, \dots, K$  : probabilité pour une personne de décéder au cours de sa  $k$ -ème année ;

$n_k$  : nombre de décès dans la  $k$ -ème tranche d'âge, pour 1000 habitants.

Ces deux concepts sont liés par la relation suivante :

**Proposition.** – Pour tout  $k = 1, 2, \dots, K$ ,

$$n_k = \frac{1000 p_k}{\sum_{j \geq 1} (1 - p_1) \dots (1 - p_j)}$$

et inversement :

$$p_k = \frac{n_k}{\sum_{j=1}^K n_j}$$

**Démonstration.** - Plaçons-nous au 31 décembre, minuit. Le nombre de décès de personnes âgées d'un an est  $p_1 B$ . Il nous reste donc  $(1 - p_1) B$  personnes âgées d'un an. C'était déjà le cas au 31 décembre précédent (hypothèse de stationnarité) et, pendant l'année,  $p_2 B$  parmi les personnes de deux ans sont mortes. Il nous reste donc  $(1 - p_1)(1 - p_2) B$  personnes âgées de deux ans.

Réitérant ce raisonnement, nous constatons que, au 31 décembre minuit, nous avons  $v_k = (1 - p_1) \dots (1 - p_k) B$  personnes âgées de  $k$  années,  $k = 1, 2, \dots, K$ .

La population totale au 31 décembre minuit est donc :

$$N_{tot} = \sum_{k \geq 1} v_k = \sum_{k \geq 1} (1-p_1) \cdots (1-p_k) B \quad (1)$$

Si  $n_k$  est le nombre de décès de personnes âgées de  $k$  années, pour 1 000 personnes, le nombre de décès dans cette tranche d'âge, parmi toute la population, sera :

$$n'_k = \frac{n_k N_{tot}}{1000} \quad (2)$$

mais ceci, par définition, est égal à  $p_k B$ . Nous avons donc :

$$n_k = \frac{1000 p_k B}{N_{tot}} \quad (3)$$

et ceci prouve la première partie de la proposition.

Inversement, on peut calculer les  $p_k$  en fonction des  $n_k$ . Posons :

$$C = \sum_{k=1}^K (1-p_1) \cdots (1-p_k) \quad (4)$$

On a d'après (1) :

$$N_{tot} = CB \quad (5)$$

et :

$$n_k = \frac{1000 p_k}{C}, \quad k = 1, \dots, K \quad (6)$$

et donc :

$$\sum_{k=1}^K n_k = \frac{1000}{C} \quad (7)$$

D'où :

$$C = \frac{1000}{\sum_{k=1}^K n_k} \quad (8)$$

et :

$$p_k = \frac{n_k C}{1000} \quad (9)$$

et finalement :

$$p_k = \frac{n_k}{\sum_{j=1}^K n_j} \quad (10)$$

comme annoncé.

Il résulte de (5) et (8) que :

$$\sum_{k=1}^K n_k = \frac{1000B}{N_{tot}}.$$

## Annexe 2

### Utilisation inappropriée du modèle de Cox : un exemple simple

#### I. Description de la population

Prenons deux populations, chacune de 60 personnes, atteintes d'une même maladie et soumises à des traitements différents A et B. Chaque mois, des individus décèdent dans chacune des populations. Après 110 mois, il n'y a plus d'individus en vie.

Durée de traitement (en mois)	Nombre de décès parmi la population qui suit le traitement A	Nombre de décès parmi la population qui suit le traitement B
entre 0 et 10 mois	1	10
entre 10 et 20 mois	3	8
entre 20 et 30 mois	5	6
entre 30 et 40 mois	7	4
entre 40 et 50 mois	9	2
entre 50 et 60 mois	10	0
entre 60 et 70 mois	9	2
entre 70 et 80 mois	7	4
entre 80 et 90 mois	5	6
entre 90 et 100 mois	3	8
entre 100 et 110 mois	1	10

Tableau 1 : Nombre de décès, pour les personnes ayant suivi les traitements A ou B par intervalle de temps

La figure ci-dessous représente le nombre de décès par population en fonction du nombre de mois :



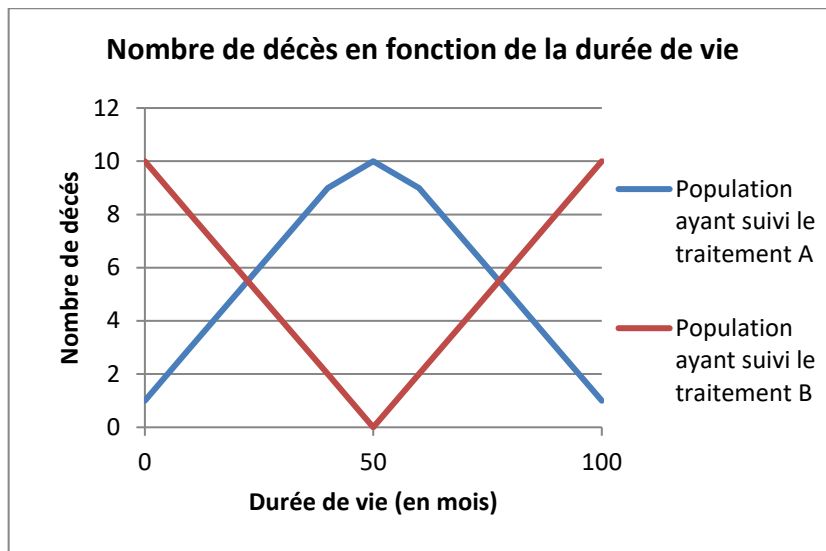


Figure 2 : Loi de probabilité des décès pour la population ayant suivi le traitement A

Les deux figures ci-dessous illustrent les lois de probabilité correspondantes.

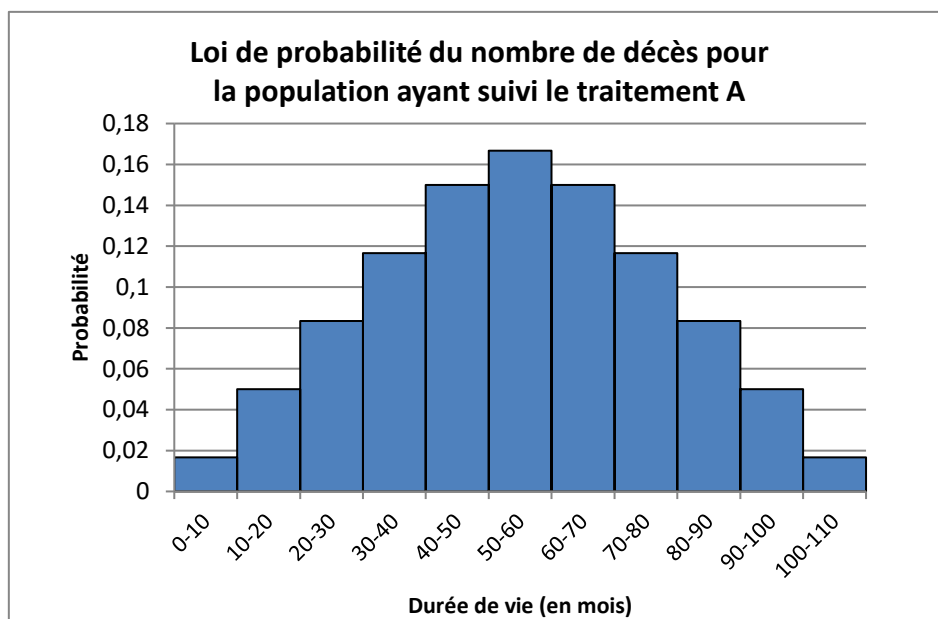


Figure 3 : Loi de probabilité des décès pour la population ayant suivi le traitement A

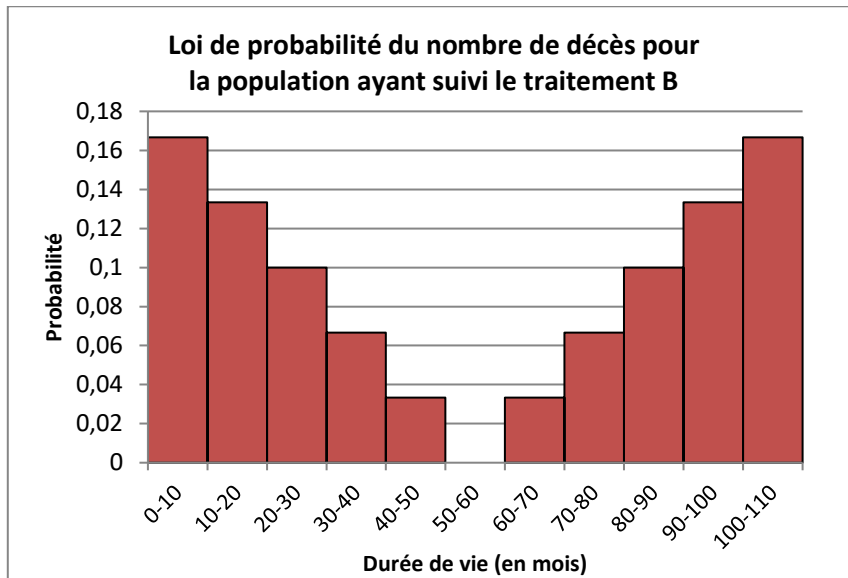


Figure 4 : Loi de probabilité des décès pour la population ayant suivi le traitement B

## II. Utilisation du modèle de Cox

On regarde s'il existe une influence du type de traitement sur la durée de vie des individus. Pour cela, on regarde l'influence du type de traitement B par rapport au type de traitement A. Ainsi, les résultats fournis par le modèle correspondent au traitement B.

On utilise le logiciel R, qui est un langage de programmation et un environnement mathématique utilisé pour le traitement de données et l'analyse statistique. Il permet notamment de simuler le modèle de Cox.

On fournit en entrée du logiciel trois vecteurs de taille 120 (une valeur par individu) :

- La durée de vie : 0, 0 ...10, 10, 10...20, 20, 20... 100, 100, 100 ;
- Le type de traitement suivi par l'individu : on affecte 1 si l'individu a suivi le traitement B et 0 si l'individu a suivi le traitement A ;
- L'indicateur de décès : on affecte 1 à un individu mort et 0 à un individu perdu de vue. Dans notre cas, tous les individus sont morts.

En appliquant le modèle de Cox aux données, le logiciel R donne les résultats suivants :

$e^{\beta}$	Intervalle de confiance	Degré de signification du test
0.66	[0,44 ; 0,96]	0.033 (< 0.05)

Tableau 5 : résultats

Le coefficient  $e^\beta$  et son intervalle de confiance sont strictement inférieurs à 1. De plus, le degré de signification du test est bien inférieur à 5%. Ainsi, le modèle de Cox conclut que le traitement  $B$  a une influence néfaste certaine sur la durée de vie et que, inversement, le traitement  $A$  a une influence bénéfique sur la durée de vie : mais ceci n'est pas correct.

### III. Utilisation des probabilités conditionnelles

Pour évaluer l'impact d'un traitement sur la durée de survie d'un individu, nous utilisons une méthode probabiliste. Cette méthode consiste à tracer la fonction de répartition de la durée de survie dans deux cas de figure : pour la population ayant suivi le traitement  $A$ , et pour la population ayant suivi le traitement  $B$ .

La durée de survie est découpée en intervalles. Nous déterminons l'effectif cumulé de chaque intervalle, c'est-à-dire le nombre d'individus dont la durée de survie est supérieure à chaque borne.

En divisant l'effectif cumulé d'un intervalle par l'effectif du cas de figure (traitement  $A$  ou traitement  $B$ ), nous obtenons le pourcentage d'individus dont la durée de vie dépasse le seuil fixé.

Les courbes ci-dessous sont obtenues en traçant les pourcentages correspondant à chaque intervalle en fonction du type de traitement.

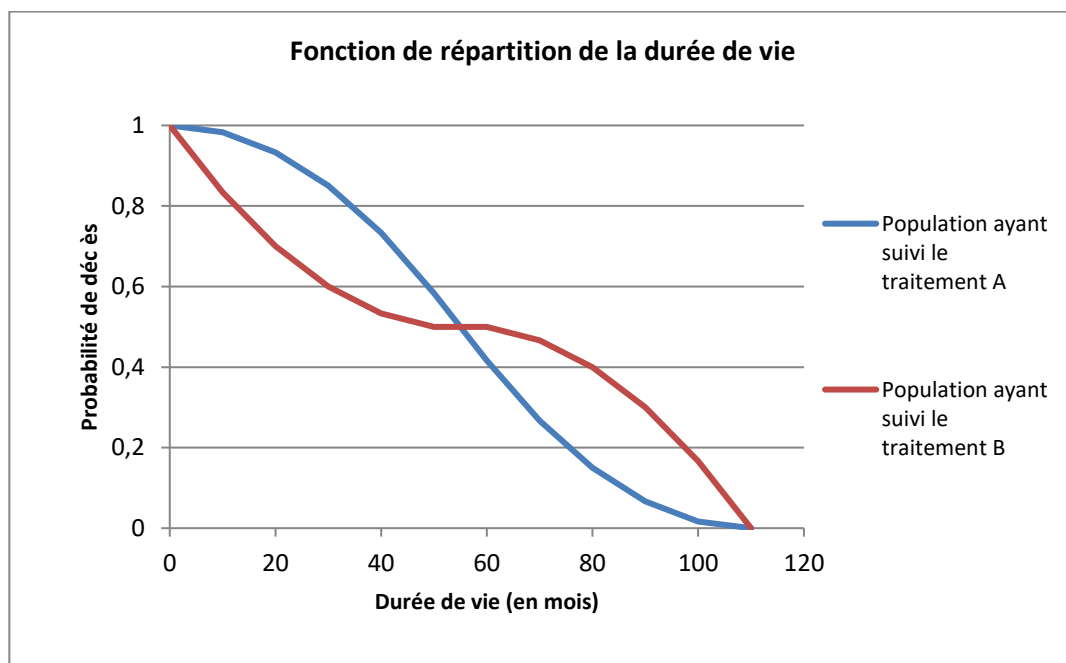


Figure 6 : Fonctions de répartition de la durée de survie des individus sachant qu'ils ont une fonction rénale normale ou sachant qu'ils ont une fonction rénale anormale

La courbe rouge correspond à la fonction de répartition de la durée de vie pour les individus qui ont suivi le traitement  $B$  ; la courbe bleue correspond à la fonction de répartition de la durée de vie pour les individus qui ont suivi le traitement  $A$ .

Considérons une durée de vie de 20 mois, le pourcentage associé à la courbe rouge est 70 %, le pourcentage associé à la courbe bleue est 96 %. Ceci signifie que 96 % des individus ayant suivi le traitement *A* vivent plus de 20 mois, alors que seulement 70 % des individus ayant suivi le traitement *B* dépassent cette durée de vie.

Considérons maintenant une durée de vie de 80 mois, le pourcentage associé à la courbe rouge est 40 %, le pourcentage associé à la courbe bleue est 12 %. Ceci signifie que 12 % des individus ayant suivi le traitement *A* vivent plus de 80 mois, alors que 40 % des individus ayant suivi le traitement *B* dépassent cette durée de vie.

Ainsi, nous observons deux tendances :

- Le traitement *A* a un effet protecteur dans un premier temps, puis il a un effet néfaste dans un second temps ;
- Le traitement *B* a un effet néfaste dans un premier temps, puis il a un effet protecteur dans un second temps ;

#### **IV. Comparaison des résultats des deux méthodes**

Sur cet exemple, les résultats des deux méthodes sont différents : la méthode des probabilités conditionnelles montre qu'il y a deux situations distinctes, que le modèle de Cox n'identifie pas.

#### **V. Autre remarque sur le modèle de Cox**

Les résultats du modèle de Cox dépendent de l'échelle de temps choisie. Dans l'exemple développé ci-dessus, les données sont exprimées en mois : 0, 10, 20..., 110, 120 et le modèle de Cox conclut à une influence néfaste du traitement *B*. Si on prend les mêmes données en changeant l'échelle de temps, par exemple en prenant 0, 1, 2..., 11, 12, le modèle de Cox ne conclut pas.

Les résultats sont donc différents si on exprime les données en jour, en mois, en années.

En revanche, dans notre modèle utilisant les lois de probabilités conditionnelles, les résultats sont indépendants de l'échelle de temps.

## Annexe 3

### Analyse critique de l'étude Autisme-Autoroutes

*Residential Proximity to Freeways and Autism in the CHARGE Study*

*by Heather E. Volk, Irva Hertz-Picciotto, Lora Delwiche, Fred Lurmann, and Rob McConnell*

*Environmental Health Perspectives • volume 119 | number 6 | June 2011*

#### Résumé

Cette étude voudrait établir un lien entre la proximité d'une autoroute et la prévalence de l'autisme. Elle recèle une très intéressante erreur de logique, relative à l'utilisation des cas-témoin.

#### 1. Introduction

La présence d'infrastructures ou d'équipements et les conséquences qu'elle peut avoir sur la santé publique sont des préoccupations très anciennes : on peut imaginer que les riverains de la Via Appia (construite en 312 av JC) se plaignaient déjà du bruit. De nos jours, l'interrogation est systématique : nous-même l'avons rencontrée lors de contrats avec Aéroports de Paris (bruit), Réseau de Transport d'Electricité (diverses maladies associées à la proximité des lignes HT). D'autres exemples d'actualité sont les antennes, les routes, les voies ferrées, etc.

L'étude que nous analysons ici traite du risque d'autisme, pour les populations qui résident à proximité d'une autoroute ? Y sont-elles plus exposées que la moyenne ?

#### 2. Bien poser le problème

Posons bien le problème : prenons une population d'un million d'habitants, vivant à proximité d'une autoroute, et une population exactement identique à tous égards, vivant loin de toute autoroute, y aura-t-il un nombre significativement plus élevé d'enfants autistes dans la première que dans la seconde ? Dès que le problème est bien posé, on voit qu'il est impossible à résoudre : il est impossible d'analyser deux panels d'un million de personnes, identiques, mais différant par ce seul critère : l'un est à proximité d'une autoroute, l'autre à grande distance.

#### 3. Analyse critique des résultats

L'étude dit ceci : les données proviennent de 304 cas d'autisme et de 259 témoins. Les sujets avaient entre 24 et 60 mois au moment du recrutement, qui a eu lieu entre 2003 et 2009, ont vécu avec au moins un parent biologique anglophone ou hispanophone, sont nés en Californie et résidaient dans l'une des zones de recrutement de l'étude au moment de l'inscription.

Voici les résultats obtenus :

Exposure ORs (95% CIs) for autism, by category of distance from residence to the nearest freeway at time of birth ( $n = 563$ ).

Exposure category	n (cases/controls)	Crude	Adjusted <sup>a</sup>
< 309 m from freeway (closest 10%)	38/19	1.86 (1.04–3.45)	1.86 (1.03–3.45)
309–647 m from freeway (10th to 25th percentile)	43/41	0.98 (0.60–1.59)	0.96 (0.58–1.56)
647–1,419 m from freeway (25th to 50th percentile)	77/63	1.14 (0.76–1.71)	1.11 (0.73–1.67)
> 1,419 m from freeway (further 50%)	146/136	Reference	Reference

Le résultat principal est en première ligne du tableau : dans la population proche de l'autoroute (moins de 309 m), on trouve 38 cas d'autisme, contre seulement 19 dans la population témoin.

Pour bien comprendre les données, présentons-les sous forme de tableau :

distance autoroute	d<309	309<d<647	647<d<1419	>1419	total
autistes	38	43	77	146	304
témoins	19	41	63	136	259

La distance 309 m est choisie parce que la somme 38+19= 57 est à peu près 10% de l'effectif total (ici 563) et la distance 647 parce que la somme 38+43+19+41 est à peu près 25% de l'effectif total.

L'article croit pouvoir conclure que, dans la part de l'échantillon la plus proche de l'autoroute (moins de 309 m), la proportion d'autistes est beaucoup plus élevée que dans la population totale.

La proportion d'autistes proche de l'autoroute est en effet :

$$p_1 = \frac{38}{38+19} \approx 0.67, ,$$

tandis que la proportion d'autistes dans la population générale est :

$$p_2 = \frac{304}{304+259} \approx 0.54.$$

Or, comment a été choisie la population témoin ? L'article dit explicitement :

*"Population-based controls were recruited from the sampling frame of birth files from the State of California and were frequency matched by sex, age, and broad geographic area to the autism cases."*

C'est nous qui soulignons les mots "broad geographic area". On ne connaît pas réellement et précisément la localisation des enfants-témoin. Il se trouve que, à proximité de l'autoroute, il y a 38 enfants autistes (c'est ainsi, on n'y peut rien), mais le sort a fait que, parmi la population témoin, seulement 19 soient à proximité de l'autoroute, ce qui crée un artefact majeur et une erreur dans la logique du raisonnement. Il aurait très bien pu se faire que, parmi les 259 témoins, 200 se trouvent à proximité de l'autoroute et la conclusion aurait été différente.

L'erreur principale tient au fait que les auteurs ne savent pas réellement ce qu'est une étude cas-témoin (ignorance fort répandue) ! Pour qu'elle soit valide, comme nous l'avons dit en introduction, il faudrait disposer de deux populations, disons chacune de 1 000 personnes, absolument identiques, si ce n'est que la première est à proximité d'une autoroute et l'autre non. Dans ces conditions, si on observe un surplus significatif d'autistes dans la première, on pourra incriminer l'autoroute.

Nous avons réalisé en 2009, pour le compte de RTE, une analyse critique très semblable :

[http://www.scmsa.eu/archives/SCM\\_Draper\\_2009.pdf](http://www.scmsa.eu/archives/SCM_Draper_2009.pdf) :

il s'agissait des cas de leucémies au voisinage des lignes HT. Nous y renvoyons le lecteur pour une liste des biais innombrables que comportent de telles études : ces biais sont les mêmes ici.

S'y ajoute le fait que l'autisme peut avoir une origine génétique :

<https://spectredelautisme.com/trouble-du-spectre-de-l-autisme-tsa/statistiques-autisme-tsa/>

qui n'a évidemment rien à voir avec la proximité d'une autoroute.

Enfin, il y a un élément, cité par l'étude, qui invalide complètement les résultats : l'étude dit (en conclusion) : *"Il a été estimé que 11 % de la population américaine vit à moins de 100 m d'une autoroute à quatre voies, de sorte qu'un lien de causalité avec l'autisme ou d'autres troubles neurodéveloppementaux aurait de vastes répercussions sur la santé publique"*.

Or la population américaine se monte à environ 330 millions de personnes ; 11% cela fait 36 millions vivant à proximité immédiate d'une autoroute. Si l'autisme était significativement développé en ce cas (et nous sommes à moins de 100 m, et pas seulement à 309 m), cela se verrait de manière immédiate et sans la moindre ambiguïté. On n'aurait pas besoin d'une étude cas-témoin portant sur moins de 600 personnes.

#### **4. Conclusion**

Nous sommes ici en présence d'une étude entièrement dépourvue de valeur scientifique. Elle cherche, par tous moyens statistiques disponibles, à établir que la prévalence de l'autisme est plus élevée à proximité des autoroutes, mais n'y parvient pas, parce que la conception même de l'étude est défectueuse.

De tels procédés, à l'inverse, permettraient de prouver que la Place de la Concorde favorise le génie : tous les génies, au cours de leur vie, sont passés par la Place de la Concorde au moins une fois. Nous renvoyons à notre article :

[http://scmsa.eu/archives/SCM\\_Bonnes\\_pratiques\\_epidemiologie\\_2009b.pdf](http://scmsa.eu/archives/SCM_Bonnes_pratiques_epidemiologie_2009b.pdf)

pour la définition des bonnes pratiques en épidémiologie.

Lorsque des populations très importantes sont exposées à un risque, il existe un argument très simple qui permet de conclure instantanément. Prenons un exemple typique : celui des téléphones portables. Il y a des milliards d'utilisateurs, depuis des dizaines d'années. Si l'usage du portable était associé à un risque, cela se serait vu depuis longtemps.