

# PRIORITÉS DE RAPPELS POUR NON-RÉPONSE TOTALE

## REVUE DE LA LITTÉRATURE ET SIMULATIONS

*Amandine RODRIGUES (\*)*,

*Benoît BUISSON (\*)*

*(\*) Insee, Direction régionale des Pays de la Loire*

### Introduction

La collecte d'informations sous la forme d'enquête s'opère dans un contexte de plus en plus contraint au niveau des moyens humains. Ce contexte implique que les contrôles doivent être de plus en plus ciblés et efficaces. Il existe une abondante littérature sur le sujet, notamment en ce qui concerne les macros-contrôles ou encore le selective editing. Ces notions sont désormais au cœur du processus de production des statistiques structurelles d'entreprises et constituent un des points saillants du projet de refonte des statistiques conjoncturelles. La littérature sur **les priorités de rappels**, suite à non-réponse totale, reste, quant à elle, moins abondante et plus récente. Elle s'inscrit elle aussi dans un contexte de moyens contraints - nécessité de cibler les relances téléphoniques des gestionnaires dans un temps court - et concerne plus particulièrement les enquêtes auprès des entreprises. Cela peut s'expliquer notamment par le fait que les unités interrogées ont des « tailles » très différentes avec des impacts très différenciés sur les résultats. Nous tenterons dans une première partie de faire **une revue de la littérature**, sans viser à l'exhaustivité, sur les priorités de rappels avant de laisser place aux **simulations** afin de comparer les méthodes entre elles.

### 1. Revue de la littérature

Dans la plupart des articles consultés, la méthode pour déterminer les priorités de rappel repose sur la même base. Il s'agit en premier lieu de définir **une fonction objectif**, avant de calculer **des scores individuels** (au niveau de chaque unité non répondante) relativement à cette fonction objectif. Ces scores servent à classer les entreprises non répondantes et donc à définir des priorités de rappel. Une fonction objectif est définie par rapport à une variable d'intérêt de l'enquête. Les priorités de rappel vont donc être définies par rapport à une variable jugée centrale de l'enquête. S'il s'avère nécessaire de tenir compte de plusieurs variables d'intérêt, il faudra combiner les différentes fonctions scores ou les différents rangs de priorité obtenus.

## 1.1. Erreur d'imputation

La fonction objectif la plus fréquemment utilisée semble être **la notion d'erreur d'imputation**. L'approche la plus complète dans ce cadre est celle développée par Richard McKenzie (Australian Bureau of Statistics) dans son article « A framework for priority contact of non respondents ». L'expression de l'erreur d'imputation est très détaillée et formalisée. La non-réponse est ici corrigée par imputation et non par pondération. L'erreur d'imputation est la somme pondérée par les poids de lancement, sur les unités non répondantes, de l'écart entre, d'une part, la valeur de la variable d'intérêt que l'on observerait si l'unité répondait et, d'autre part, la valeur que l'on imputerait pour cette même unité si elle restait non répondante. Il est très important de constater que cette somme est calculée après le processus de rappels ciblés<sup>1</sup>. L'objectif sera bien sûr de minimiser cette erreur d'imputation. Après quelques approximations et étapes de calcul, le score individuel à maximiser de chaque unité non répondante se définit de la manière suivante :

$$S_i = w_i |Y_i - Y_{i\{R\}}| * [\hat{p}_i \{C\} - \hat{p}_i \{NC\}]$$

w représente ici classiquement le poids, Y la valeur de la variable d'intérêt qui peut être soit constatée, soit estimée par imputation à partir des entreprises répondantes. Ce score fait également intervenir la probabilité de réponse des unités contactées suite au processus de rappel et la probabilité de réponse « spontanée » des unités non-contactées. Comme souvent, il est supposé que la probabilité de réponse est de 1 pour les unités appartenant au processus de rappel et de 0 pour celles qui ne font pas l'objet de rappel particulier. Pour définir des priorités de rappel, il est nécessaire de calculer ou plutôt **d'estimer l'erreur d'imputation pour chaque unité non répondante**. Comme dans beaucoup d'autres cas, l'exemple d'application fourni par Richard McKenzie concerne une enquête récurrente de type conjoncturel. Les non répondants chroniques et les entrants dans le dispositif d'enquête font l'objet d'une procédure spécifique. Pour les autres unités, l'erreur d'imputation est estimée à partir de celle calculée sur une précédente vague : comparaison de la valeur fournie par l'unité et de la valeur que l'on aurait imputée avec le modèle utilisé pour l'enquête en question (l'erreur d'imputation est supposée constante d'une vague à l'autre). Dans cet article, il est estimé une valeur du score individuel  $S_i$  pour les unités non répondantes (le taux de réponse avant processus de relance est de 82,5 %). L'étude de la distribution des  $S_i$  permet de répartir les unités non-répondantes selon les déciles de cette distribution. Il est montré dans l'article qu'il suffit de relancer les unités des déciles 7 à 10 pour que l'estimateur du chiffre d'affaires soit très proche de sa « valeur finale » (écart de 0,13 % pour l'Australie et un écart maximum de 0,43 % par région). Cette approche, avec cette fonction score, est reprise par Yves Berger (2009) et par Gareth James de l'Office for National Statistics.

---

<sup>1</sup> Pour une formalisation complète, voir l'encadré page suivante et se référer à l'article mentionné dans la bibliographie.

## Encadré 1 : formalisation de l'erreur d'imputation

### Approche développée par Richard MacKenzie, Australian Bureau of Statistics

**Notations :**

S : unités échantillonnées  
R : unités répondantes avant le processus de rappel ciblé  
NR : unités non répondantes avant le processus de rappel ciblé  
C : unités non répondantes qui seront contactées lors du processus de rappel ciblé  
NC : unités non répondantes et non contactées lors du processus de rappel ciblé  
CR : unités contactées lors du rappel et répondantes suite à ce rappel  
CNR : unités contactées lors du rappel et non répondantes suite à ce rappel  
NCR : unités non contactées lors du rappel mais répondantes spontanément suite à ce rappel  
NCNR : unités non contactées lors du rappel et qui vont rester non répondantes  
 $F_i$  : variable indicatrice déterministe qui vaut 1 pour les unités qui reçoivent le rappel (0 dans le cas contraire)  
 $w_i$  : poids de l'unité au lancement

$Y_i^\Omega$  : variable aléatoire représentant la donnée utilisée lors du processus d'imputation, avant le processus de rappel ciblé :

$$Y_i^\Omega = \begin{cases} Y_i & \text{si l'unité est répondante} \\ Y_{i\{R\}} & \text{si l'unité n'est pas répondante (donnée imputée à partir des répondants)} \end{cases}$$

$Y_i^\Psi$  : variable aléatoire représentant la donnée utilisée lors du processus d'imputation, après le processus de rappel ciblé :

$$Y_i^\Psi = \begin{cases} Y_i & \text{si l'unité est répondante} \\ Y_{i\{R \cup CR \cup NCR\}} & \text{si l'unité n'est pas répondante (donnée imputée à partir des répondants après le rappel)} \end{cases}$$

$\Gamma_i$  : variable indicatrice aléatoire indiquant si l'unité est répondante ou non

$\Gamma_i\{C\}$  : variable qui vaut 1 pour les unités répondantes contactées lors du rappel

$p_i\{C\}$  : probabilité de réponse pour les unités contactées lors du rappel

$\Gamma_i\{NC\}$  : variable qui vaut 1 pour les unités répondantes non contactées par le rappel

$p_i\{NC\}$  : probabilité de réponse pour les unités non contactées lors du rappel

L'erreur d'imputation après la procédure de rappel peut donc s'exprimer de la façon suivante :

$$\begin{aligned} & \left| \sum_{i \in NR} w_i \times (Y_i - Y_i^\Psi) \right| \\ &= \left| \sum_{i \in NR} w_i \times F_i \left[ \Gamma_i\{C\} (Y_i - Y_i) + (1 - \Gamma_i\{C\}) (Y_i - Y_{i\{R \cup CR \cup NCR\}}) \right] + \sum_{i \in NR} w_i \times (1 - F_i) \left[ \Gamma_i\{NC\} (Y_i - Y_i) + (1 - \Gamma_i\{NC\}) (Y_i - Y_{i\{R \cup CR \cup NCR\}}) \right] \right| \\ &= \left| \sum_{i \in NR} w_i \times [Y_i - Y_{i\{R \cup CR \cup NCR\}}] \times [F_i (1 - \Gamma_i\{C\}) + (1 - F_i) (1 - \Gamma_i\{NC\})] \right| \end{aligned}$$

Nous pouvons simplement écrire :  $(Y_i - Y_{i\{R \cup CR \cup NCR\}}) = (Y_i - Y_{i\{R\}}) + (Y_{i\{R\}} - Y_{i\{R \cup CR \cup NCR\}})$ . Nous pouvons raisonnablement supposer que le second terme de cette somme est négligeable devant le premier. Cette hypothèse pourrait être remise en question en tout début de collecte. Toutefois, ce n'est pas à ce stade que le processus de relances personnalisées apparaît le plus pertinent. Sous cette hypothèse, l'objectif revient donc à minimiser l'erreur d'imputation suivante :

$$\begin{aligned} & \left| \sum_{i \in NR} w_i \times [Y_i - Y_{i\{R\}}] \times [F_i (1 - \Gamma_i\{C\}) + (1 - F_i) (1 - \Gamma_i\{NC\})] \right| \\ &= \left| \sum_{i \in NR} w_i \times [Y_i - Y_{i\{R\}}] \times [(1 - \Gamma_i\{NC\}) - F_i (\Gamma_i\{C\} - \Gamma_i\{NC\})] \right| \\ &= \sum_{i \in NR} w_i \times [Y_i - Y_{i\{R\}}] \times (1 - \Gamma_i\{NC\}) - \sum_{i \in NR} w_i [Y_i - Y_{i\{R\}}] \times F_i \times (\Gamma_i\{C\} - \Gamma_i\{NC\}) \end{aligned}$$

Le passage à la dernière expression vient de l'application de l'inégalité triangulaire. Nous cherchons à minimiser cette dernière expression. Nous pouvons assez facilement « admettre » que minimiser cette expression revient à maximiser le deuxième terme. C'est notamment le cas lorsque l'on suppose que la probabilité de réponse est nulle pour les unités non contactées par la

procédure de rappel. Il faut donc maximiser la fonction objectif suivante :  $\sum_{i \in NR} w_i [Y_i - Y_{i\{R\}}] \times F_i \times (\Gamma_i\{C\} - \Gamma_i\{NC\})$

À partir de cette fonction objectif, nous pouvons définir une fonction de score individuel pour les unités à relancer selon un processus personnalisé :  $S_i = w_i [Y_i - Y_{i\{R\}}] \times (\Gamma_i\{C\} - \Gamma_i\{NC\})$

Nous devons donc maximiser la fonction suivante  $B = \sum_{i \in NR} F_i S_i$

En estimant la fonction score par  $\hat{S}_i = w_i [Y_i - Y_{i\{R\}}] \times [\hat{p}_i\{C\} - \hat{p}_i\{NC\}]$  nous pouvons de fait choisir les unités à relancer qui maximisent cette fonction.

## 1.2. Erreur d'imputation et agrégat de type chiffre d'affaires

Gareth James propose plusieurs estimateurs possibles pour l'erreur d'imputation au niveau individuel. Il reprend l'idée d'une mesure de cette erreur d'imputation lors d'une précédente vague, mais teste également l'utilisation du **chiffre d'affaires comme proxy de l'erreur d'imputation**. À partir d'une simulation, il montre notamment que cela fonctionne relativement bien. Cette idée est intéressante puisqu'elle permet de rapprocher les méthodes de priorités de rappels basées sur l'utilisation du chiffre d'affaires (ou d'une autre grandeur liée à la variable d'intérêt) de la méthode basée sur la minimisation de l'erreur d'imputation. Les priorités de rappels établies à partir des chiffres d'affaires sont notamment utilisées à Statistics Canada. Ces méthodes sont exposées par Pierre Daoust (2006) et par Hansheng Xie ; Serge Godbout ; Sungjin Youn et Pierre Lavallée (2009). **La fonction objectif est ici le rapport, pondéré, entre le chiffre d'affaires des unités répondantes du champ et le chiffre d'affaires des unités enquêtées du champ**. L'idée est bien sûr de maximiser ce rapport (taux de couverture) suite au processus de rappels. Le score individuel, associé à chaque entreprise non répondante, est le rapport entre le chiffre d'affaires pondéré (par le poids de lancement) de l'unité potentiellement à relancer et la somme pondérée, sur les entreprises de l'échantillon et dans le champ, des chiffres d'affaires. Nous pourrions utiliser une autre grandeur macro-économique que le chiffre d'affaires, il s'agit toutefois de choisir une variable externe à l'enquête et donc différente de la variable d'intérêt. Dans cette approche, il est à noter que cette variable externe est également celle qui sera utilisée comme variable auxiliaire pour la recherche d'un donneur, dans le cadre de la correction de la non-réponse en fin de processus. Un point intéressant est à signaler dans cette méthode : le score ainsi défini peut être modifié par un facteur correctif qui tient compte du nombre de contacts (rappels) déjà effectués auprès de l'unité en question. L'idée sous-jacente est sans doute de ne pas passer trop de temps sur les unités qui ont déjà été relancées plusieurs fois et pour lesquelles la probabilité de réponse apparaît faible. Cela revient à définir un nombre maximum de relances admissible et de faire diminuer proportionnellement la fonction score initiale, tant que le nombre admissible de relances n'est pas atteint<sup>2</sup>.

Des simulations ont été menées pour juger de la pertinence de cette méthode par des techniques proches du bootstrap. Pour juger de la pertinence d'une méthode, l'écart moyen à l'estimateur cible et la dispersion des écarts à la moyenne sont analysés. Les résultats sont de deux ordres. D'une part, la méthode est d'autant plus efficace que la variable externe qui sert à définir le score individuel (chiffre d'affaires par exemple) est corrélée à la variable d'intérêt. Ce résultat semble assez « intuitif », même s'il est possible que cela soit plutôt la corrélation entre l'agrégat et l'erreur d'imputation sur la variable cible qui prime. D'autre part, le fait d'introduire un facteur correctif (en lien avec le nombre de rappels) apparaît positif, notamment dans le cas où la corrélation est faible entre la variable externe et la variable d'intérêt.

---

<sup>2</sup> Si nous nous fixons 10 comme nombre de relances admissible, la fonction score initiale est multipliée par 9/10 pour les unités déjà relancées une fois, 8/10 pour les unités relancées deux fois...

### 1.3. Méthode utilisée pour l'enquête TIC

Lors de la précédente édition des journées de méthodologie statistique, nous avons développé la méthode de priorité de rappels mise en place pour l'enquête sur les technologies de l'information et de la communication (TIC). Cette méthode est reprise dans l'encadré 2. **La fonction objectif est ici la distance entre l'estimateur cible, calculé avec 100% de répondants, et l'estimateur avec non-réponse suite au processus ciblé de relance d'une unité.** L'idée générale est bien sûr de minimiser cette distance. La correction de la non-réponse totale s'effectue dans ce cadre par repondération, contrairement aux autres approches détaillées précédemment. Dans l'article que nous avons présenté, nous arrivons à la fonction du score individuel suivante :

$$\frac{n_s}{r_s + 1} \left[ \left( \frac{1}{r_s} \sum_{rep} w_i Y_i \right) - w_{rel} Y^{rel} \right].$$

Nous nous situons ici dans la strate (au sens de la correction de la non-réponse, donc du groupe de réponse homogène)  $s$  de l'unité à relancer,  $n$  représente le nombre d'unités échantillonnées,  $r$  le nombre d'unités répondantes,  $w$  le poids de lancement, l'indice rel est relatif à l'unité à relancer pour non-réponse totale. L'unité qui maximise ce score est à relancer en priorité dans cette optique. En toute rigueur, il devrait s'agir de l'unité qui enregistre la fonction score la plus élevée tout en respectant **la contrainte** naturelle suivante : l'estimateur après rappel (et réponse) de l'unité en question doit être plus proche de la cible que l'estimateur avant le rappel de cette unité. Même si elle apparaît naturelle, la contrainte peut poser difficulté car elle fait intervenir l'estimateur avec 100 % de réponse, non connu en cours d'enquête. Nous reviendrons sur ce point lors des simulations menées. Comme les approches basées sur l'erreur d'imputation, la fonction score fait intervenir la valeur de la variable d'intérêt pour l'unité à relancer, non connue avant le rappel téléphonique. Il est nécessaire d'estimer la variable d'intérêt pour les unités à relancer : nous pouvons utiliser pour cela la valeur de cette même variable sur une enquête précédente.

### 1.4. Expression du biais

Les approches précédentes semblent assez similaires et peuvent être classées dans une méthode globale de minimisation de l'écart entre estimateur avec non-réponse suite à relance et l'estimateur cible avec 100 % de réponse. Yves Berger, de l'Université de Southampton, a présenté une approche similaire lors d'un congrès à Neuchâtel en juin 2009. L'idée générale est ici de repartir de **l'expression du biais** lorsque la non-réponse est corrigée par repondération :

$$\text{Biais} = \sum_{c=1}^C \sum_{i \in s_c} w_i (y_i - \bar{y}_c) \frac{(p_i - \bar{p}_c)}{p_c}.$$

La probabilité de réponse est notée  $p$  (indiquée par  $i$  pour les unités à relancer, par  $c$  pour la moyenne pondérée des probabilités de réponse dans le groupe de réponse homogène  $c$ ). L'idée développée ici est de choisir les unités non répondantes qui maximisent

$$\text{le score individuel } w_i (y_i - \bar{y}_c) \frac{(p_i - \bar{p}_c)}{p_c}.$$

Les unités qui appartiennent à un groupe de réponse homogène avec une faible probabilité de réponse moyenne pondérée seraient donc notamment à privilégier.

## Encadré 2 : méthode de priorités de rappels utilisée dans le cadre de l'enquête TIC

Soit  $Y$ , la variable d'intérêt, quantitative. En absence de non-réponse, nous obtenons  $Y_1$  comme estimateur de  $Y$ . En présence de non-réponse, avant les opérations de relances téléphoniques ciblées, nous obtenons  $Y_2$  comme estimateur de  $Y$ . Cet estimateur tient compte de la correction de la non-réponse, que nous supposons faite par repondération (les strates utilisées pour la correction de la non-réponse ne sont pas définies *a priori*). En présence de non-réponse et après une relance téléphonique ciblée sur une entreprise (relance que nous supposons aboutir avec une probabilité de 1), nous obtenons  $Y_2^R$  comme estimateur de  $Y$ . Nous supposons également que les unités qui n'ont pas été relancées n'ont pas répondu.

Nous pouvons considérer que nous choisissons de **relancer l'entreprise qui minimise la distance**  $F_R = (Y_2^R - Y_1)^2$ . Posons :  $F_2 = (Y_2 - Y_1)^2$ , nous faisons de plus l'hypothèse que la valeur absolue de l'écart entre  $Y_2$  et  $Y_1$  est plus grande que la valeur absolue de l'écart entre  $Y_2$  et  $Y_2^R$ . Cette hypothèse semble peu contraignante, elle pose éventuellement problème en tout début de collecte et en toute fin de collecte. Toutefois, ce n'est pas lors de ces phases que la notion de « priorités de rappels » est cruciale. Du fait de cette hypothèse, minimiser la distance  $F_R$  revient à maximiser la grandeur  $(Y_2 - Y_2^R)^2$  sous la contrainte que  $F_2 - F_R > 0$ . Il faut donc s'éloigner le plus possible de  $Y_2$  tout en se rapprochant de  $Y_1$  (une analyse graphique est immédiate). **La contrainte**

**pose problème** car elle fait intervenir  $Y_1$ , grandeur inconnue et qui peut être difficile à estimer. Comment faire dès lors pour vérifier la condition qui porte sur la contrainte ? Dans le cas d'une enquête répétitive, nous pouvons utiliser l'estimation de  $Y$  de l'enquête précédente. Cela peut servir de garde-fou à condition que cette estimation soit fiable. Or, dans certains cas, les priorités de relance sont justement définies dans le but d'améliorer une estimation que nous supposons fragile. Autre possibilité : choisir une variable auxiliaire que nous savons liée à la variable d'intérêt et pour laquelle nous disposons d'une estimation fiable ou mieux de sa « vraie » valeur sur la population. Il est important de disposer d'un garde-fou en la matière pour une raison simple : nous allons choisir de relancer l'entreprise qui fait le plus varier l'estimateur. Il faut donc s'assurer que cette variation s'effectue dans le « bon » sens !

**Nous souhaitons donc maximiser la valeur absolue de**  $(Y_2 - Y_2^R)$  sous contrainte. Nous avons :

$$Y_2 = \sum_{rep} w_i^* Y_i = \sum_{rep} \sum_{strate} w_i^* Y_i \quad \text{et} \quad Y_2^R = \sum_{rep+lstrate} w_i^{**} Y_i$$

Ici les strates font référence aux strates de correction de la non-réponse - ou groupes de réponse homogènes. Pour calculer la différence  $(Y_2 - Y_2^R)$ , il faut bien voir que cette différence est nulle sur toutes les strates qui ne contiennent pas l'unité à relancer. En effet, dans ces strates, les répondants sont les mêmes avant et après relance, tout comme les poids. La différence est donc nulle.

Soit la strate  $s$  qui contient l'unité à relancer, nous avons :

$$(Y_2 - Y_2^R) = \sum_{rep} w_i^* Y_i - \sum_{rep+l} w_i^{**} Y_i = -w_{rel}^{**} Y^{rel} + \sum_{rep} Y_i (w_i^* - w_i^{**}) ; \text{ avec}$$

$$w_i^* = w_i * \frac{n_s}{r_s}$$

$$w_i^{**} = w_i * \frac{n_s}{r_s + 1}$$

$r_s$  désigne le nombre de répondants dans la strate (GRH) de l'unité à relancer ;  $n_s$  le nombre d'unités échantillonnées dans cette même strate ;  $w_{rel}$  le poids initial de l'unité à relancer.

On obtient ainsi :

$$(Y_2 - Y_2^R) = -w_{rel} \frac{n_s}{r_s + 1} Y^{rel} + \frac{n_s}{r_s (r_s + 1)} \sum_{rep} w_i Y_i = \frac{n_s}{r_s + 1} \left[ \left( \frac{1}{r_s} \sum_{rep} w_i Y_i \right) - w_{rel} Y^{rel} \right] \quad (A)$$

Il faut bien voir ici qu'au moment de cibler la relance téléphonique,  $Y^{rel}$  est inconnue. **Il faut donc pour établir les priorités de relance estimer  $Y$  sur les unités non répondantes.** Dans le cas d'une enquête répétitive, nous pouvons estimer  $Y$  pour les unités à relancer à partir de la réponse à la précédente enquête (si l'unité était répondante à la précédente enquête).

Toutefois, à ce stade de notre réflexion il ne nous apparaît pas évident de voir comment évolue l'estimation du biais après relance d'une unité. Si l'estimation du biais reste inchangée après le processus de relance, choisir les unités à relancer en fonction du score individuel défini précédemment n'apparaît pas complètement évident. Ou alors, est-il nécessaire d'actualiser le modèle de correction de la non-réponse pour l'estimation des probabilités de réponse par exemple ? Nous mentionnons cette méthode ici, notamment du fait qu'elle fournit un prolongement intéressant à celles déjà mentionnées, sans toutefois la tester dans les simulations ultérieures.

### 1.5. La variance à gagner

La dernière approche que nous avons retenue dans la littérature est celle de la **variance à gagner**, définie par Philippe Brion, et que nous avons également exposée lors de la précédente édition des journées de méthodologie statistique. Cette approche est différente de celles exposées jusqu'à maintenant. L'objectif est ici de **cibler les relances sur les strates pour lesquelles on s'attend à une forte réduction de la variance entre la situation actuelle en cours de collecte et la situation**

**idéale sans non-réponse**. Si  $x_h = \frac{r_h}{n_h}$  est le taux de questionnaires utilisés dans la strate  $h$ , on a

une perte de variance de :  $\Delta V_h = \frac{N_h^2 S_h^2}{n_h} \left( \frac{1}{x_h} - 1 \right)$  dans le cas où on procéderait par repondération.

Cette méthode est détaillée dans l'encadré 3, page suivante. Afin d'établir des priorités de relance, on peut regarder la part de la perte de variance anticipée due à chaque strate par l'intermédiaire des différentes grandeurs  $\Delta V_h$  : ceci donne des indications sur les priorités à donner dans le traitement des différentes strates (il faut se consacrer d'abord aux strates pour lesquelles  $\Delta V_h$  est la plus importante). Nous pouvons donc obtenir un ordre de priorité pour chaque strate, selon les strates de tirage. Il reste à choisir, au sein d'une strate donnée, les entreprises à relancer. Il faut également interclasser les strates. Pour cela, nous pouvons faire l'hypothèse simplificatrice que la probabilité de réponse suite à relance téléphonique est de 1, et réitérer les calculs. **Cette approche complète et va plus loin que l'approche, souvent appliquée, qui consiste à relancer en priorité les strates avec un taux de réponse faible**, notamment du fait qu'elle prend en compte la dispersion de la variable d'intérêt au sein de la strate. Cette approche est notamment utilisée dans le cadre des extensions régionales à l'enquête innovation (CIS08 et CIS10).

### Encadré 3 : priorités de rappels suivant la méthode « variance à gagner »

L'approche de « la perte de variance anticipée » a été développée par Philippe BRION. Nous reprenons ci-dessous une note de Philippe BRION (cf. Bibliographie) parue en 2003 sur le sujet. L'idée est de cibler les relances sur les strates, pour lesquelles on s'attend à une forte réduction de la variance entre la situation actuelle en cours de collecte et la situation idéale sans non-réponse.

Pour un sondage aléatoire simple stratifié (ce qui est le cas de beaucoup d'enquêtes auprès des entreprises), la variance de l'estimation d'un total d'une variable Y vaut :

$$V(\hat{T}(Y)) = \sum_{h=1}^k N_h^2 \left(1 - \frac{n_h}{N_h}\right) S_h^2$$

Où  $h$  est l'indice de strate ;  $N_h$  est le nombre d'entreprises de la strate  $h$  ;  $n_h$  est le nombre d'entreprises échantillonnées dans la strate  $h$  ;  $S_h^2$  est la dispersion de la variable Y au sein de la strate  $h$ .

Si dans la strate  $h$  on n'a récupéré que  $r_h$  questionnaires au lieu des  $n_h$  attendus, on peut procéder à de la répondération : on montre que si l'on répond de manière uniforme à l'intérieur de chaque strate de tirage et conditionnellement à l'hypothèse que les non répondants n'ont rien de spécifique à l'intérieur de chaque strate, la variance

de l'estimation du total, pour sa partie relative à la strate  $h$ , devient  $V_h(\hat{T}(Y)) = N_h^2 \left(1 - \frac{r_h}{N_h}\right) \frac{1}{r_h} S_h^2$

Si  $x_h = \frac{r_h}{n_h}$  est le taux de questionnaires utilisés dans la strate  $h$ , on a donc une perte de variance de :

$\Delta V_h = \frac{N_h^2 S_h^2}{n_h} \left(\frac{1}{x_h} - 1\right)$  dans le cas où on procéderait par répondération. On peut ainsi calculer, pour chaque

variable d'intérêt (une variable d'intérêt pouvant être relative à un sous-champ), la quantité :

$$\sum_h \Delta V_h / V(\hat{T}(Y))$$

Où  $V(\hat{T}(Y))$  est la variance attendue avec, dans chaque strate, les  $n_h$  questionnaires enquêtés ; **la quantité calculée est la « perte de variance anticipée »**. Au fur et à mesure que l'enquête se déroule, elle diminue (pour arriver à zéro si on pouvait récupérer et traiter l'ensemble des questionnaires).

En regard de cette rapide revue de littérature sur les priorités de rappels pour non-réponse totale, nous avons choisi de tester les méthodes suivantes dans le cas des simulations :

- l'approche basée sur les chiffres d'affaires qui vise à maximiser le taux de couverture du chiffre d'affaires ;
- l'approche déjà mise en place pour définir des priorités de relances dans l'enquête TIC, sans tenir compte de la contrainte ;
- cette même approche en tenant compte de la contrainte ;
- l'approche « variance à gagner ».

## 2. Les simulations

### 2.1. Présentation de l'enquête TIC

Les simulations, afin de pouvoir porter un jugement sur l'efficacité des méthodes de priorités de rappels, vont se baser sur l'enquête sur les **Technologies de l'Information et de la Communication** (TIC) auprès des entreprises. Nous prendrons comme référence l'enquête TIC réalisée en 2010 qui porte sur des données relatives à l'année 2009. L'enquête TIC, commanditée par Eurostat, vise à mieux connaître l'informatisation et la diffusion des technologies de l'information et de la communication dans les entreprises. Elle cherche notamment à apprécier la place des nouveaux outils dans les relations externes de l'entreprise (Internet, commerce électronique) et dans leur fonctionnement interne (réseaux, systèmes intégrés de gestion). Les thèmes abordés sont l'équipement en TIC, l'accès et usage d'Internet, le commerce électronique<sup>3</sup>. L'échantillon est stratifié par secteur d'activité et par tranche d'effectif salarié. Environ 13 000 entreprises sont interrogées. Cette enquête annuelle s'inscrit dans un programme de 5 ans, renouvelable. Depuis le début de cette enquête, les données sur le commerce électronique sont abondamment commentées et comparées à d'autres sources, plus partielles. Depuis plusieurs années, un des objectifs majeurs reste d'obtenir des indicateurs robustes dans ce domaine. Pour cette raison, nous prendrons comme variables cibles pour ces simulations **les ventes et les achats réalisés par voie électronique**. Nous avons complété ces variables cibles par deux autres variables également analysées lors de la publication annuelle des résultats : la part des entreprises disposant d'un site web, d'une part, et la part des entreprises réalisant des ventes par voie électronique, d'autre part.

Pour cette enquête, il a été décidé que les gestionnaires de l'enquête puissent faire, lors de la phase de collecte, **des rappels téléphoniques ciblés** auprès des entreprises non répondantes. Pour obtenir une liste de rappels prioritaires, distribuée à chaque gestionnaire, la méthode utilisée est celle décrite dans l'encadré 2 avec, toutefois, des aménagements. En premier lieu, il est défini une liste **d'entreprises dites non-substituables**, à rappeler en priorité, qui figureront donc automatiquement en tête de liste. Ces entreprises sont majoritairement des grandes entreprises ou des entreprises qui réalisent un fort montant de ventes ou d'achats électroniques. Plus précisément, les unités légales dites non-substituables ont un poids au lancement égal à l'unité et répondent au moins à un des critères ci-dessous :

- poids en termes de chiffre d'affaires supérieur à 10 % en regard de leur strate de diffusion ou chiffre d'affaires au lancement supérieur à 4 milliards d'euros ;
- poids en termes d'effectifs supérieur à 10 % en regard de leur strate de diffusion ou effectif au lancement supérieur à 10 000 ;
- poids en termes d'achats supérieurs à 15 % en regard de leur strate de diffusion ou achats supérieurs à 5 milliards d'euros ;
- ventes électroniques via un site web estimées à plus de 150 millions d'euros ;

---

<sup>3</sup> Pour obtenir plus d'informations sur l'enquête TIC auprès des entreprises : [la fiche descriptive de l'enquête](#) et [le questionnaire de TIC 2011](#).

- ventes électroniques estimées à plus de 600 millions d'euros ;
- achats électroniques estimés à plus de 600 millions d'euros.

En second lieu, nous appliquons la méthode définie dans l'encadré 2 en une seule fois et non pas complètement de manière dynamique. Théoriquement, la méthode décrite précédemment devrait nous fournir la première entreprise à rappeler, puis nous devrions l'appliquer de nouveau - en supposant que l'entreprise de rang 1 réponde et pas les autres entreprises - pour obtenir la deuxième entreprise à relancer et ainsi de suite. Pour des raisons pratiques, nous l'appliquons ici en une fois. Le pôle enquêtes entreprises de la direction régionale de l'Insee de Midi-Pyrénées, responsable de la collecte, définit le nombre d'entreprises à rappeler et la méthode fournit directement en une fois cette liste d'entreprises. À partir du moment où le taux de réponse de cette enquête atteint un seuil jugé « raisonnable » jusqu'à 75-80 %, une liste est fournie à chaque gestionnaire toutes les semaines. À partir de simulations, **nous voulons porter un jugement critique sur le choix de cette méthode** : est-elle la plus adaptée ? Faut-il tenir compte de la contrainte pour la rendre plus efficace ? Est-ce qu'il existe une méthode plus simple à mettre en place et qui fournirait des résultats proches ?

## 2.2. Situation de référence et estimateurs cibles

Le fichier redressé définitif de l'enquête TIC 2010 constituera le point de départ de ces simulations. Nous considérons que ce fichier redressé correspond au fichier de toutes les unités échantillonnées (pas de non-réponse donc). Les poids par strate de tirage ont été recalculés afin d'avoir des poids identiques au sein de chaque strate. C'est évidemment une situation fictive qui correspond à notre **situation de référence**. Les simulations sont réalisées à partir de ce fichier pour juger de l'efficacité de différentes méthodes de priorités de relances. Sur cette base « 100 % de réponse », nous avons calculé **des estimateurs et des estimations de variance d'estimateurs pour plusieurs variables cibles**. Pour ce faire, la macro SAS Calker mise au point par l'UMS-E a été utilisée, en supposant qu'il n'y avait pas de non-réponse dans le fichier. Ainsi, seule la variance due au sondage a été calculée. Comme déjà signalé, **deux variables quantitatives** ont été retenues : les ventes électroniques (WEB + EDI) et les achats électroniques (WEB + EDI). **Deux autres variables issues de questions qualitatives** ont également fait l'objet d'estimations : la part des entreprises disposant d'un site web et la part d'entreprises réalisant des ventes par voie électronique.

	Estimateur cible	Ecart-type cible
Achats électroniques	269 269 978,70	18 026 710,30
Ventes électroniques	396 347 886,20	47 378 528,10
Taux de sites	58,38 %	0,007
Taux de ventes	14,55 %	0,0048

Certaines entreprises sont très grandes et/ou très particulières par rapport aux thèmes traités - par exemple le secteur de la vente par correspondance pour le commerce électronique. Ces entreprises ont été qualifiées de « **non-substituables** ». Dans TIC 2010, elles sont au nombre de 176. En ce qui concerne les variables quantitatives que nous avons retenues, les « entreprises non-substituables » pèsent beaucoup sur le résultat final : à hauteur de 44 % pour les achats électroniques et de 32 % pour les ventes électroniques. Étant donné l'importance des « entreprises non-substituables », nous

considérons par la suite qu'elles sont toujours répondantes. Nous nous intéressons donc aux priorités de rappels sur les unités substituables ; les unités non-substituables étaient de fait toujours jugées prioritaires devant les autres.

### 2.3. Génération de la non-réponse totale

Afin de simuler la situation en cours de collecte, nous avons **généré sur le fichier de référence de la non-réponse totale**. Trois taux de non-réponse cible ont été définis : 40 % (début des opérations de relance), 30 % et 20 % (fin des opérations de relance). Pour chaque taux cible, la non-réponse totale a été générée par groupe de réponse homogène (GRH). On obtient donc 3 scénarios : 3 taux cibles et 1 mécanisme de génération de la non-réponse. Pour chaque scénario, 100 échantillons ont été générés. Pour générer la non-réponse, nous avons utilisé le logiciel **GENESIS** (General Simulation System) développé à Statistics Canada (Haziza, 2003) sous SAS. Le logiciel GENESIS est une interface ergonomique sous SAS, qui permet de simuler des échantillons selon des plans de sondages divers, calculer des estimateurs de totaux ou moyennes par les valeurs dilatées, par le ratio et par régression ainsi que des indicateurs Monte Carlo et éditer des graphiques qui permettent de comparer les différentes méthodes d'estimation. À l'origine, GENESIS a été développé pour des études de simulations en présence de non-réponse. Il est donc aussi particulièrement performant pour simuler de la non-réponse dans des données complètes et comparer les méthodes d'estimation dans ce cadre. GENESIS intègre de la non-réponse selon un mécanisme de génération de la non-réponse et un taux de non-réponse paramétrés. Pour simuler un mécanisme de non-réponse uniforme par GRH, nous avons utilisé les taux de réponse par GRH du fichier TIC 2010 définitif. Ces taux ont été ramenés, par une simple règle de trois, aux taux de non-réponse cibles, c'est-à-dire 20, 30 ou 40 % sur l'ensemble de l'échantillon. À l'issue de cette étape, nous avons obtenu 300 échantillons sur lesquels lancer l'exercice de simulation.

Une fois que la non-réponse a été générée, des estimateurs des variables cibles ont été calculés pour chaque scénario, en présence de non-réponse et sans corriger celle-ci. Voici les estimateurs moyens et les écarts-types moyens ainsi obtenus :

Taux de non-réponse (%)	Achats électroniques		Ventes électroniques		Taux de sites		Taux de ventes	
	Estimateur moyen	Écart-type moyen	Estimateur moyen	Écart-type moyen	Estimateur moyen	Écart-type moyen	Estimateur moyen	Écart-type moyen
20	218 181 586,1	13 725 004,3	323 473 330,5	19 034 025,7	58,52%	0,00387	18,18 %	0,0013
30	188 000 384,6	15 041 828,9	280 001 621,4	25 033 879,1	58,47%	0,00442	21,01 %	0,00206
40	162 905 561,7	15 746 068,9	246 127 790,3	27 791 339,4	58,55%	0,00601	24,16 %	0,00272
Cible	269 269 978,7	18 026 710,3	396 347 886,2	47 378 528,1	58,38%	0,007	14,55 %	0,0048

Les estimateurs ainsi obtenus sont d'autant plus loin de la cible que le taux de non-réponse est grand. En comparant avec la situation de référence, on en déduit l'importance de corriger la non-réponse. Sans correction de la non-réponse, les résultats sont très proches de la cible pour la part des entreprises disposant d'un site web. Dans la suite de cet article, **nous axerons nos simulations sur les ventes et achats électroniques**.

#### Encadré 4 : Détermination et composition des GRH dans l'enquête TIC 2010

La méthode de constitution des GRH consiste à bâtir un modèle explicatif du comportement de réponse, et à retenir les variables qui apparaissent significatives. Les variables retenues doivent être connues sur les répondants et sur les non répondants, ce qui exclut le recours aux questions de l'enquête.

Pour TIC 2010, les variables utilisées sont :

- le secteur d'activité ;
- la tranche d'effectif (effectif au lancement - variable « class\_effl2 ») ;
- la localisation du siège (à Paris ou non - variable « Paris ») ;
- le comportement de réponse à TIC 2009 (variable « tic09 »). Pour cela, une variable à trois modalités a été introduite, à savoir :
  - o entreprise non interrogée dans TIC 2009 (modalité « 0 ») ;
  - o entreprise répondante dans TIC 2009 (modalité « 2 ») ;
  - o entreprise non répondante ou hors-champ dans TIC 2009 (modalité « 1 »).

Les variables explicatives du comportement de réponse ont été choisies parmi des variables au lancement ; par ailleurs, les tests du khi-deux montrent clairement un lien entre les variables retenues, d'une part, et la variable indicatrice de réponse, d'autre part. Une procédure logistic a permis de confirmer le modèle et la sélection de ces variables, en raisonnant « toutes choses égales par ailleurs ». Le tableau suivant résume la composition des groupes de réponses homogènes.

GRH	Situation concernant TIC 2009	Localisation à Paris (départements 75, 92, 93)	Secteur d'activité	Tranche d'effectifs au lancement	Taille du GRH	Taux de réponse du GRH (en %)
1	Non interrogée	Non	Industrie manufacturière, Production et distribution d'électricité, de gaz, d'eau ; assainissement, gestion des déchets, dépollution, ...	0 à 19	236	80.08
2	Non interrogée	Non		20 à 249	914	86.00
3	Non interrogée	Non		250 et plus	234	87.18
4	Non interrogée	Non	Construction	Peu importe	613	81.73
5	Non interrogée	Non	Commerce, réparation d'automobiles et motocycles ; transports et entreposage ; hébergement restauration.	Peu importe	1549	79.28
6	Non interrogée	Non	Information et communication ; activités financières et d'assurance ; activités spécialisées, scientifiques et techniques.	Peu importe	472	79.66
7	Non interrogée	Non	Activités immobilières ; activités de services administratifs et soutien ; ...	Peu importe	427	77.99
8	Non interrogée	Oui	Peu importe	Peu importe	885	71.98
9	Interrogée, hors champ ou NRT	Peu importe	Industrie manufacturière, Production et distribution d'électricité, de gaz, d'eau ; assainissement, gestion des déchets, dépollution, ...	Peu importe	241	57.68
10	Interrogée, hors champ ou NRT	Peu importe	Construction	Peu importe	103	61.17
11	Interrogée, hors champ ou NRT	Peu importe	Commerce, réparation d'automobiles et motocycles ; transports et entreposage ; hébergement restauration.	Peu importe	411	54.01
12	Interrogée, hors champ ou NRT	Peu importe	Information et communication ; activités financières et d'assurance ; activités spécialisées, scientifiques et techniques.	Peu importe	174	55.75
13	Interrogée, hors champ ou NRT	Peu importe	Activités immobilières ; activités de services administratifs et soutien ; ...	Peu importe	80	33.75
14	Interrogée répondante	Non	Industrie manufacturière, Production et distribution d'électricité, de gaz, d'eau ; assainissement, gestion des déchets, dépollution, ...	Peu importe	1600	91.69
15	Interrogée répondante	Non	Construction	Peu importe	582	92.27
16	Interrogée répondante	Non	Commerce, réparation d'automobiles et motocycles ; transports et entreposage ; hébergement restauration.	Peu importe	1577	89.73
17	Interrogée répondante	Non	Information et communication.	Peu importe	115	89.57
18	Interrogée répondante	Non	Activités financières et d'assurance.	Peu importe	111	97.30
19	Interrogée répondante	Non	Activités spécialisées, scientifiques et techniques.	Peu importe	213	84.51
20	Interrogée répondante	Non	Activités immobilières ; activités de services administratifs et soutien ; ...	Peu importe	279	90.68
21	Interrogée répondante	Oui	Peu importe	Peu importe	1229	85.84

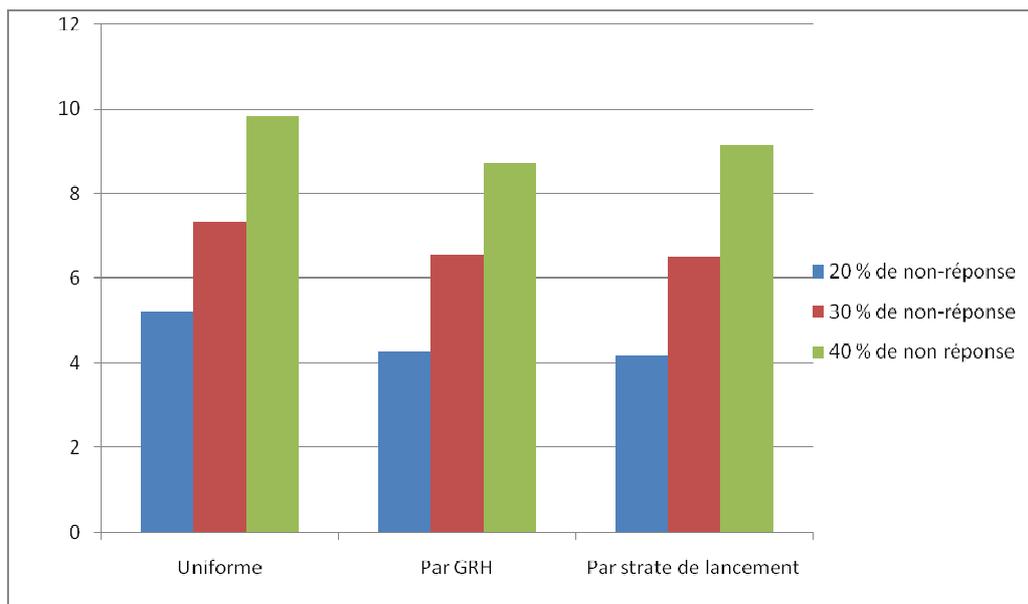
## 2.4. Correction de la non-réponse totale selon trois mécanismes

Par la suite, nous nous placerons toujours en cours de collecte et avec présence de non-réponse mais nous allons corriger la non-réponse par repondération selon **trois mécanismes distincts** : correction uniforme sur l'ensemble de l'échantillon, correction selon les GRH mis en évidence lors de l'enquête TIC, correction selon les strates de lancement. Dans les trois cas, nous appliquons une **méthode de repondération**. Un coefficient correcteur est appliqué au poids des entreprises répondantes d'un même couple échantillon-strates de correction de la non-réponse. Il est calculé selon la formule suivante :

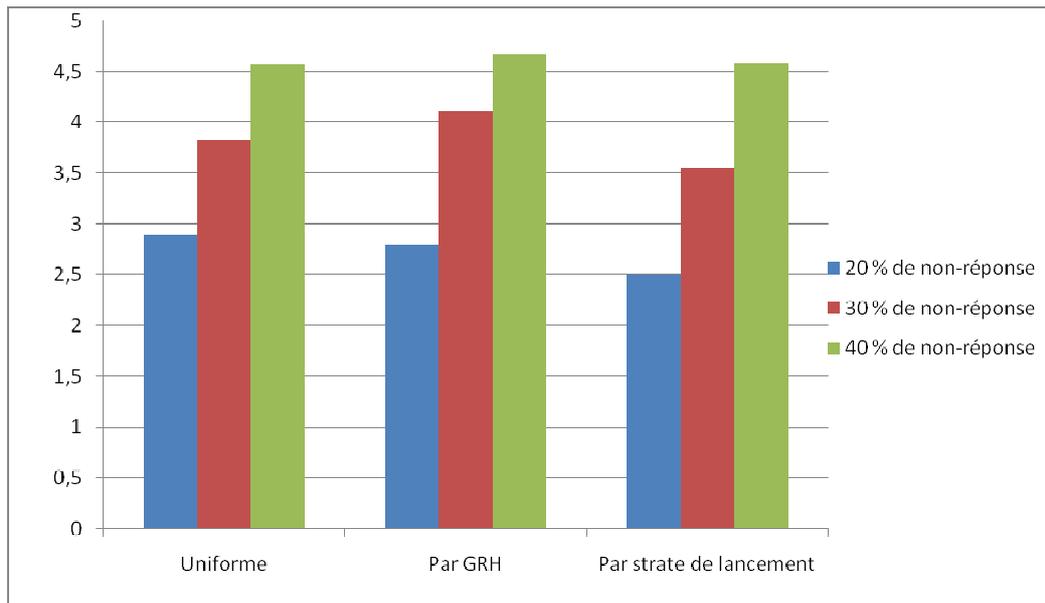
$$\text{Coefficient\_correcteur} = 1 + \frac{\sum \text{poids\_des\_entreprises\_non\_répondantes}}{\sum \text{poids\_des\_entreprises\_répondantes}}$$

Ce coefficient correcteur est appliqué au poids des entreprises répondantes et fournit un nouveau poids. Le poids des entreprises non répondantes est mis à zéro. **Les entreprises « non-substituables » sont traitées à part.** Étant donné leur impact sur les variables cibles, nous avons considéré que les entreprises « non-substituables » sont toujours répondantes à l'issue de l'enquête, un suivi particulier leur étant accordé au cours de l'enquête par les gestionnaires. Les entreprises « non-substituables » ne sont pas affectées par la repondération : elles conservent toutes leur poids d'origine qui est de 1. De nouveau, les estimateurs et leur variance estimée ont été calculés pour chaque échantillon. À partir de là, le calcul d'un estimateur moyen sur les 100 échantillons d'un scénario perd un peu de son intérêt car, après redressement de la non-réponse, l'estimateur moyen est assez proche de la cible. La dispersion reste pourtant assez importante. Dans un scénario donné et pour chaque échantillon, nous avons donc calculé **un écart absolu à la cible** de l'estimateur. La moyenne de ces écarts absolus à la cible est ensuite calculée pour chaque scénario.

**Graphique 1- Moyenne de l'écart absolu à la cible pour les ventes électroniques**



**Graphique 2 - Moyenne de l'écart absolu à la cible pour les achats électroniques**



Plus le taux de non-réponse augmente, plus la moyenne de l'écart absolu à la cible est importante, ce qui est en phase avec les résultats attendus. Pour les ventes, le redressement selon les GRH et les strates de lancement semble meilleur que le redressement uniforme. Pour les achats, le redressement selon les strates de lancement semble donner des résultats légèrement meilleurs.

Par la suite, nous testerons quatre méthodes de priorités de relance :

- l'approche basée sur les chiffres d'affaires qui vise à maximiser le taux de couverture du chiffre d'affaires ;
- l'approche déjà mise en place pour définir des priorités de relances dans l'enquête TIC, sans tenir compte de la contrainte ;
- cette même approche en tenant compte de la contrainte ;
- l'approche « variance à gagner ».

Pour chaque échantillon, on applique les quatre méthodes. Dans chacun des cas, on obtient les entreprises à relancer, par ordre de priorité décroissante. Deux cas de figure seront alors testés :

- on relance 300 entreprises ;
- on relance le nombre d'entreprises permettant de gagner 10 points de taux de réponse soient 1 010 entreprises.

On suppose que **chaque entreprise relancée devient répondante** (et que chaque unité non relancée reste non répondante). Une fois que les entreprises relancées sont devenues répondantes, les estimateurs sont calculés pour chaque échantillon. Enfin, pour juger de la qualité de chaque scénario, **la moyenne de l'écart absolu à la cible** est ensuite calculée.

## 2.5. Approche basée sur les chiffres d'affaires

Il s'agit ici de baser les priorités de relances sur le chiffre d'affaires. **Les entreprises relancées seront celles qui auront le plus grand chiffre d'affaires.** Dans un premier temps, nous relançons les 300 premières entreprises non répondantes qui ont le chiffre d'affaires le plus important. Les estimateurs et l'écart absolu à la cible sont calculés pour chaque échantillon. La moyenne de l'écart absolu à la cible est ensuite calculée et nous permet de juger de la qualité des résultats des différents scénarios.

Tableau sur les ventes électroniques, moyenne de l'écart absolu à la cible

Taux de non-réponse	Méthode de correction de la non-réponse					
	Uniforme		Par GRH		Par strate de lancement	
	sans relance	avec relances	sans relance	avec relances	sans relance	avec relances
20	5,22	3,67	4,26	2,92	4,17	2,32
30	7,33	6,06	6,56	4,80	6,50	3,81
40	9,83	9,68	8,73	8,63	9,16	8,50

Tableau sur les achats électroniques, moyenne de l'écart absolu à la cible

Taux de non-réponse	Méthode de correction de la non-réponse					
	Uniforme		Par GRH		Par strate de lancement	
	sans relance	avec relances	sans relance	avec relances	sans relance	avec relances
20	2,89	2,59	2,79	2,63	2,50	2,28
30	3,82	3,49	4,11	3,77	3,55	3,32
40	4,57	4,29	4,67	4,33	4,58	4,33

Relancer 300 entreprises selon l'importance de leur chiffre d'affaires fait **diminuer la moyenne de l'écart absolu à la cible**. C'est cependant peu marqué pour les achats électroniques, **la corrélation** entre chiffre d'affaires et achats électroniques étant moins forte que celle entre chiffre d'affaires et ventes électroniques. Plus le taux de non-réponse initial est grand, moins le rapprochement à la cible est marqué pour les ventes. De plus, le redressement de la non-réponse selon les strates de lancement semble donner de meilleurs résultats que le redressement uniforme ou par GRH.

Dans un deuxième temps, on relance le nombre d'entreprises ayant le plus gros chiffre d'affaires nécessaire pour gagner 10 points de taux de réponse. Si le taux de réponse vaut  $x$  au départ, après relance il vaudra  $x-10$ . La nouvelle situation pourra être comparée à la situation sans relance (mais corrigée de la non-réponse) avec un taux de non-réponse à  $x$  mais aussi à  $x-10$ .

Tableau sur les ventes électroniques, moyenne de l'écart absolu à la cible

Taux de non-réponse	Méthode de correction de la non-réponse					
	Uniforme		Par GRH		Par strate de lancement	
	sans relance	avec relances	sans relance	avec relances	sans relance	avec relances
20	5,22		4,26		4,17	
30	7,33	2,99	6,56	2,59	6,50	2,25
40	9,83	5,45	8,73	4,82	9,16	4,50

Tableau sur les achats électroniques, moyenne de l'écart absolu à la cible

Taux de non-réponse	Méthode de correction de la non-réponse					
	Uniforme		Par GRH		Par strate de lancement	
	sans relance	avec relances	sans relance	avec relances	sans relance	avec relances
20	2,89		2,79		2,50	
30	3,82	3,21	4,11	3,67	3,55	3,50
40	4,57	4,05	4,67	4,21	4,58	4,29

Relancer 1 010 entreprises pour gagner 10 points de taux de réponse semble diminuer la moyenne de l'écart absolu à la cible, surtout pour les ventes électroniques et pour le redressement uniforme.

Pour les ventes électroniques, nous améliorons le résultat par rapport à la situation sans relance avec un taux de non-réponse de x-10. Ce n'est pas le cas pour les achats. Ici encore, la corrélation entre le chiffre d'affaires et la variable d'intérêt impacte les résultats.

## 2.6. Approche enquête TIC sans contrainte

Cette méthode se base sur l'approche mise en place pour définir des priorités de relances dans l'enquête TIC. Comme déjà signalé, la méthode développée ici aurait pu être plus « **dynamique** » avec des hypothèses « fortes ». En effet, dans les simulations réalisées ici, seules les entreprises relancées deviennent répondantes et les autres restent non répondantes. Cette hypothèse ne cadre pas avec la réalité où des listes d'entreprises à relancer sont éditées chaque semaine pour les gestionnaires et où la mise à jour se fait d'elle-même en prenant en compte les nouvelles répondantes, qu'elles aient été relancées ou non. Dans le cadre de ces simulations, nous sommes donc restés sur une approche plus « **statique** » afin de mimer la situation réelle. Comme déjà vu, la liste de priorités est éditée en une fois, comme cela se pratique durant la phase de collecte. On calcule donc pour chaque entreprise non répondante et « substituable » un rang de priorité pour les ventes, *priorité\_vente*, et un rang de priorité pour les achats, *priorité\_achat*, comme suit<sup>4</sup> :

$$priorité\_vente = \left| \frac{champ}{réponse + 1} \times \left( \frac{vente_{elecst}}{réponse} - poids\_corr \times vente \right) \right|$$

$$priorité\_achat = \left| \frac{champ}{réponse + 1} \times \left( \frac{achatelecst}{réponse} - poids\_corr \times achat \right) \right|$$

Où *champ* est le nombre d'entreprises dans l'échantillon et dans le champ de l'enquête,

*réponse* est le nombre de répondants dans l'échantillon,

*vente<sub>elecst</sub>* est le montant des ventes électroniques par échantillon dans le cas d'un redressement uniforme, le montant des ventes électroniques par échantillon et GRH dans le cas d'un redressement par GRH, le montant des ventes électroniques par échantillon et strate de lancement dans le cas d'un redressement par strate de lancement,

*achatelecst* est le montant des achats électroniques par échantillon dans le cas d'un redressement uniforme, le montant des achats électroniques par échantillon et GRH dans le cas d'un redressement

<sup>4</sup> Voir l'encadré 2 pour plus de détails.

par GRH, le montant des achats électroniques par échantillon et strate de lancement dans le cas d'un redressement par strate de lancement,

*poids\_corr* est le poids, recalculé au début des travaux de simulations, attribué à l'entreprise pour laquelle on calcule un rang de priorité de relance,

*vente* est le montant des ventes électroniques de l'entreprise non répondante pour laquelle on calcule un rang de priorité de relance,

*achat* est le montant des achats électroniques de l'entreprise non répondante pour laquelle on calcule un rang de priorité de relance.

Une fois ces rangs de priorité calculés, nous pouvons procéder à un **classement mixte** ventes/achats et effectuer les relances en suivant ce classement. Pour ce faire, nous calculons deux rangs :

- le premier, rang1, est le minimum entre priorité\_vente et priorité\_achat ;
- le second, rang2, est le maximum entre ces deux même valeurs.

Pour classer la liste des entreprises selon la priorité à les relancer, il suffit de faire un tri croissant sur rang1 puis croissant sur rang2.

Alternativement, nous pouvons effectuer un **classement dissocié** : l'un pour les ventes nous fournissant des entreprises à relancer lorsque la variable d'intérêt est la variable ventes électroniques, l'autre pour les achats nous fournissant des entreprises à relancer lorsque la variable d'intérêt est la variable achats électroniques.

#### Les résultats obtenus avec un classement mixte

Dans un premier temps, nous considérons le cas où la relance porte sur les 300 premières entreprises non-répondantes fournies par le classement mixte ventes/achats.

Tableau sur les ventes électroniques, moyenne de l'écart absolu à la cible

Taux de non-réponse	Méthode de correction de la non-réponse					
	Uniforme		Par GRH		Par strate de lancement	
	sans relance	avec relances	sans relance	avec relances	sans relance	avec relances
20	5,22	12,91	4,26	10,18	4,17	4,22
30	7,33	24,67	6,56	21,58	6,50	9,83
40	9,83	36,54	8,73	32,06	9,16	16,14

Tableau sur les achats électroniques, moyenne de l'écart absolu à la cible

Taux de non-réponse	Méthode de correction de la non-réponse					
	Uniforme		Par GRH		Par strate de lancement	
	sans relance	avec relances	sans relance	avec relances	sans relance	avec relances
20	2,89	10,73	2,79	8,61	2,50	3,45
30	3,82	20,74	4,11	18,49	3,55	8,34
40	4,57	31,12	4,67	27,52	4,58	13,39

La méthode TIC avec relance de 300 unités, fournie par le classement mixte ventes/achats, **dégrade fortement les résultats** par rapport à une situation sans relance. De prime abord, ce résultat peut apparaître fort surprenant. Afin d’avoir confirmation des résultats nous avons considéré des exemples d’échantillon pour lesquels la situation se dégradait fortement. De fait les unités relancées sont celles dont les valeurs des ventes et achats électroniques s’éloignent le plus des moyennes de strate pour ces mêmes variables. A chaque fois, **les ventes et achats électroniques les plus éloignés de la moyenne sont des très fortes valeurs**, et non un mélange de fortes valeurs et de valeurs nulles. De plus, via le jeu de la repondération, ces unités avec des fortes valeurs de commerce électronique voient **leur poids augmenter**, d’autant plus que le taux de non-réponse initial est fort. Relancer uniquement les unités légales qui génèrent beaucoup de commerce électronique s’avère donc « catastrophique » en regard de la qualité des estimateurs. La dégradation de la qualité s’avère moindre dans le cas de la correction de la non-réponse selon les strates de lancement, probablement du fait d’une plus grande homogénéité des ventes et achats électroniques au sein de ces strates.

Dans un deuxième temps, on relance le nombre d’entreprises nécessaire pour gagner 10 points de taux de réponse.

Tableau sur les ventes électroniques, moyenne de l’écart absolu à la cible

Taux de non-réponse	Méthode de correction de la non-réponse					
	Uniforme		Par GRH		Par strate de lancement	
	sans relance	avec relances	sans relance	avec relances	sans relance	avec relances
20	5,22		4,26		4,17	
30	7,33	15,16	6,56	9,35	6,50	3,59
40	9,83	24,82	8,73	17,63	9,16	7,06

Tableau sur les achats électroniques, moyenne de l’écart absolu à la cible

Taux de non-réponse	Méthode de correction de la non-réponse					
	Uniforme		Par GRH		Par strate de lancement	
	sans relance	avec relances	sans relance	avec relances	sans relance	avec relances
20	2,89		2,79		2,50	
30	3,82	12,68	4,11	7,83	3,55	2,26
40	4,57	21,16	4,67	14,63	4,58	5,17

**Les résultats précédents sont confirmés** lorsque nous relançons 1 +010 entreprises, dans une moindre mesure toutefois. Le fait de relancer plus d’entreprises limite les aspects négatifs de la méthode. Au bout d’un moment c’est les entreprises avec une valeur nulle de commerce électronique qui vont être rappelées, minorant ainsi l’impact négatif des fortes valeurs avec des poids élevés. Que cela soit pour les achats et les ventes, avec un taux de réponse initial à 30 %, la situation s’améliore dans le cas de la correction de la non-réponse selon les strates de lancement. L’amélioration demeure toutefois relativement modeste en regard de celle espérée.

Les résultats obtenus avec un classement dissocié

Nous réitérons donc les tests en utilisant le classement dissocié : celui sur les ventes électroniques nous fournit des entreprises à relancer lorsque la variable d'intérêt est la variable « ventes électroniques », celui sur les achats électroniques nous fournit des entreprises à relancer lorsque la variable d'intérêt est la variable « achats électroniques ». Nous relançons donc 300 entreprises jugées prioritaires pour les ventes électroniques et 300 autres (il peut toutefois y avoir des intersections entre les deux listes de priorités de relance) jugées prioritaires pour les achats électroniques.

Tableau sur les ventes électroniques, moyenne de l'écart absolu à la cible

Taux de non-réponse	Méthode de correction de la non-réponse					
	Uniforme		Par GRH		Par strate de lancement	
	sans relance	avec relances	sans relance	avec relances	sans relance	avec relances
20	5,22	12,59	4,26	9,65	4,17	4,11
30	7,33	24,37	6,56	21,00	6,50	9,21
40	9,83	37,15	8,73	32,05	9,16	15,42

Tableau sur les achats électroniques, moyenne de l'écart absolu à la cible

Taux de non-réponse	Méthode de correction de la non-réponse					
	Uniforme		Par GRH		Par strate de lancement	
	sans relance	avec relances	sans relance	avec relances	sans relance	avec relances
20	2,89	10,27	2,79	7,78	2,50	3,61
30	3,82	19,78	4,11	17,28	3,55	8,42
40	4,57	30,36	4,67	27,15	4,58	13,21

Globalement les résultats sont identiques à l'autre type de classement. Cela peut s'expliquer en lien avec la formule retenue pour le classement mixte. Interclasser selon le rang minimum va garantir de relancer en priorité les unités avec de fortes valeurs de ventes électroniques et d'achats électroniques. Dans les deux cas nous relancerons les unités les plus atypiques en priorité, la dégradation des estimateurs étant le fait de quelques unités relativement peu nombreuses mais relancées en priorité.

Dans un deuxième temps, on relance le nombre d'entreprises nécessaire pour gagner 10 points de taux de réponse.

Tableau sur les ventes électroniques, moyenne de l'écart absolu à la cible

Taux de non-réponse	Méthode de correction de la non-réponse					
	Uniforme		Par GRH		Par strate de lancement	
	sans relance	avec relances	sans relance	avec relances	sans relance	avec relances
20	5,22		4,26		4,17	
30	7,33	14,84	6,56	7,90	6,50	2,96
40	9,83	25,00	8,73	16,17	9,16	6,40

Tableau sur les achats électroniques, moyenne de l'écart absolu à la cible

Taux de non-réponse	Méthode de correction de la non-réponse					
	Uniforme		Par GRH		Par strate de lancement	
	sans relance	avec relances	sans relance	avec relances	sans relance	avec relances
20	2,89		2,79		2,50	
30	3,82	12,25	4,11	6,73	3,55	1,71
40	4,57	20,71	4,67	13,48	4,58	3,83

Globalement, nous retrouvons ici la conclusion émise précédemment : relancer plus d'entreprises minore les aspects négatifs de cette méthode. La situation s'améliore même dans un cas : taux de réponse initial de 30 % et correction de la non-réponse par strate de lancement.

## 2.7. Approche enquête TIC avec contrainte

Cette dégradation des résultats après les relances, que le classement des priorités de relances soit mixte ventes/achats ou dissocié, nous pousse à **prendre en compte la contrainte de manière explicite**. Nous avons donc décidé d'étudier la possibilité de rajouter comme contrainte le fait que l'unité relancée nous rapproche de la cible si elle seule devient répondante. Dans le cas d'un classement mixte ventes/achats des priorités de relance, nous rajouterons une double contrainte : l'entreprise ne sera relancée que si le fait qu'elle devienne répondante nous rapproche de la cible à la fois pour les ventes électroniques et les achats électroniques. Dans le cas d'un classement dissocié des priorités de relance, nous rajouterons une contrainte uniquement sur les ventes électroniques (respectivement les achats électroniques) : l'entreprise ne sera relancée que si le fait qu'elle devienne répondante nous rapproche de la cible pour les ventes électronique (respectivement les achats électroniques).

L'ajout d'une contrainte ne nous assure pas d'être en mesure de relancer 300 entreprises et encore moins 1 010. En effet, certains échantillons ne présentent pas autant d'entreprises non-répondantes qui respectent la contrainte. La double contrainte, à la fois sur les achats et les ventes, appliquée dans le cas du classement mixte ventes/achats des priorités de relance renforce le phénomène. Ainsi, le gain espéré de 10 points de non-réponse après 1 010 relances n'est pas atteint lorsqu'on ajoute la contrainte.

Taux de non-réponse du fichier initial	Taux de non-réponse après 300 relances				Taux de non-réponse après 1010 relances			
	sans contrainte	avec contrainte mixte	avec contrainte sur les achats	avec contrainte sur les ventes	sans contrainte	avec contrainte mixte	avec contrainte sur les achats	avec contrainte sur les ventes
20	15,8	16,5	16,1	15,9	10	12,2	11,2	10,0
30	26,6	27,2	26,6	26,6	20	24,1	22,5	21,1
40	36,0	36,3	36,0	36,0	30	34,0	31,9	30,4

Rappelons que nous sommes ici dans **une situation idéale** car nous pouvons connaître le respect de la contrainte, ce qui ne sera évidemment pas le cas en situation réelle, c'est-à-dire au cours de la collecte.

### Les résultats obtenus avec un classement mixte

Plaçons-nous dans le cas d'un classement mixte ventes/achats des priorités de relance avec respect d'une double contrainte : l'entreprise ne sera relancée que si le fait qu'elle devienne répondante nous rapproche de la cible à la fois pour les ventes électroniques et les achats électroniques. Nous relançons dans un premier temps 300 entreprises.

Tableau sur les ventes électroniques, moyenne de l'écart absolu à la cible

Taux de non-réponse	Méthode de correction de la non-réponse					
	Uniforme		Par GRH		Par strate de lancement	
	sans relance	avec relances	sans relance	avec relances	sans relance	avec relances
20	5,22	3,31	4,26	2,88	4,17	3,40
30	7,33	5,54	6,56	4,87	6,50	5,24
40	9,83	8,39	8,73	6,02	9,16	6,55

Tableau sur les achats électroniques, moyenne de l'écart absolu à la cible

Taux de non-réponse	Méthode de correction de la non-réponse					
	Uniforme		Par GRH		Par strate de lancement	
	sans relance	avec relances	sans relance	avec relances	sans relance	avec relances
20	2,89	2,45	2,79	2,73	2,50	2,65
30	3,82	4,66	4,11	5,55	3,55	4,61
40	4,57	7,51	4,67	8,33	4,58	6,64

En ce qui concerne les ventes électroniques, **le respect de la contrainte améliore les résultats** par rapport à la situation sans relance et à la situation de relances sans respect de la contrainte. Dans le cas de la correction de non-réponse de manière uniforme ou par GRH, cette méthode se révèle plus efficace que l'approche basée sur le chiffre d'affaires. Ce n'est toutefois pas le cas pour les achats électroniques, pour lesquels nous observons une dégradation des résultats obtenus par rapport à la situation sans relance. Dans tous les cas les progrès sont spectaculaires par rapport à la dégradation enregistrée avec la méthode sans contrainte. Ce résultat peut se comprendre facilement. Les unités avec des fortes valeurs du commerce électronique, qui expliquaient la détérioration des estimateurs, ne vérifient pas la contrainte ici. Ces unités ne sont pas relancées.

Dans un second temps, nous relançons potentiellement 1 010 entreprises.

Tableau sur les ventes électroniques, moyenne de l'écart absolu à la cible

Taux de non-réponse	Méthode de correction de la non-réponse					
	Uniforme		Par GRH		Par strate de lancement	
	sans relance	avec relances	sans relance	avec relances	sans relance	avec relances
20	5,22		4,26		4,17	
30	7,33	5,74	6,56	7,46	6,50	6,56
40	9,83	7,35	8,73	8,27	9,16	7,44

Tableau sur les achats électroniques, moyenne de l'écart absolu à la cible

Taux de non-réponse	Méthode de correction de la non-réponse					
	Uniforme		Par GRH		Par strate de lancement	
	sans relance	avec relances	sans relance	avec relances	sans relance	avec relances
20	2,89		2,79		2,50	
30	3,82	5,76	4,11	7,86	3,55	6,92
40	4,57	7,98	4,67	10,46	4,58	9,31

La situation s'améliore donc quelque peu pour les ventes et se dégrade assez nettement pour les achats. **La prise en compte de la contrainte s'avère nécessaire mais les progrès enregistrés par rapport à la situation sans relances ne sont pas nets.**

Plaçons-nous dans le cas d'un classement dissocié des priorités de relance portant sur les ventes (respectivement les achats), nous rajouterons une contrainte uniquement sur les ventes (respectivement les achats) : l'entreprise ne sera relancée que si le fait qu'elle devienne répondante nous rapproche de la cible pour les ventes (respectivement les achats). Nous relançons dans un premier temps 300 entreprises.

Tableau sur les ventes électroniques, moyenne de l'écart absolu à la cible

Taux de non-réponse	Méthode de correction de la non-réponse					
	Uniforme		Par GRH		Par strate de lancement	
	sans relance	avec relances	sans relance	avec relances	sans relance	avec relances
20	5,22	4,13	4,26	5,07	4,17	5,95
30	7,33	9,26	6,56	10,63	6,5	10,64
40	9,83	13,55	8,73	12,34	9,16	12,51

Tableau sur les achats électroniques, moyenne de l'écart absolu à la cible

Taux de non-réponse	Méthode de correction de la non-réponse					
	Uniforme		Par GRH		Par strate de lancement	
	sans relance	avec relances	sans relance	avec relances	sans relance	avec relances
20	2,89	4,17	2,79	5,28	2,50	5,66
30	3,82	9,67	4,11	11,47	3,54	11,18
40	4,57	15,29	4,67	16,62	4,57	15,36

Dans un second temps, nous relançons potentiellement 1 010 entreprises.

Tableau sur les ventes électroniques, moyenne de l'écart absolu à la cible

Taux de non-réponse	Méthode de correction de la non-réponse					
	Uniforme		Par GRH		Par strate de lancement	
	sans relance	avec relances	sans relance	avec relances	sans relance	avec relances
20	5,22		4,26		4,17	
30	7,33	10,14	6,56	15,50	6,50	13,80
40	9,83	12,81	8,73	17,90	9,16	17,41

Tableau sur les achats électroniques, moyenne de l'écart absolu à la cible

Taux de non-réponse	Méthode de correction de la non-réponse					
	Uniforme		Par GRH		Par strate de lancement	
	sans relance	avec relances	sans relance	avec relances	sans relance	avec relances
20	2,89		2,79		2,5	
30	3,82	11,03	4,11	14,50	3,55	13,41
40	4,57	16,48	4,67	20,09	4,58	18,78

Dans ce cas de figure, les résultats sont nettement dégradés aussi bien pour les ventes que pour les achats électroniques. **Contre toute attente, la contrainte n'améliore pas les choses.** Cela est probablement dû à son mode de calcul. En effet, dans le cadre de ces simulations le calcul de la contrainte est « statique ». Pour chaque unité non-répondante, nous avons calculé un nouvel estimateur prenant en compte que cette unité et elle seule devenait répondante. Dans le cas où l'estimateur ainsi obtenu nous rapprochait de la cible par rapport à la situation où l'unité en question était non-répondante, la contrainte était vérifiée. Un mode de calcul « dynamique » aurait pu être appliqué : pour calculer la contrainte de l'entreprise de rang n, il faut supposer que toutes les entreprises de rang 1 à n-1 deviennent répondantes. Une contrainte « dynamique » devrait par définition améliorer les choses. Toutefois, nous avons décidé de ne pas simuler une telle méthode, les hypothèses sous-jacentes étant trop fortes et ce mode de calcul n'étant pas adapté dans le cadre des relances effectuées par les gestionnaires. En effet, on anticiperait ici l'ordre d'arrivée des répondants en cours de collecte en faisant l'hypothèse très forte que cet ordre est totalement déterminé par les priorités de relances, étant donné que dans nos simulations seules les entreprises relancées deviennent répondantes et que les entreprises qui ne le sont pas restent non-répondantes. Ces résultats nous montrent paradoxalement **qu'il serait nécessaire d'intégrer complètement la contrainte dynamique**, sans que cela soit pratiquement faisable en période de collecte car reposant sur des hypothèses trop fortes. Les résultats dépendent fortement de l'expression de la contrainte.

## 2.8. Approche « variance à gagner »

Nous considérons désormais la méthode dite de **la variance à gagner**, exposée dans le détail dans l'encadré 3. Cette approche est différente de celles considérées précédemment : son objectif est ici de réduire la variance de l'estimateur et non plus de se focaliser sur l'erreur d'imputation. La méthode a été ici programmée de manière complètement dynamique. À partir de la situation initiale, nous déterminons la strate dans laquelle les rappels sont prioritaires. Au sein de cette strate, nous choisissons aléatoirement l'unité légale non répondante à relancer. Nous supposons que cette unité répond tandis que cela n'est pas le cas pour les autres unités. Nous déterminons ensuite de nouveau la strate prioritaire et ainsi de suite jusqu'à atteindre le nombre d'unités à relancer. Il est important de revenir sur la formule de référence de cette méthode. Pour établir celle-ci, nous nous sommes placés implicitement dans le cas où les groupes de réponses homogènes étaient identiques aux strates de tirage. **Cette formalisation est donc valable lorsque nous corrigeons la non-réponse selon les strates de tirage.** Lorsque nous pratiquons la correction de la non-réponse par repondération au sein

des groupes de réponses homogènes définis dans l'enquête TIC, nous sortons du cadre théorique de l'encadré 3 et la formalisation est plus complexe<sup>5</sup>. De fait, il faut bien voir dans l'analyse des résultats des simulations que seul le cas où le redressement a été effectué selon les strates de lancement est licite ici. Nous avons toutefois considéré les autres situations, à titre illustratif uniquement, pour voir si les résultats dépendent fortement de la méthode de correction de la non-réponse. Dans les tableaux ci-dessous, nous évoquons uniquement le cas où les rappels concernent 300 unités légales. Le cas de la relance pour gagner 10 points de taux de réponse ne change pas les conclusions qui vont être établies ici.

Tableau sur les ventes électroniques, moyenne de l'écart absolu à la cible

Taux de non-réponse	Méthode de correction de la non-réponse					
	Uniforme		Par GRH		Par strate de lancement	
	sans relance	avec relances	sans relance	avec relances	sans relance	avec relances
20	5,22	10,32	4,26	8,86	4,17	0,79
30	7,33	13,98	6,56	11,86	6,50	1,98
40	9,83	17,11	8,73	15,87	9,16	3,42

Tableau sur les achats électroniques, moyenne de l'écart absolu à la cible

Taux de non-réponse	Méthode de correction de la non-réponse					
	Uniforme		Par GRH		Par strate de lancement	
	sans relance	avec relances	sans relance	avec relances	sans relance	avec relances
20	2,89	7,94	2,79	7,11	2,50	1,16
30	3,82	8,28	4,11	7,21	3,55	2,23
40	4,57	9,30	4,67	8,42	4,58	3,12

Comme nous le constatons directement, **cette méthode s'avère très efficace lorsque la non-réponse est redressée à partir des strates de tirage** (strates de lancement). L'écart à la cible est fortement réduit, cela se révèle de fait dans ce cas **la méthode la plus efficace**. Les résultats sont particulièrement bons pour les ventes électroniques, dans les cas avec 20 % ou 30 % de non-réponse. Comme déjà signalé, seule l'analyse de ce mode de correction par strate de lancement s'avère théoriquement fondée. De fait, l'examen des cas avec redressement uniforme et redressement par GRH au sens de l'enquête TIC montre un fort écart à la cible, la situation se détériorant grandement par rapport à la situation initiale. Que peut-on déduire de cela en pratique pour la gestion d'enquête ? Il est primordial d'appliquer cette formule à bon escient, c'est-à-dire d'utiliser la formule qui se base sur le mode de redressement de la non-réponse totale pour l'enquête en cours. Pour une enquête répétitive, comme l'enquête TIC, il peut être utile de considérer les groupes de réponses homogènes mis en évidence l'année précédente. Par expérience, les contours de ceux-ci changent peu d'une année sur l'autre. Nous pourrions même envisager, avec un peu de témérité, de figer les groupes de réponses homogènes d'une année sur l'autre. Cela pourrait avoir pour conséquence d'établir une méthode de priorité de rappels efficace, de limiter fortement la

<sup>5</sup> Pour information, la formalisation de l'encadré 3 est celle retenue dans la macro SAS Calker de calcul de précision. Une macro Calker\_GRH a été élaborée par Emmanuel GROS de l'UMS-E pour tenir compte du fait que les groupes de réponses homogènes pourraient être différents des strates de tirage. Cette macro s'appuie sur une formalisation qui sera décrite dans la notice de cette macro SAS, notice en cours d'élaboration.

variance des estimateurs, en tolérant toutefois un « léger » biais en lien avec un modèle perfectible de correction de la non-réponse. Pour une enquête non-répétitive, la situation est plus complexe. Imposer un mode de correction sur les strates de tirage, par exemple, pourrait se révéler efficace en termes de variance mais pourrait engendrer un biais notable sur les estimateurs, en lien avec des variables auxiliaires non prises en compte dans le mode de correction de la non-réponse.

## 2.9. Poursuites des travaux et conclusions provisoires

Même si les simulations précédentes apportent des **enseignements importants** sur les méthodes de priorité de rappel à mettre en œuvre lors de la collecte, plusieurs travaux seraient nécessaires pour arriver à un diagnostic complet. Nous pouvons évoquer ici rapidement **plusieurs approfondissements possibles**. Pour les méthodes qui se basent sur des agrégats du type chiffre d'affaires, nous pourrions mettre en évidence, pour chaque variable, la variable auxiliaire la plus efficace. Il resterait à voir ensuite comment passer d'un classement de priorité par variable à un classement unique et global pour toutes les variables cibles. Cela pourrait se faire en combinant les rangs déterminés pour chaque variable ou alors en choisissant une variable auxiliaire qui marche bien, sans être la plus efficace, pour chaque variable cible de l'enquête. Relativement à la méthode utilisée dans TIC, il pourrait être utile d'aller plus loin en ce qui concerne la contrainte. Établir une méthode complètement dynamique pourrait avoir des vertus pédagogiques ici, notamment pour comparer son efficacité à des méthodes du type « chiffre d'affaires » ou « variance à gagner ». Toutefois, les applications pratiques resteraient incertaines pour au moins deux raisons. D'une part, comme nous l'avons déjà signalé, les hypothèses se révèlent cruciales ici : pour l'efficacité de la méthode, seules les non répondants relancés doivent répondre. De fait, cela n'est jamais (heureusement ?) vérifié en cours d'enquête. D'autre part, en situation réelle, nous ne connaissons pas l'expression exacte de la contrainte car nous ne connaissons pas l'estimateur final pour chaque variable cible ! Nous pouvons approcher cet estimateur, de plus en plus finement au fur et à mesure de la collecte, mais sans toutefois porter un jugement définitif sur la qualité de la contrainte exprimée. Enfin, en lien avec la méthode « variance à gagner », il pourrait être intéressant de programmer cela lorsque la non-réponse est corrigée selon les groupes de réponses homogènes. Nous nous rapprocherons ainsi du mode de correction de la non-réponse utilisé dans l'enquête TIC.

Les travaux mentionnés dans cet article vont avoir des **conséquences pratiques** sur les méthodes de priorités de rappels utilisées dans le cadre des enquêtes thématiques entreprises. Pour l'enquête TIC 2012, la méthode doit être opérationnelle pour le mois de février 2012. En lien avec les résultats précédents, nous allons abandonner la méthode précédemment utilisée pour revenir à une méthode plus simple, basée sur des agrégats du type chiffre d'affaires ou achats. Cette méthode semble produire de bons résultats, elle a l'avantage également d'être simple à programmer et à expliquer aux équipes de gestionnaires. En lien avec les délais, il n'apparaît pas possible de programmer une méthode opérationnelle qui se base sur la variance à gagner. Toutefois, nous avons le projet de continuer les simulations en regard de cette méthode, pour voir s'il serait opportun de la rendre pleinement robuste et opérationnelle dans le cadre des enquêtes thématiques entreprises.

## Bibliographie

- [1] Pascal ARDILLY, « Les techniques de sondage », Technip 2006.
- [2] Yves BERGER, « Developing a scoring system for prioritising response-chasing », congrès de Neuchâtel 25 juin 2009.
- [3] Philippe BRION, « Critère d'arrêt de traitement d'enquête » note interne Insee n°4/E210 du 11 avril 2003. Cette note a été reprise, sous forme résumée, dans « échantillonnage et méthodes d'enquêtes », Dunod 2004, pages 113 à 118.
- [4] Philippe BRION, « Arbitrages entre délais et précision dans les enquêtes statistiques », document de travail de l'Insee n°E2007/018.
- [5] Benoît BUISSON, « Estimateurs en cours d'enquête et priorités de relances », journées de méthodologie statistique 2009.
- [6] Benoît BUISSON et Béatrice NEITER, « Comment redresser une enquête thématique ? », document de travail de l'Insee n°E2010/01.
- [7] Nathalie CARON, « la correction de la non-réponse par repondération et par imputation », document de travail de l'Insee n°M0502.
- [8] Pierre DAOUST, « Prioritizing follow-up on non-respondents using scores for the Canadian quarterly survey of financial statistics for entreprises », Work session on statistical data editing, Bonn 25-27 septembre 2006.
- [9] David HAZIZA, « Traitement de la non-réponse dans les enquêtes », polycopié de cours de la FCDA Ensai.
- [10] Gareth JAMES, « A strategy for prioritising non-response followp-up to reduce costs without reducing output quality », UK Office for national statistics.
- [11] Richard MAC-KENZIE, « A framework for priority contact of non respondents », document de l'Australian Bureau of Statistics (document disponible sur le site de l'OCDE).
- [12] Eric RANCOURT, Jean-François BEAUMONT, David HAZIZA et Charles MITCHELL (2003), « Statistics Canada's new software to better understand and measure the impact of non-response and imputation », Conference of european Statisticians, Work Session on Statistical Data Editing.
- [13] Olivier SAUTORY, « Redressements d'échantillons et méthode de Calage », polycopié de cours FCDA Ensai.
- [14] Hansheng XIE, Serge GODBOUT, Sungjin YOUN et Pierre LAVALLÉE, « Collection Follow-Up opération using priority scores for business surveys », Work session on statistical data editing, Ljubljana 9-11 may 2011.