

# REVUE DE STATISTIQUE APPLIQUÉE

ANIS ABI FARAH

## **Un test pour le contrôle de la qualité du travail dans un recensement**

*Revue de statistique appliquée*, tome 22, n° 1 (1974), p. 67-86

[http://www.numdam.org/item?id=RSA\\_1974\\_\\_22\\_1\\_67\\_0](http://www.numdam.org/item?id=RSA_1974__22_1_67_0)

© Société française de statistique, 1974, tous droits réservés.

L'accès aux archives de la revue « *Revue de statistique appliquée* » (<http://www.sfds.asso.fr/publicat/rsa.htm>) implique l'accord avec les conditions générales d'utilisation (<http://www.numdam.org/conditions>). Toute utilisation commerciale ou impression systématique est constitutive d'une infraction pénale. Toute copie ou impression de ce fichier doit contenir la présente mention de copyright.

NUMDAM

Article numérisé dans le cadre du programme  
Numérisation de documents anciens mathématiques  
<http://www.numdam.org/>

# UN TEST POUR LE CONTROLE DE LA QUALITÉ DU TRAVAIL DANS UN RECENSEMENT

Anis ABI FARAH

Université Libanaise, Faculté des Sciences, Hadeth-Beyrouth Liban

## 1 – INTRODUCTION

Dans un recensement, la qualité du travail peut être mesurée par la proportion d'unités statistiques recensées effectivement ; ou encore par la proportion  $p$  d'unités statistiques oubliées ; en général  $p$  varie de 2 à 6 %.

L'objet de cet article est de présenter une méthode de contrôle de qualité. On compare entre eux plusieurs modèles probabilistes, afin de choisir le meilleur modèle qui servira pour la construction d'un test classique ou séquentiel. Ce test porte sur les valeurs que peut prendre la proportion  $p$ , il nous permet alors de contrôler la qualité du travail au fur et à mesure qu'il est fourni.

2 –

### 2.1 – Description de la méthode de contrôle.

Supposons qu'on veuille recenser les logements dans une ville donnée  $V$ . La ville  $V$  est considérée comme étant quadrillée par un quadrillage aussi fin qu'on le désire ; (on pourrait se servir des tournées déterminées par les rues), de telle sorte que chaque logement appartienne à un pâté de logements et à un seul.

Un enquêteur  $E_1$ , est envoyé pour recenser les logements dans une région  $R_1$  de  $V$  comprenant  $f_1$  pâtés, en remplissant un questionnaire approprié pour chaque logement.

Un enquêteur  $E_2$  est envoyé pour recenser indépendamment de  $E_1$  les logements d'une sous-région  $R_2$  de  $R_1$  formée de  $f_2$  pâtés choisis au hasard parmi les  $f_1$  pâtés de  $R_1$ . On a bien  $R_2 \subseteq R_1$  et  $f_2 \leq f_1$ .

Soit  $X$  l'ensemble des logements de  $R_2$  recensés par  $E_1$ , et soit  $Y$  l'ensemble des logements recensés par  $E_2$  dans la même région  $R_2$ . On peut écrire la relation suivante :

$$R_2 = X \Delta Y + X \cap Y + C_{R_2}(X \cup Y)$$

$$= (X - Y) + (Y - X) + X \cap Y + C_{R_2}(X \cup Y).$$

Les ensembles au second membre sont deux à deux disjoints.

*Remarque* : L'indépendance entre  $E_1$  et  $E_2$  peut être assurée en les choisissant au hasard parmi l'ensemble des recenseurs, et en veillant à ce qu'ils ne soient pas courant du fait qu'ils recensent la même région  $R_2$ .

## 2.2. – Modèles mathématiques.

Soient  $p_1$  et  $p_2$  les probabilités d'oubli d'un logement quelconque par les enquêteurs  $E_1$  et  $E_2$  respectivement. Une expérience aléatoire consiste à considérer chaque logement de  $R_2$  ; il peut appartenir (indépendamment des autres logements) à  $X - Y$  ou à  $Y - X$  ou à  $X \cap Y$  ou enfin à  $R_2 - X \cup Y$ .

Posons :

$$N_1 = \text{card}(X - Y) \quad N_2 = \text{card}(Y - X)$$

$$N_3 = \text{card}(X \cap Y) \quad \text{et} \quad N_4 = \text{card}(R_2 - X \cup Y)$$

Ayant pour réalisations  $n_1, n_2, n_3$  et  $n_4$  respectivement.

Si  $n$  est le nombre théorique de logements dans  $R$ , la loi de probabilité de  $(N_1, N_2, N_3, N_4)$  est multinomiale ; ses paramètres sont  $[n ; (1 - p_1) p_2, (1 - p_2) p_1, (1 - p_1)(1 - p_2), p_1 p_2]$ .  $N_1, N_2, N_3$  et  $N_4$  sont quatre variables aléatoires liées par la relation  $N_1 + N_2 + N_3 + N_4 = n$ . Autrement dit, ce sont les coordonnées d'un point aléatoire d'un sous-espace linéaire à trois dimensions.

## 2.3. – Loi conditionnelle de $(N_1, N_2, N_3)$ .

Un inconvénient du modèle décrit au § 2.2. est qu'on ne connaît pas  $n$  ; sinon le problème serait partiellement résolu. L'information fournie par la réalisation de  $N_1, N_2$  et  $N_3$  devrait nous permettre de définir un autre modèle utilisable par la suite pour la construction du test.

On considère pour cela la loi conditionnelle de  $(N_1, N_2, N_3)$  sachant que  $N_1 + N_2 + N_3 = l$ .

Soit  $(N_1, N_2, N_3, N_4)$  de loi multinomiale  $[n ; r_1, r_2, r_3, r_4]$

En posant :

$$r_1 = (1 - p_1) p_2, \quad r_2 = (1 - p_2) p_1, \quad r_3 = (1 - p_1)(1 - p_2) \quad \text{et} \quad r_4 = p_1 p_2.$$

On a :

$$\begin{aligned}
& P [N_1 = n_1, N_2 = n_2, N_3 = n_3 / N_1 + N_2 + N_3 = l] \\
&= \frac{P [N_1 = n_1, N_2 = n_2, N_3 = n_3, N_1 + N_2 + N_3 = l]}{P [N_1 + N_2 + N_3 = l]} \\
&= \frac{\frac{n!}{n_1! n_2! n_3! (n - n_1 - n_2 - n_3)!} r_1^{n_1} r_2^{n_2} r^{l - n_1 - n_2}}{\frac{n!}{l! (n - l)!} (r_1 + r_2 + r_3)^l r_4^{n_4}} \\
&= \left( \frac{l}{n_1 n_2 n_3} \right) \left( \frac{r_1}{1 - r_4} \right)^{n_1} \left( \frac{r_2}{1 - r_4} \right)^{n_2} \left( \frac{r_3}{1 - r_4} \right)^{l - n_1 - n_2}
\end{aligned}$$

avec  $n_i \geq 0$ ,  $\sum_{i=1}^3 n_i = l$ ; et  $r_i \geq 0$ ,  $\sum_{i=1}^3 r_i = 1$ ,  $r_i' = r_i / (1 - r_4)$ .

Donc  $[N_1, N_2, N_3 / N_1 + N_2 + N_3 = l]$  suit une loi multinomiale de paramètres

$$\left[ l ; \frac{r_1}{1 - r_4} \quad \frac{r_2}{1 - r_4} \quad \frac{r_3}{1 - r_4} \right]$$

3. —

### 3.1 — Modèle à retenir pour faire le test portant sur les valeurs de $p_1$

Un critère pour retenir un modèle  $M_1$  plutôt qu'un autre  $M_2$  consiste à comparer les quantités d'information au sens de Fisher des deux modèles au sujet du paramètre  $p_1$ . Celui qui a une quantité d'information plus grande sera préféré à l'autre.

Quelle est alors la quantité d'information  $I(M_i)$  fournie par une réalisation d'une variable aléatoire  $Z$  au sujet du paramètre  $p_1$ , si  $Z$  a comme loi de probabilité  $M_i$  :

1/  $M_1$  :  $Z$  suit la loi décrite dans le § 2.2.

2/  $M_2$  :  $Z$  suit la loi décrite dans le § 2.3.

3/  $M_3$  : On considère la variable aléatoire  $N_1 + N_2 / N_1 + N_2 + N_3 = l$  elle suit une loi binomiale  $\left( l ; \frac{r_1 + r_2}{1 - r_4} \right)$

On a :

$$1/ I(M_1) = - E \left( \frac{\partial^2 \log L_1}{\partial p_1^2} \right) \text{ avec } L_1 = \left( \frac{n!}{n_1! n_2! n_3! n_4!} \right) r_1^{n_1} r_2^{n_2} r_3^{n_3} r_4^{n_4}$$

Ce qui donne  $I(M_1) = \frac{n}{p_1 (1 - p_1)}$ .

$$2/ I(M_2) = - E \left( \frac{\partial^2 \log L_2}{\partial p_1^2} \right) \text{ avec } L_2 = \binom{l!}{n_1! n_2! n_3!} \left( \frac{r_1}{1 - r_4} \right)^{n_1} \left( \frac{r_2}{1 - r_4} \right)^{n_2} \left( \frac{r_3}{1 - r_4} \right)^{n_3}$$

Le calcul donné en Annexe A<sub>1</sub> conduit à :

$$I(M_2) = \frac{l}{1 - p_1 p_2} \left[ \frac{1}{1 - p_1} + \frac{1 - p_2}{p_1} \right] - \frac{l p_2^2}{(1 - p_1 p_2)}$$

$$3/ I(M_3) = - E \frac{\partial^2 \log L_3}{\partial p_1^2} \text{ avec } L_3 = \binom{n}{k} \left[ \frac{(1 - p_1) p_2 + (1 - p_2) p_1}{1 - p_1 p_2} \right]^k \left[ \frac{(1 - p_1) (1 - p_2)}{1 - p_1 p_2} \right]^{l-k}$$

Le calcul donné en Annexe A<sub>2</sub> donne :

$$I(M_3) = \frac{l}{1 - p_1 p_2} \left[ \frac{(1 - 2 p_2)^2}{(1 - p_1) p_2 + (1 - p_2) p_1} + \frac{1 - p_2}{1 - p_1} \right] - \frac{l p_2^2}{(1 - p_1 p_2)^2}$$

*Remarque* : Dans le modèle M<sub>1</sub>, E<sub>2</sub> ne nous renseigne par sur la valeur du paramètre p<sub>1</sub>.

### 3.2. – Comparaison de I(M<sub>1</sub>) et I(M<sub>2</sub>).

Si p<sub>1</sub> p<sub>2</sub>, p<sub>1</sub><sup>2</sup> et p<sub>2</sub><sup>2</sup> sont négligeables à côté de p<sub>1</sub> ou de p<sub>2</sub> on a :

$$I(M_2) \simeq l \frac{1 + p_1 - p_2}{p_1 (1 - p_1)}$$

$$\frac{I(M_2)}{I(M_1)} \simeq \frac{l}{n} (1 + p_1 - p_2)$$

### 3.3. – Comparaison de I(M<sub>1</sub>) et de I(M<sub>3</sub>)

En négligeant p<sub>1</sub> p<sub>2</sub> ; p<sub>1</sub><sup>2</sup> et p<sub>2</sub><sup>2</sup> à côté de p<sub>1</sub> ou de p<sub>2</sub> comme on a fait au § précédent on obtient :

$$\begin{aligned} I(M_3) &\simeq l \left[ \frac{1 - 4p_2}{p_1 p_2} + \frac{1 - p_2}{1 - p_1} \right] \\ &= l \left[ \frac{1 - 3p_2}{(p_1 + p_2) (1 - p_1)} \right] \end{aligned}$$

D'où :

$$\frac{I(M_3)}{I(M_1)} \approx \frac{l}{n} p_1 \left[ \frac{1 - 3 p_2}{p_1 + p_2} \right]$$

Exemple numérique :  $p_1 = 0,02$  et  $p_2 = 0,06$  donne  $\frac{I(M_3)}{I(M_1)} \approx \frac{l}{n} 0,2050$ .

Il y a environ 4/5 de l'information qui est perdue si l'on adopte le modèle  $M_3$  au lieu du modèle  $M_1$ . Or  $n$  n'est pas connu et l'on ne peut prendre dans ce cas que le modèle  $M_2$ .

### 3.4. - Etude du cas $p_1 = p_2 = p$ .

Si les deux enquêteurs  $E_1$  et  $E_2$  fournissent théoriquement un travail de même qualité, en d'autres termes si  $p_1 = p_2 = p$ , les quantités d'information fournies par les modèles  $M_1$ ,  $M_2$  et  $M_3$  au sujet du paramètre  $p$ , sont respectivement  $I'(M_1)$ ,  $I'(M_2)$  et  $I'(M_3)$  où :

$$1/ \quad I'(M_1) = -E \frac{\partial^2 \log L_1}{\partial p^2}$$

$$\text{avec} \quad L_1 = \binom{n}{n_1 \ n_2 \ n_3 \ n_4} [p(1-p)]^{n_1+n_2} \times [(1-p)^2]^{n_3} (p^2)^{n_4}$$

Le calcul (cf Annexe A<sub>3</sub>) conduit à

$$I'(M_1) = \frac{2n}{p(1-p)}$$

$$2/ \quad I'(M_2) = -E \left( \frac{\partial^2 \log L_2}{\partial p^2} \right)$$

$$\text{avec} \quad L_2 = \binom{l}{n_1 \ n_2 \ n_3} \left[ \frac{p(1-p)}{1-p^2} \right]^{n_1} \times \left[ \frac{p(1-p)}{1-p^2} \right]^{n_2} \left[ \frac{(1-p)^2}{1-p^2} \right]^{n_3}$$

Le calcul (cf Annexe A<sub>4</sub>) donne

$$I'(M_2) = \frac{2l}{p(1-p)} \cdot \frac{1}{(1+p)^2}$$

$$3/ \quad I'(M_3) = -E \left( \frac{\partial^2 \log L_3}{\partial p^2} \right) \text{ avec } L_3 = \binom{l}{k} \left( \frac{2p}{1+p} \right)^k \left( \frac{1-p}{1+p} \right)^{l-k}$$

Le calcul (cf Annexe A<sub>5</sub>) donne encore :

$$I'(M_3) = \frac{2l}{p(1-p)} \cdot \frac{1}{(1+p)^2}$$

*Remarque 1* – On a :

$$\begin{aligned}\frac{I'(M_1)}{I(M_1)} &= 2 \frac{n}{p(1-p)} \cdot \frac{p_1(1-p_1)}{n} \\ &= 2 \frac{p_1(1-p_1)}{p(1-p)}\end{aligned}$$

La quantité d'information fournie par le modèle  $M_1$  au sujet de  $p$  se trouve alors doublée.

*Remarque 2* – De même si l'on compare  $I'(M_1)$  à  $I'(M_2)$  on obtient :

$$\begin{aligned}\frac{I'(M_1)}{I'(M_2)} &= \frac{2n}{p(1-p)} \cdot \frac{p(1-p)(1+p)^2}{2l} \\ &= \frac{n}{l} (1+p)^2 \\ &\simeq \frac{n}{l} (1+2p)\end{aligned}$$

Il vaudrait mieux utiliser le modèle  $M_1$  plutôt que le modèle  $M_2$ . Mais, vu qu'on ne peut pas obtenir une réalisation de  $N_4$  on est obligé d'utiliser le modèle  $M_2$  ; il en résulte une perte d'information relative de l'ordre de  $2p$  si  $n$  est à peu près égal à  $l$ .

*Remarque 3* – Les quantités d'information  $I'(M_2)$  et  $I'(M_3)$  sont égales : les second et troisième modèles sont équivalents, en ce sens qu'ils apportent la même quantité d'information au sujet de  $p$ . Ceci est dû à la propriété énoncée au § 3.5.

### 3.5 – Proposition.

$N_1 + N_2 / N_1 + N_2 + N_3 = l$  est un résumé exhaustif au sujet de  $p$ .

*Démonstration* – En effet la fonction de vraisemblance  $L$  est :

$$\begin{aligned}L &= \binom{l}{n_1 \ n_2 \ n_3} \left(\frac{p}{1+p}\right)^{n_1+n_2} \left(\frac{1-p}{1+p}\right)^{n_3} \\ L &= \binom{l}{n_1 + n_2} \left(\frac{2p}{1+p}\right)^{n_1+n_2} \left(\frac{1-p}{1+p}\right)^{n_3} \cdot \binom{n_1 + n_2}{n_1} \frac{1^{n_1+n_2}}{2} \\ &= f(n_1 + n_2, p) \cdot \phi(n_1, n_2) \\ &= p [N_1 + N_2 = n_1 + n_2] \cdot \phi(n_1, n_2 / N_1 + N_2 = n_1 + n_2)\end{aligned}$$

avec  $\phi(n_1, n_2 / N_1 + N_2 = n_1 + n_2)$  est indépendante du paramètre  $p$ .

### 3.6. – Généralisation de la propriété donnée dans le § 3.5.

*Proposition* – Si  $(N_1, N_2, \dots, N_{h-1}, N_h)$  est de loi multinomiale

$(n; p_1, p_2, \dots, p_h)$  et si  $p_1 = \alpha_1 g(p), p_2 = \alpha_2 g(p), \dots, p_{h-1} = \alpha_{h-1} g(p),$

alors  $N_1 + N_2 + \dots + N_{h-1}$  est un résumé exhaustif au sujet de  $p$ .

*Démonstration* – La fonction de vraisemblance  $L$  est donnée par :

$$\begin{aligned} L &= \binom{n}{n_1, n_2, \dots, n_h} p_1^{n_1} p_2^{n_2} \dots p_h^{n_h} \\ &= \binom{n}{n_1 + n_2 + \dots + n_{h-1}} (p_1 + p_2 + \dots + p_{h-1})^{n_1 + n_2 + \dots + n_{h-1}} p_h^{n_h} \\ &\quad \times \binom{n_1 + n_2 + \dots + n_{h-1}}{n_1, n_2, \dots, n_{h-1}} \left( \frac{p_1}{p_1 + \dots + p_{h-1}} \right)^{n_1} \dots \left( \frac{p_{h-1}}{p_1 + \dots + p_{h-1}} \right)^{n_{h-1}} \end{aligned}$$

et en remplaçant les  $p_i$  par leurs valeurs on obtient :

$$\begin{aligned} L &= \binom{n}{n_1 + n_2 + \dots + n_{h-1}} [(\alpha_1 + \alpha_2 + \dots + \alpha_{h-1}) g(p)]^{n_1 + \dots + n_{h-1}} p_h^{n_h} \\ &\quad \times \binom{n_1 + \dots + n_{h-1}}{n_1, \dots, n_{h-1}} \left( \frac{\alpha_1}{\alpha_1 + \dots + \alpha_{h-1}} \right)^{n_1} \dots \left( \frac{\alpha_{h-1}}{\alpha_1 + \dots + \alpha_{h-1}} \right)^{n_{h-1}} \\ &= P[N_1 + N_2 + \dots + N_{h-1} = l, p] \times \phi(n_1, n_2, \dots, n_h) \end{aligned}$$

où  $P$  est la loi de probabilité de  $N_1 + N_2 + \dots + N_{h-1}$  qui dépend du paramètre  $p$  ; et  $\phi$  est la loi de probabilité de

$$N_1, N_2, \dots, N_{h-1} / N_1 + N_2 + \dots + N_{h-1} = l$$

$\phi$  étant fonction des  $n_i$  et non de  $p$ .

*Remarque 4* – Dans le cas où  $\alpha_1 = \alpha_2 = \dots = \alpha_{h-1} = 1,$

$$g(p) = \frac{p(1-p)}{1-p^2} = \frac{p}{1+p}$$

et  $h = 3,$  on obtient le cas décrit au § 3.5.

### 3.7. – Généralisation de la méthode décrite au § 2.1.

On suppose qu'on a envoyé  $m$  enquêteurs  $E_1, E_2, \dots, E_m$  pour recenser indépendamment les uns des autres les logements de la région  $R_2$ .  $R_2$  se trouve alors partitionnée en  $2^m$  parties disjointes

$$A_j; j = 1, 2, \dots, 2^m. \quad \text{On a :} \quad R_2 = \bigcup_{i=1}^{2^m} A_i \quad \text{et} \quad \bigcap A_i A_j = \phi, \quad i \neq j.$$



Soit  $A_1$  la région des logements oubliés par tous les enquêteurs sans exception, et  $N_1 = \text{card } A_1$  (l'homologue du  $N_4$  de 2.2.). Si  $p_1$  est la probabilité d'oubli de  $E_1$ ,  $p_2$  celle de  $E_2, \dots, p_m$  celle de  $E_m$ , alors la probabilité qu'un logement appartienne à  $A_1$  est  $p_1, p_2, \dots, p_m$ .

De même, soit  $A_2$  la région des logements oubliés par tous les enquêteurs sauf le 1<sup>er</sup>. et soit  $N_2 = \text{card } A_2$ .

On a :

$$p(\text{logement} \in A_2) = (1 - p_1) \prod_{i \neq 1} p_i$$

et ainsi de suite pour les autres régions, la dernière région est  $A_{2m}$  dont le cardinal est  $N_{2m}$  et telle que  $P[\text{logement} \in A_{2m}] = \prod_{i=1}^m (1 - p_i)$ . On constate que les probabilités respectives des régions  $A_j$  sont les termes du développement du produit :  $[p_1 + (1 - p_1)] [p_2 + (1 - p_2)] \dots [p_m + (1 - p_m)]$ .

Alors :  $(N_1, N_2, \dots, N_{2m})$  est de loi multinomiale

$$\left[ n ; \prod_{i=1}^m p_i, (1 - p_1) \quad p_2, \dots, \prod_{i=1}^m (1 - p_i) \right].$$

Autrement dit  $(N_1, N_2, \dots, N_{2m})$  est de loi mult.  $[n ; r_1, \dots, r_j, \dots, r_{2m}]$

en posant  $r_1 = \prod_{i=1}^m p_i, r_2 = (1 - p_1) \prod_{i=1}^m p_i, \dots, r_{2m} = \prod_{i=1}^m (1 - p_i)$ . Tout

$r_j$  s'écrit sous la forme  $p_1 r'_k$  ou  $(1 - p_1) r'_k$  ; les  $r'_k$  étant les termes du développement :  $[p_2 + (1 - p_2)] [p_3 + (1 - p_3)] \dots [p_m + (1 - p_m)]$ . Ce

qui fait que  $\sum_{k=1}^{2m-1} r'_k = 1$ .

En calculant la quantité d'information  $I(p_1)$  on trouve alors :

$$\begin{aligned} I(p_1) &= \sum_{k=1}^{2m-1} E \left[ \frac{n_k}{p_1^2} + \frac{n - n_k}{(1 - p_1)^2} \right] \\ &= \sum_{k=1}^{2m-1} \left[ \frac{np_1 r_k}{p_1^2} + \frac{n(1 - p_1) r_k}{(1 - p_1)^2} \right] \\ &= \frac{n}{p_1 (1 - p_1)} \end{aligned}$$

*Remarque* – La quantité d'information au sujet de  $p_1$  est seulement fournie par  $E_1$  ; les autres enquêteurs n'apportent aucune information supplémentaire au sujet de  $p_1$ .



*Remarque* – Si  $m$  est suffisamment grand, on a :

$$I(p) \approx \frac{m \cdot l}{p(1-p)}.$$

Au contraire, si  $m = 2$ , on a :

$$I(p) = \frac{2l}{p(1-p)} \cdot \frac{1}{(1+p)^2}$$

formule déjà trouvée au § 3.4.

4.

4.1. –

On considère les hypothèses des § 2.3., et 3.4. On a vu que dans le cas où  $p_1 = p_2 = p$  les modèles  $M_2$  et  $M_3$  sont équivalents et que

$$(N_1 + N_2 / N_1 + N_2 + N_3 = l)$$

est un résumé exhaustif au sujet de  $p$  (§ 3.5)  $p$  étant la probabilité d'oubli des recenseurs  $E_1$  et  $E_2$ . Donc on a intérêt à ce que les deux enquêteurs  $E_1$  et  $E_2$  aient la même probabilité  $p$  afin de pouvoir se servir du modèle  $M_3$  pour construire le test portant sur la valeur de ce paramètre  $p$ .

4.2. – Test de l'hypothèse  $H_0 : p_1 = p_2$  contre  $H_1 : p_1 \neq p_2$ .

La loi de probabilité de  $N_1$  sachant que  $N_1 + N_2 = l$  est binomiale ; de paramètres

$$\left( l, \frac{p_2 (1 - p_1)}{1 - p_1 p_2 - (1 - p_1) (1 - p_2)} \right) = (l, q)$$

Si l'hypothèse nulle est vraie  $p_1 = p_2 \implies q = \frac{1}{2}$  ; et si l'hypothèse alternative est vraie.  $q \neq \frac{1}{2} : 0 \leq q \leq 1$ .

D'ailleurs on voit facilement que  $q > 1/2$  signifie  $p_2 > p_1$ , et  $q < 1/2$  l'inverse.

D'où la région critique  $w$  du test est définie par :

$\frac{L_0}{L_1} < c$  à l'intérieur de la région critique, c'est-à-dire :

$$\frac{\binom{l}{k} \left(\frac{1}{2}\right)^l}{\binom{l}{k} q^k (1-q)^{l-k}} < c$$

où  $k$  désigne  $N_1$  ou  $N_2$  (notations de 2.2. et 2.3).

$$l \log \frac{1}{2} - k \log q - (l - k) \log (1 - q) < c'$$

$$k \left( \log \frac{1 - q}{q} \right) < c''$$

si  $\frac{1 - q}{q} > 1$  c'est-à-dire,  $q < \frac{1}{2} \implies w$  est définie par  $k < c_1$ ,

et si  $\frac{1 - q}{q} < 1$  c'est-à-dire,  $q > \frac{1}{2} \implies w$  est définie par  $k > c_2$

Donc on ne rejette pas l'hypothèse nulle si  $c_2 > k > c_1$  et on la rejette dans le cas contraire.

Donc on obtient un test bilatéral symétrique.

*Remarque* – Si l'hypothèse nulle  $H_0 : p_1 = p_2$  n'est pas rejetée on adopte le modèle  $M_3$  du § 3. 4, c'est-à-dire, la loi de  $N_1 + N_2 / N_1 + N_2 + N_3 = l$  avec  $p_1 = p_2 = p$  et on procède à la construction d'un test portant sur la valeur de  $p$ . Mais dans le cas où l'hypothèse nulle  $H_0$  est rejetée, il faut adopter le modèle  $M_2$  du § 3.1, en considérant la loi de  $(N_1, N_2, N_3 / N_1 + N_2 + N_3 = l)$  avec  $p_1 \neq p_2$  ; et l'on construit alors un test portant sur les valeurs du paramètre  $p_1$  en supposant que  $p_2$  est connu.

Dans ce qui suit, on suppose que  $H_0$  n'est pas rejetée et l'on procède à la construction d'un test classique et un test séquentiel portant sur la valeur de  $p$ . (Modèle  $M'_2$  du § 3.4).

Dans le second cas, deux tests analogues peuvent être construits facilement utilisant le modèle  $M_2$  de § 3.1.

#### 4.3. – Test classique de l'hypothèse nulle $H_0$ :

$p \leq P_0$  contre l'hypothèse alternative  $H_1 : p \geq P_1$

En adoptant le modèle  $M'_3$  du § 3.4., on a :

$$L = P [N_1 + N_2 = k / N_1 + N_2 + N_3 = l] \\ = \binom{l}{k} \left( \frac{2p}{1 + p} \right) \left[ \frac{(1 - p)}{1 + p} \right]^{l-k} \quad k = 0, 1, 2, \dots, l$$

$N_1 + N_2$  est la somme des nombres des logements oubliés par  $E_1$  et recensés par  $E_2$  et ceux, oubliés par  $E_2$  et retrouvés par  $E_1$ .

On a :  $\frac{L_0}{L_1} < c$  dans la région critique  $w$ .

Ce qui donne dans le cas où  $P_0 < P_1$ , une région critique définie par  $k > \text{constante } C$ .

4.4. – Application numérique et calcul de la puissance du test.

On admet en général dans les recensements une proportion d'unités oubliées allant de 2 à 6 %. On va donner dans ce § une liste des tests de l'hypothèse  $p \leq P_0$  contre l'hypothèse alternative  $p \geq P_1$ , où  $P_0 = 0,02$  et  $P_1$  prenant successivement les valeurs 0,03 ; 0,04 ; 0,05 ; 0,06 ; 0,07 ; et 0,08. (Table n° 1) On va indiquer dans cette table la taille  $l$  de l'échantillon, la région critique, l'erreur  $\alpha$  de première espèce et la puissance du test.

Table N° 1  
Puissances des tests,  $1 - \beta$

Taille $l$	Valeur Crit. C	Risque $\alpha$	$P_1$					
			0,03	0,04	0,05	0,06	0,07	0,08
10	1	0,056	0,1120	0,1765	0,2454	0,3153	0,3834	0,4487
20	2	0,042	0,1077	0,1958	0,2958	0,3984	0,4964	0,5858
50	4	0,046	0,1652	0,3396	0,5234	0,6818	0,8002	0,8809
100	7	0,043	0,2282	0,5070	0,7464	0,8908	0,9589	0,9862
150	10	0,035	0,2598	0,6092	0,8550	0,9595	0,9909	0,9983
200	12	0,053	0,3840	0,7730	0,9490	0,9922	0,9991	0,9999
300	17	0,051	0,4844	0,8896	0,9850			
400	22	0,045	0,5585					

4.5. – Test séquentiel de l'hypothèse nulle  $H_0$

$p \leq P_0$  contre  $H_1 : p \geq P_1$  avec  $P_0 < P_1$

On considère ici aussi la variable aléatoire

$$N_1 + N_2 / N_1 + N_2 + N_3 = l$$

qui suit une loi binomiale.

Si  $H_0$  est vraie :

$$N_1 + N_2 / N_1 + N_2 + N_3 = l$$




a une loi binomiale

$$\left[ l ; r_0 = \frac{2P_0}{1 + P_0} \right]$$

et si  $H_1$  est vraie, elle a une loi binomiale de paramètres

$$\left[ l ; r_1 = \frac{2P_1}{1 + P_1} \right]$$

En prenant pour erreur  $\alpha$  et  $\beta$  (de première et deuxième espèce respectivement) on obtient :



$$D_1 = \frac{\log \frac{\beta}{1-\alpha}}{\log \frac{r_1}{r_0} - \log \frac{1-r_1}{1-r_0}} + l \frac{\log \frac{1-r_0}{1-r_1}}{\log \frac{r_1}{r_0} - \log \frac{1-r_1}{1-r_0}} \leq k \leq$$

$$\frac{\log \frac{1-\beta}{\alpha}}{\log \frac{r_1}{r_0} - \log \frac{1-r_1}{1-r_0}} + l \frac{\log \frac{1-r_0}{1-r_1}}{\log \frac{r_1}{r_0} - \log \frac{1-r_1}{1-r_0}} = D_2$$

L'enquêteur  $E_2$  continue à recenser tant que  $k$  varie entre les deux limites indiquées dans l'inégalité double :  $D_1 < k < D_2$  ; et lorsqu'on a  $k \leq D_1$  ou  $k \geq D_2$ , on arrête l'échantillonnage pour ne pas rejeter ou pour rejeter l'hypothèse nulle (respectivement).

#### 4.6. – Application numérique.

Donnons aux paramètres du § 4.5, les valeurs numériques suivantes :

$$P_0 = 0,02 ; P_1 = 0,05 ; \alpha = 0,05 \quad \text{et} \quad \beta = 0,05.$$

D'où

$$r_0 = 0,0392 \quad \text{et} \quad r_1 = 0,0952$$

$D_1$  et  $D_2$  ont pour équations respectives.

$$D_1 = -3,109 + 0,063 l < k < 3,109 + 0,063 l = D_2.$$

Voir figure 1, 2 et 3 où l'on donne respectivement les graphes de  $D_1$  et  $D_2$ , l'O.C du test et la courbe du nombre moyen d'observations nécessaires pour le test.

## 5. CONCLUSION

On peut retenir le modèle  $M'_3$  pour contrôler la qualité du recensement, à condition que les deux enquêteurs  $E_1$  et  $E_2$  fournissent un travail de même qualité. Cette condition peut être satisfaite en choisissant  $E_1$  et  $E_2$  au hasard dans un groupe homogène d'enquêteurs. On peut chaque fois tester si  $p_1$  est égale à  $p_2$  en faisant le test du § 4.2.

Un test séquentiel nous permet alors de décider après chaque observation faite par le second enquêteur (ou un groupe d'observations).

Le test fournit une réduction dans le nombre d'observations nécessaires par rapport au test classique ( $\alpha$  et  $\beta$  étant les mêmes pour les deux tests).

Cette réduction est de l'ordre de 15 % au moins. C'est-à-dire que, dans le cas où  $r = 0,063 = s$  et  $\alpha = 0,05$  et  $\beta = 0,05$ , on a besoin de 200 observations pour le test classique et de 170 observations environ pour le test séquentiel. (voir Tableau n° 1 et figure n° 3).

Cependant, si le test du § 4.2 nous conduit à rejeter l'hypothèse nulle  $p_1 = p_2$ , alors on devra utiliser le modèle  $M_2$  pour faire le test portant sur les valeurs de  $p_1$ , en supposant  $p_2$  connu. On pourra construire d'une manière analogue un test classique et un autre séquentiel pour contrôler la qualité du recensement.

## BIBLIOGRAPHIE

- [1] DIRECTION CENTRALE DE LA STATISTIQUE AU LIBAN – Enquête par sondage sur la population active 1970 volume I.
- [2] FELLER, W. – An introduction to probability and its applications. Wiley.
- [3] KENDALL, M. STUART, A. – The advanced theory of statistics, London Griffin.
- [4] KOHN, A. – A cost effectiveness model for air pollution control with a single stochastic variable. Journal of the American Statistical Association, March 1972.
- [5] MINTON, G. – Vérification error in single sampling inspection plans for processing survey data. Journal of the American Statistical Association, March 1972.
- [6] WALD, A. – Sequential analysis. John Wiley and Sons inc. Eighth Printing, October 1966.
- [7] U.S. BUREAU OF THE CENSUS – United States Census of Population and Housing 1960 ; quality of preparatory operations, microfilming and coding, Washington, D.C. : U.S. Government Printing Office.

## ANNEXES

A<sub>1</sub> Calcul de  $I(M_2)$  du 3.1/2 :

$$\begin{aligned} \text{Log } L_2 &= \log \binom{l}{n_1 \ n_2 \ n_3} + n_1 \log r_1 + n_2 \log r_2 + n_3 \log r_3 \\ &\quad - (n_1 + n_2 + n_3) \log (1 - r_4). \end{aligned}$$



$$\frac{\partial \log L_2}{\partial p_1} = -\frac{n_1}{(1-p_1)p_2} p_2 + \frac{n_2(1-p_2)}{(1-p_2)p_1} - \frac{n_3(1-p_2)}{(1-p_1)(1-p_2)} + \frac{(n_1+n_2+n_3)}{1-p_1 p_2} p_2$$

$$\frac{\partial^2 (\log L_2)}{\partial p_1^2} = -\frac{n_1}{(1-p_1)^2} - \frac{n_2}{p_1^2} - \frac{n_3}{(1-p_1)^2} + \frac{(n_1+n_2+n_3)p_2^2}{(1-p_1 p_2)^2}$$

$$\begin{aligned} I(M_2) &= \frac{l}{(1-p_1)^2} \left[ \frac{(1-p_1)p_2 + (1-p_1)(1-p_2)}{1-p_1 p_2} \right] \\ &\quad + \frac{l p_1}{p_1^2} \frac{(1-p_2)}{(1-p_1 p_2)} - \frac{p_2^2}{(1-p_1 p_2)} \quad 2.l \\ &= \frac{l}{(1-p_1)} \times \frac{1}{1-p_1 p_2} + l \left[ \frac{1-p_2}{p_1(1-p_1 p_2)} \right] - l \frac{p_2^2}{(1-p_1 p_2)} \end{aligned}$$

D'où :

$$I(M_2) = \frac{l}{1-p_1 p_2} \left[ \frac{1}{1-p_1} + \frac{1-p_2}{p_1} \right] - \frac{l p_2^2}{(1-p_1 p_2)^2}$$

A<sub>2</sub> Calcul de I(M<sub>3</sub>). du 3.1/3 :

$$\begin{aligned} \log L_3 &= \log \binom{n}{k} + k \log [(1-p_1)p_2 + (1-p_2)p_1] \\ &\quad + (l-k) [\log(1-p_1) + \log(1-p_2)] - l(1-p_1 p_2). \end{aligned}$$

$$\frac{\partial \log L_3}{\partial p_1} = \frac{k(1-2p_2)}{p_2(1-p_1) + (1-p_2)p_1} - \frac{l-k}{1-p_1} + \frac{l p_2}{1-p_1 p_2}$$

$$\frac{\partial^2 (\log L_3)}{\partial p_1^2} = -\frac{k(1-2p_2)^2}{[(1-p_1)p_2 + (1-p_2)p_1]^2} - \frac{l-k}{(1-p_1)^2} + \frac{l p_2^2}{(1-p_1 p_2)^2}$$

$$\begin{aligned} -E \left( \frac{\partial^2 \log L_3}{\partial p_1^2} \right) &= \frac{(1-2p_2)^2}{[(1-p_1)p_2 + (1-p_2)p_1]^2} \times \frac{l[(1-p_1)p_2 + (1-p_2)p_1]}{1-p_1 p_2} \\ &\quad + \frac{l(1-p_1)(1-p_2)}{(1-p_1 p_2)} \cdot \frac{1}{(1-p_1)^2} - \frac{l p_2^2}{(1-p_1 p_2)^2} \\ &= \frac{l}{1-p_1 p_2} \left[ \frac{(1-2p_2)^2}{(1-p_1)p_2 + (1-p_2)p_1} + \frac{1-p_2}{1-p_1} \right] - \frac{l p_2^2}{(1-p_1 p_2)^2} \end{aligned}$$

A<sub>3</sub>. Calcul de I'(M<sub>1</sub>) du 3.4/1 :

$$\begin{aligned} \log L_1 &= \log \binom{n}{n_1 \ n_2 \ n_3 \ n_4} + (n_1 + n_2) [\log p + \log (1 - p)] \\ &\quad + 2n_3 \log(1 - p) + 2n_4 \log p. \\ &= \log \binom{n}{n_1 \ n_2 \ n_3 \ n_4} + (\log p) (n_1 + n_2 + 2n_4) \\ &\quad + [\log (1 - p)] (n_1 + n_2 + 2n_3) \\ \frac{\partial \log L_1}{\partial p} &= \frac{(n_1 + n_2 + 2n_4)}{p} - \frac{(n_1 + n_2 + 2n_3)}{1 - p} \\ \frac{\partial^2 (\log L_1)}{\partial p^2} &= -\frac{(n_1 + n_2 + 2n_4)}{p^2} - \frac{(n_1 + n_2 + 2n_3)}{(1 - p)^2} \end{aligned}$$

D'où

$$\begin{aligned} I'(M_1) &= \frac{n}{p^2} [2p(1 - p) + 2p^2] + \frac{n}{(1 - p)^2} [2p(1 - p) + 2(1 - p^2)] \\ &= 2 \cdot \frac{n}{p(1 - p)}. \end{aligned}$$

A<sub>4</sub>. Calcul de I'(M<sub>2</sub>) du 3.4/2 :

$$\begin{aligned} L_2 &= \binom{l}{n_1 \ n_2 \ n_3} \left[ \frac{p}{1 + p} \right]^{n_1 + n_2} \left[ \frac{1 - p}{1 + p} \right]^{n_3} \\ \log L_2 &= \log \binom{l}{n_1 \ n_2 \ n_3} + (n_1 + n_2) [\log p - \log (1 + p)] \\ &\quad + n_3 [\log (1 - p) - \log (1 + p)] \\ \frac{\partial \log L_2}{\partial p} &= (n_1 + n_2) \left[ \frac{1}{p} - \frac{1}{1 + p} \right] + n_3 \left[ -\frac{1}{1 - p} - \frac{1}{1 + p} \right] \\ \frac{\partial^2 (\log L_2)}{\partial p^2} &= (n_1 + n_2) \left[ -\frac{1}{p^2} + \frac{1}{(1 + p)^2} \right] + n_3 \left[ -\frac{1}{(1 - p)^2} + \frac{1}{(1 + p)^2} \right] \end{aligned}$$

D'où :

$$\begin{aligned}
I'(M_2) &= \frac{2lp}{1+p} \left[ \frac{1}{p^2} - \frac{1}{(1+p)^2} \right] + \frac{l(1-p)}{1+p} \left[ \frac{1}{(1-p)^2} - \frac{1}{(1+p)^2} \right] \\
&= \frac{l}{1+p} \left[ \frac{2}{p} - \frac{2p}{(1+p)^2} \right] + \frac{l}{1+p} \left[ \frac{1}{1-p} - \frac{1-p}{(1+p)^2} \right] \\
&= \frac{l}{1+p} \left[ \frac{2-2p+p}{p(1-p)} - \frac{1}{1+p} \right] \\
&= \frac{2l}{p(1-p)} \cdot \frac{1}{(1+p)^2}
\end{aligned}$$

A<sub>5</sub>. Calcul de I'(M<sub>3</sub>) du 4.4/3 :

$$\begin{aligned}
\log L_3 &= \log \binom{l}{k} + k [\log 2 + \log p - \log (1+p)] \\
&\quad + [\log (1-p) - \log (1+p)] (l-k) \\
\frac{\partial^2 \log L_3}{\partial p^2} &= k \left[ -\frac{1}{p^2} + \frac{1}{(1+p)^2} \right] + (l-k) \left[ \frac{1}{(1-p)^2} + \frac{1}{(1+p)^2} \right] \\
I'(M_3) &= \frac{2lp}{1+p} \left[ \frac{1}{p^2} - \frac{1}{(1+p)^2} \right] + l \frac{1-p}{1+p} \left[ \frac{1}{(1-p)} - \frac{1}{(1+p)^2} \right] \\
&= \frac{2l}{p(1-p)} \cdot \frac{1}{(1+p)^2}
\end{aligned}$$

A<sub>6</sub>. Calcul de I(P) du 3.8. :

On a :

$$\begin{aligned}
\log L &= \log \binom{n}{n_1, \dots, n_{2m}} + n_0 \log p^m + \left[ n_1 + n_2 + \dots + n_{\binom{m}{1}} \right] \\
&\quad \log p^{m-1} (1-p) + \dots + \left[ n_{k_1} + n_{k_2} + \dots + n_{k_{\binom{m}{k}}} \right] \log p^{m-k} (1-p)^k \\
&\quad \quad \quad + \dots + n_{2m} \log (1-p)^m \\
\frac{\partial \log L}{\partial p} &= \sum_{k=0}^m \left[ n_{k_1} + n_{k_2} + \dots + n_{k_{\binom{m}{k}}} \right] \left[ \frac{m-k}{p} - \frac{k}{1-p} \right] \\
\frac{\partial^2 (\log L)}{\partial p^2} &= \sum_{k=0}^m \left[ n_{k_1} + n_{k_2} + \dots + n_{k_{\binom{m}{k}}} \right] \left[ -\frac{m-k}{p^2} - \frac{k}{(1-p)^2} \right]
\end{aligned}$$

D'où

$$\begin{aligned}
 I(p) &= \sum_{k=1}^m n \binom{m}{k} p^{m-k} (1-p) \left[ \frac{m-k}{p^2} + \frac{k}{(1-p)^2} \right] \\
 &= n \left[ \frac{m - m(1-p)}{p^2} + \frac{m(1-p)}{(1-p)^2} \right] \\
 &= \frac{n \cdot m}{p(1-p)}
 \end{aligned}$$

#### A<sub>7</sub>. Démonstration de la proposition 3.10.

Considérons la loi de probabilité du § 3.8. On peut montrer, comme on l'a fait au § 2.3., que la loi conditionnelle de

$$(N_{2m}, \dots, N_2 / N_{2m} + \dots + N_2 = l)$$

est multinomiale, avec les paramètres

$$\left[ l ; \frac{(1-p)^m}{1-p^m}, \dots, \frac{p^{m-k}(1-p)}{1-p^m}, \dots, \frac{p^{m-1}(1-p)}{1-p^m} \right]$$

répétés  $\binom{m}{k}$  fois

On a :

$$\log L = \text{constante} + \sum (n_{k_1} + \dots + n_{\binom{m}{k}}) [(m-k) \log p + k \log (1-p)]$$

$$- l \log (1 - p^m)$$

$$\begin{aligned}
 \frac{\partial^2 \log L}{\partial p^2} &= \sum_{k=1}^m \left[ n_{k_1} + \dots + n_{\binom{m}{k}} \right] \left[ -\frac{m-k}{p^2} - \frac{k}{(1-p)^2} \right] \\
 &\quad + l \frac{m(m-1) p^{m-2} (1-p^m) + (m p^{m-1})^2}{(1-p^m)^2}
 \end{aligned}$$

D'où :

$$\begin{aligned}
 I(p) &= \sum_{k=1}^m l \frac{\binom{m}{k} p^{m-k} (1-p)^k}{1-p} \left[ \frac{m-k}{p^2} + \frac{k}{(1-p)^2} \right] \\
 &\quad - l \frac{m(m-1) p^{m-2} (1-p^m) + (m p^{m-1})^2}{(1-p^m)^2}
 \end{aligned}$$

$$\begin{aligned}
&= \left[ \frac{ml}{p} + \frac{ml}{1-p} \right] \cdot \frac{1}{1-p^m} - l \frac{m^2 p^{m-2} (1-p^m) + m^2 p^{2m-2}}{(1-p^m)^2} \\
&= \frac{ml}{p(1-p)} \cdot \frac{1}{(1-p^m)^2} [1-p^m - m p^{m-2} (p-p^2)] \\
&= \frac{ml}{p(1-p)} \cdot \frac{1}{(1-p^m)^2} [(1-p)(1+p+\dots+p^{m-1}) - m p^{m-1} + m p^m]
\end{aligned}$$