

Traitement de la non-réponse partielle pour l'enquête sur les relations entre entreprises

Olivier HAAG (), Emmanuel RAULIN (**)*

() Sessi, Sous-direction Ingénierie et Coordination Statistique,*

*(**) Insee, Département Système Statistique d'Entreprise*

Introduction

Dans le but de mieux connaître l'ampleur, la logique et les raisons économiques des liens inter-entreprises aujourd'hui, une enquête sur les relations entre entreprises (ERIE) a été réalisée durant l'année 2003, dans le cadre d'une collaboration entre différents services statistiques (Sessi, Insee, SES-construction, SCEES et ministère de la recherche).

Les objectifs principaux étaient d'une part de dresser un large panorama de ces relations inter-entreprises, quels que soient le secteur d'activité de ces dernières, la fonction dans laquelle elles s'exercent, en aval ou en amont du processus de production, la nature de ces relations, etc. D'autre part, il s'agissait de fournir quelques éléments quantitatifs sur l'importance et l'intensité de ces relations. En outre, il s'agissait de bien distinguer les relations intra-groupe des autres. Étaient toutefois exclues du champ de l'enquête ERIE, d'une part les relations strictement financières et, d'autre part, les relations clients/fournisseurs usuelles.

Cette enquête était principalement qualitative, alors que généralement, les enquêtes françaises auprès des entreprises sont quantitatives. De plus, le fait de demander aux entreprises de décrire précisément quelques relations individuellement et non pas une relation moyenne constituait également une nouveauté. Ces deux éléments ont nécessité la mise en place de traitements de la non-réponse partielle originaux pour des enquêtes « entreprises ».

Les réflexions concernant le traitement de la non-réponse partielle ont été menées dès la collecte des données et ont ainsi orienté l'organisation des rappels téléphoniques des entreprises. Ces rappels ont permis de mieux comprendre les raisons de cette non-réponse et d'en tenir compte dans son traitement de fin d'enquête (prise en compte du comportement de non-réponse).

L'objet de cet article est de présenter les méthodes utilisées pour le traitement de la non-réponse sur la base d'un exemple concret et donc d'illustrer les grands principes suivants :

1. **l'estimation de la non-réponse, totale ou partielle, d'un individu de la population enquêtée (ici des entreprises), sera d'autant meilleure qu'elle mobilisera l'information disponible sur cet individu.** Dans le cas présent deux exemples sont donnés, l'un faisant appel à une information endogène à l'enquête, l'autre mobilisant une information exogène à l'enquête.
2. **l'estimation des non-réponses repose généralement sur l'hypothèse que les non-répondants (totaux ou partiels) ont le même comportement, quant aux variables**

d'intérêt, que les répondants. Ainsi, ce sont les réponses obtenues qui permettent d'inférer les réponses des non-répondants. Dans cet exemple concret, on s'est attaché à vérifier la validité de cette hypothèse sur un échantillon de non-répondants ; on verra que cette hypothèse n'est pas toujours totalement vérifiée.

3. **l'estimation des non-réponses est d'autant meilleure qu'elle utilise des classes de comportement homogène (stratification de la population) ;** les deux exemples traités montrent une recherche de telles classes allant au-delà des critères usuels utilisés en statistique d'entreprise (activité principale et taille de l'entreprise) pour privilégier des critères a priori mieux corrélés avec les variables d'intérêt de l'enquête elle-même.
4. **la qualité des résultats d'une enquête (au sens restrictif de leur précision) dépend notamment de l'importance des non-réponses et de la variance résultant du traitement de ces dernières ;** dans le cas présent, des simulations ont été utilisées pour estimer cette variance, un calcul direct s'avérant trop compliqué vu les méthodes utilisées.

Enfin, l'une des originalités de ce traitement de la non-réponse réside dans la mise en place d'un modèle d'inférence des non-réponses partielles faisant appel à des techniques rarement utilisées en statistique d'entreprises (classification hiérarchique) ; pour une large part, cette originalité s'explique par le caractère principalement qualitatif de l'enquête.

L'illustration de ces différentes assertions se basera donc sur l'analyse des deux principaux problèmes de non-réponses auxquels l'enquête a été confrontée :

1. **Certaines entreprises dont la déclaration d'absence de relation paraissait « suspecte ».** En effet les entreprises ayant antérieurement et dans une autre enquête - l'Enquête Annuelle d'Entreprises (EAE) - déclaré être sous-traitantes devaient a priori déclarer au moins une relation de sous-traitance dans cette enquête ERIE, ce type de relations faisant explicitement partie du champ de l'enquête. Or un grand nombre de sous-traitants, selon l'EAE, ont spontanément déclaré dans l'enquête ne pas avoir de relation. Ces réponses contradictoires devaient être examinées puis redressées le cas échéant.
2. **Certaines entreprises décrivant moins de relations que prévu.** Pour chaque fonction, les entreprises déclarant avoir moins de trois relations devaient ensuite faire une description individuelle de chacune d'entre elles tandis que les entreprises ayant plus de trois relations devaient sélectionner, parmi celles-ci, les trois relations qu'elles considéraient comme les plus stratégiques pour les décrire ensuite. Or fréquemment, les entreprises ne faisaient la description que d'une seule relation. En outre, il avait été décidé qu'un questionnaire était considéré comme acceptable (donc ne nécessitant pas de recontacter l'entreprise) dès lors que l'entreprise avait décrit parfaitement au moins une relation pour chaque fonction dans laquelle elle avait déclaré avoir des relations. Il était donc fréquent d'avoir, au final, des questionnaires dans lesquels il manquait la description de plusieurs relations. Il devenait alors nécessaire d'estimer ces dernières.

Après une rapide présentation de l'enquête, l'article examinera, pour chacun des deux problèmes séparément, dans un premier temps, les techniques élaborées dès la collecte pour mobiliser le maximum d'informations nécessaires à la mise en place des modèles d'imputation de la non-réponse (échantillonnage des entreprises à rappeler, etc.). Dans un second temps, les techniques de redressements [1] (hot-deck stratifié, utilisation d'une classification ascendante hiérarchique, etc.) seront présentées. Enfin, la variance induite par ces traitements de la non-réponse sera analysée dans une troisième partie.

Les mêmes techniques de traitement de la non-réponse ont été mises en place pour l'ensemble des services enquêteurs. Toutefois, cet article ne présentera que les résultats observés au Sessi pour les entreprises industrielles.

1. Présentation de l'enquête

L'enquête sur les relations entre entreprises a été lancée en 2003. Elle a été réalisée par cinq services enquêteurs : le Sessi au ministère de l'industrie, le SCEES au ministère de l'agriculture, le SES au ministère du logement, la DEP au ministère de l'éducation nationale et l'Insee. La participation de la quasi-totalité des services enquêteurs à cette enquête a permis d'avoir une vision globale des relations entre entreprises, de faire des comparaisons intersectorielles à partir d'une base unique qui contient l'ensemble des données des différents secteurs. De plus, une enquête similaire a été menée en 2003 par d'autres pays de l'Union Européenne, coordonnée par Eurostat.

1.1. Les principaux objectifs de l'enquête

Les deux objectifs principaux étaient :

- d'une part, de dresser un large panorama des différentes relations entre deux ou plusieurs entreprises, et ce quels que soient leur secteur d'activité, la fonction (domaine) dans laquelle s'exerce cette relation, en aval ou en amont de la production proprement dite, la nature de ces relations, etc. ;
- d'autre part de fournir quelques éléments quantitatifs sur l'importance et l'intensité de ces relations ; en outre, ont été distinguées les relations intra-groupe des autres.

Un autre objectif avait été assigné à l'enquête : établir une nouvelle typologie de relations d'après leurs caractéristiques comme l'intensité, l'équilibre, etc.

1.2. Le champ de l'enquête et le plan de sondage

Le champ de l'enquête ERIE a été calé sur celui de l'EAE pour les entreprises industrielles (champ du Sessi). A savoir, les entreprises de plus de 20 salariés ou de plus de cinq millions d'euros de chiffre d'affaires et ayant une activité principale industrielle, soit environ 22 000 entreprises.

L'échantillon de l'enquête ERIE a été corrélé négativement [2] avec celui de l'enquête sur les technologies de l'information et de la télécommunication (TIC), lancée quelques mois auparavant, afin de réduire la charge statistique des entreprises.

Une significativité des résultats était recherchée par secteur d'activité NES36 croisé avec les tranches de taille suivantes (effectifs salariés) : 20-49, 50-99, 100-249, 250-499 et 500 et plus. Ces niveaux de détail ont permis de satisfaire la demande européenne (Eurostat).

Pour les entreprises industrielles, les strates d'échantillonnage ont été obtenues par croisement de la taille (en 6 classes)
du secteur d'activité (en Nes36)
de l'appartenance ou non à un groupe.

A l'intérieur des strates ainsi définies, un tirage aléatoire simple a été réalisé. L'allocation de Neyman a été utilisée pour calculer la taille des échantillons par strate [3]. La variable auxiliaire utilisée pour cette allocation a été le chiffre d'affaires, à défaut d'une autre variable mieux corrélée avec le nombre de relations qu'une entreprise peut avoir.

Les entreprises de plus de 250 salariés ont été interrogées exhaustivement.

Au final l'échantillon contenait 5220 entreprises industrielles, soit un taux de sondage d'environ 25%.

1.3. Un questionnaire principalement qualitatif

1.3.1. Une approche par fonction

L'analyse des relations étudiées et de leurs caractéristiques a été réalisée selon chaque fonction du processus de production (biens ou services) :

- la *production* (ou le cœur de métier de l'entreprise) ;
- l'*approvisionnement* (fonction achat, y compris achat de sous-ensembles) ;
- la *commercialisation* (fonction vente à l'exclusion des fonctions marketing, publicité ou relations clients qui étaient incluses dans le domaine des services auxiliaires) ;
- les *services auxiliaires* (transport, informatique, administration générale, publicité, marketing, etc.) ;
- *innovation, recherche et développement* ;

Les entreprises n'étaient interrogées que pour les fonctions ayant du sens dans leur secteur économique.

Ainsi, les entreprises des industries manufacturières étaient interrogées sur les 5 fonctions.

Pour chaque fonction présente sur le questionnaire, l'entreprise devait répondre à deux types de questions :

- des questions de cadrage général et, le cas échéant, sur les raisons de l'absence de relation ;
- des questions visant à décrire précisément chacune des trois relations les plus stratégiques (qualitatif).

1.3.2. Un cadrage général des relations

Le questionnaire débutait avec quelques questions quantitatives. Pour chaque fonction, l'entreprise devait indiquer d'une part, le nombre de relations qu'elle entretenait pour cette fonction et, d'autre part, une estimation de la part que représentaient ces relations dans la fonction considérée. Par exemple pour la fonction *production* (ou celle relative au cœur de métier), l'entreprise devait indiquer la part du chiffre d'affaires générée par ces relations. Que ce soit le nombre ou l'importance des relations, une distinction était systématiquement faite entre les relations intra-groupes et les autres.

1.3.3. Les descriptions individualisées de 3 relations au plus par fonction

Un des reproches majeurs adressés à l'enquête similaire de 1995 (ELI95) était que la caractérisation des relations (secteurs client, géographique, modalités d'accompagnement, etc.) n'était pas mise en regard de la relation concernée, mais appréciée «en bloc», c'est-à-dire toutes relations confondues, aboutissant ainsi à une sorte de relation «moyenne» pour chaque entreprise. L'enquête ERIE a voulu aller au-delà de cette approche moyenne, en demandant aux entreprises de décrire, pour chaque fonction, ses 3 relations les plus stratégiques. Ce questionnement a permis de disposer ainsi d'une base de données sur les caractéristiques propres de plusieurs milliers de relations ; l'analyse de cette base permettra de proposer une typologie a posteriori des relations, telles qu'elles se nouent aujourd'hui entre les entreprises.

L'entreprise devait donc dans un premier temps sélectionner, pour chaque fonction, ses trois relations les plus stratégiques (de rapides indications lui étaient données, mais l'option retenue était de s'en remettre à l'entreprise pour cette sélection), puis devait les décrire une par une au travers de questions uniquement qualitatives (une douzaine en moyenne). Ces questions étaient de deux types : celles devant permettre de mieux connaître le partenaire dans la relation et celles visant à mieux définir la relation proprement dite.

Les sujets abordés étaient les suivants pour chaque fonction :

1. nature du partenaire (entreprise, groupement, laboratoire, etc.) ;
2. appartenance ou non du partenaire au même groupe que l'entreprise ;
3. localisation du partenaire ;
4. critère de sélection du partenaire ;
5. type de la relation (sous-traitance, mise en commun de moyens, etc.) ;
6. raisons de la mise en place de la relation (logique économique de la relation) ;
7. durée de la relation ;
8. intensité de la relation (degré de collaboration existant entre les 2 partenaires) ;
9. équilibre ou déséquilibre de la relation (qui avait imposé ses règles ?) ;
10. rôle assuré dans la relation (conception, fabrication etc.).

1.4. le calendrier de l'enquête

L'enquête a été lancée en janvier 2003 pour les entreprises du commerce, des services et de l'industrie (hors IAA), en avril pour les entreprises de R&D, en septembre pour les entreprises agroalimentaires et enfin en décembre pour celles de la construction.

Pour l'industrie, la collecte a duré quatre mois. L'ensemble des procédures de rappel associées à une enquête obligatoire a été utilisé, à savoir deux rappels, une mise en demeure et un constat de non réponse.

1.5. Quelques bilans d'exploitation

Les taux de réponses ont été les suivants :

- **83 % pour les entreprises industrielles hors IAA ;**
- 74 % pour les entreprises de R&D ;
- 70 % pour les entreprises commerciales ;
- 65 % pour les entreprises de service ;
- 85 % pour les IAA ;
- 63 % pour les entreprises de la construction.

Les gestionnaires d'enquête, dans tous les services, ont jugé cette enquête complexe ; une même appréciation est revenue de certaines entreprises. L'enquête était en effet originale à bien des égards, son caractère fortement qualitatif tranchant fortement avec les enquêtes habituelles, presque exclusivement quantitatives. Peu habitués, les gestionnaires ont eu tendance à considérer que la réponse de l'entreprise étant par essence subjective (hormis quelques questions), il ne pouvait y avoir de contrôle de celle-ci.

Toutefois, le taux de réponse d'une part, les résultats d'autre part, concluent à un bilan satisfaisant.

1.6. Les problèmes rencontrés

Les principes essentiels, pour cette enquête, du traitement des non-réponses et des réponses incohérentes ont été fixés dès la collecte des données afin d'en fixer la stratégie la plus pertinente, pour ces traitements, et d'optimiser ainsi l'efficacité des rappels d'entreprises (par téléphone).

Deux grandes catégories de non-réponses ont été identifiées dès les premiers retours de questionnaires :

- les réponses qui étaient incohérentes avec des éléments de l'entreprise connus par ailleurs (par exemple, une entreprise connue via l'enquête structurelle comme étant un donneur d'ordre et ne déclarant aucune relation dans ERIE alors que la relation donneur d'ordre/preneur d'ordre relevait du champ de l'enquête) ;
- les réponses qui comportaient des manquements manifestes (absence de descriptions de relations attendues, non-réponses au tableau de cadrage général).

Les différents problèmes à résoudre ont été les suivants :

- des incohérences ou anomalies dans les données de cadrage général
- des incohérences au sein même des descriptions individuelles (certaines modalités de réponses étaient en effet incompatibles)
- des entreprises dont l'absence de relations déclarées paraissait suspecte. Il s'agissait d'entreprises qui selon l'EAE étaient sous-traitantes ou donneuses d'ordre et qui se déclaraient sans relation dans l'enquête ERIE
- des entreprises qui ne décrivaient pas assez de relations par rapport au nombre de relations déclarées dans les questions de cadrage général.

Ces difficultés ont donc donné lieu à des rappels d'entreprises. Toutefois, pour certains de ces problèmes, qui concernaient trop d'entreprises, seul un échantillon d'entreprises a été rappelé. Les réponses des entreprises rappelées ont par la suite été utilisées pour redresser les réponses des autres entreprises se trouvant dans une situation similaire.

Seuls les deux derniers problèmes évoqués ci-dessus, qui étaient les plus complexes à appréhender, font l'objet d'une présentation détaillée dans la suite de cet article.

En outre, seuls les résultats de la fonction *production* seront présentés. Les 5 fonctions ont été traitées de façon identique et les résultats obtenus sont très proches.

2. Les entreprises n'ayant pas décrit assez de relations

2.1. Présentation du problème

La limitation volontaire (pour cause de charge de réponse) du nombre de relations à décrire par fonction (trois au plus) impliquait que, dès lors que l'entreprise avait déclaré, dans le tableau de cadrage général, avoir au moins trois relations dans une fonction, elle devait faire la description de trois d'entre elles (les trois plus stratégiques) ; sinon, le nombre de relations décrites individuellement devait nécessairement être égal au nombre de relations déclarées.

Il arrivait cependant que l'entreprise décrivît moins de relations qu'attendu. Toutefois, afin de ne pas trop alourdir la charge de rappel des gestionnaires d'une part, et la charge de réponse des entreprises d'autre part, la réponse était considérée comme suffisante dès lors que pour chaque fonction, pour laquelle l'entreprise avait déclaré au moins une relation, une description individuelle était disponible, et que celle-ci était jugée correcte. Dans ce cas, l'entreprise n'était donc pas rappelée.

Ainsi, en fin d'enquête, pour chaque entreprise ayant déclaré au moins une relation dans une fonction donnée, au moins une description individuelle était disponible, éventuellement après rappel de l'entreprise. Ce résultat était primordial pour le traitement de la non-réponse.

Pour autant, l'imputation des descriptions manquantes nécessitait, pour être suffisamment précise, de comprendre pourquoi une entreprise n'avait pas décrit toutes les relations attendues. Il s'agissait là encore d'affiner la compréhension du comportement de réponse : l'entreprise n'a-t-

elle pas renseigné toutes les descriptions attendues faute de temps (ou par refus) ou bien les relations à décrire sont-elles à ce point identiques que l'entreprise n'a pas jugé utile de répéter plusieurs fois sa description. De la réponse à cette question dépendait le traitement de la non-réponse à mettre en œuvre.

Le rappel d'un échantillon d'entreprises concernées par ce phénomène a permis d'éclairer ce point.

Tableau 1 : Répartition des d'entreprises selon le nombre de descriptions de relations à « imputer » par fonction

	Fonction				
	<i>Production</i>	<i>Approvisionnement</i>	<i>Commercialisation</i>	<i>Services auxiliaires</i>	<i>R&D</i>
2 descriptions manquantes (à imputer)	298	370	205	149	100
1 description manquante (à imputer)	139	172	103	72	60
0 description manquante (pas d'imputation)	1265	1468	1027	934	754
Part des descriptions à imputer	26%	27%	23%	19%	18%

2.2. Présentation des traitements mis en œuvre et variance associée

2.2.1. Principe de l'estimation

Etaient concernées toutes les entreprises :

- ayant déclaré deux relations pour une fonction donnée dans le tableau des données générales et n'en ayant décrit individuellement qu'une seule pour cette fonction ;
- ayant déclaré plus de deux relations pour une fonction donnée dans le tableau des données générales et n'en ayant décrit individuellement qu'une ou deux pour cette fonction.

Le modèle de réponse utilisé a reposé sur la « proximité » des différentes relations décrites dans une même fonction ; cette « proximité » ayant été estimée sur les entreprises qui avaient correctement répondu. Plus concrètement, puisque les entreprises à redresser (au moins une description de relation devait être imputée) comportaient nécessairement (cf. ci-dessus), pour la fonction concernée, au moins une relation correctement décrite, l'idée a consisté à utiliser au mieux cette information pour en déduire le type de la ou des relations manquantes et donc à imputer.

L'analyse de la « proximité » des relations par fonction a reposé sur la mise en évidence de classes (ou types) de relations. Dans un premier temps, il s'est donc agi de constituer des classes de relations « proches ». C'est-à-dire des classes à l'intérieur desquelles les relations avaient des caractéristiques voisines (réponses assez proches aux douze variables de caractérisation).

La mise en évidence de ces classes a reposé sur les résultats d'une classification ascendante hiérarchique réalisée sur les descriptions individuelles jugées correctes lors des traitements. Les relations décrites par les entreprises considérées comme bonnes répondantes (toutes les descriptions individuelles attendues étaient présentes) ont alors été classées (environ 500 pour la fonction *production*). Ensuite, ont été observées, sur les bonnes répondantes, les fréquences d'appartenance à une classe donnée de la 2^{ème} relation décrite et, le cas échéant, de la 3^{ème} relation décrite, conditionnellement à la classe d'appartenance de la 1^{ère} relation décrite. Un tableau de probabilités conditionnelles a alors été créé, la case ij indiquant la probabilité que la 2^{ème} relation ressortisse de la classe j , sachant que la 1^{ère} relation ressortit de la classe i . Ainsi, les paramètres du modèle probabiliste qui a servi de base au redressement de ces non-réponses ont été estimés à partir des fréquences empiriques observées.

Tout le redressement de ces non-réponses a donc été guidé par la classe d'appartenance de la seule relation décrite et par le tableau des probabilités conditionnelles de classe d'appartenance des relations de rang 2 ou 3. Une fois la classe d'appartenance de la relation à imputer ainsi estimée, l'imputation était réalisée dans cette classe, par hot-deck stratifié selon le secteur d'activité de l'entreprise et son appartenance ou non à un groupe.

2.2.2. Classification des relations

La première étape a donc consisté à classer, en groupes homogènes, les 2871 descriptions individuelles de relations disponibles pour la fonction *production*.

La méthode retenue a priori était le procédé de classification ascendante hiérarchique qui utilise la méthode de Ward comme stratégie d'agrégation pour constituer des groupes de relations à la fois homogènes (inertie intra-groupe faible), et les plus distincts possibles les uns des autres (inertie inter-groupes forte) [4], [5].

Toutefois, une classification lancée sur l'ensemble des variables des descriptions individuelles ne permettait pas d'atteindre cet objectif.

Pour la fonction *production*, il faut rappeler que chaque relation était décrite, dans le questionnaire, au moyen de 12 variables possédant, au total, plus de 60 modalités. Ainsi, il y avait plus de 33 millions de combinaisons possible et donc 33 millions de relations distinctes possibles.

La classification, fondée sur ces variables, permettait évidemment de réduire ce nombre, mais pas à moins de 100 classes pour obtenir un modèle significatif. Ce nombre de classes était encore trop important pour mettre en œuvre le processus d'imputation des non-réponses envisagé.

De même, et contrairement à ce qui se fait usuellement pour le traitement de la non-réponse, les caractéristiques d'activités et de taille de l'entreprise n'ont pas été prises en compte dans la spécification des classes car elles n'apparaissaient pas comme les plus discriminantes à ce niveau. Ces caractéristiques n'avaient de fait qu'un faible pouvoir explicatif de la non-réponse partielle. En revanche, l'activité de l'entreprise (en NES 16) a été utilisée pour la stratification des hot-deck. Ceci afin de prendre en compte d'éventuelles spécificités sectorielles de second ordre.

Ainsi, la première opération a consisté à déterminer la combinaison de variables explicatives qui permettait de discriminer au mieux l'ensemble des relations dans un minimum de classes. Aucune variable ne s'éliminait d'elle-même dans la mesure où aucune corrélation entre les différentes variables du questionnaire n'a pu être mise en évidence (si ce n'est l'appartenance au groupe du partenaire et la sélection de certaines modalités de réponses spécifiquement dédiées aux relations intra-groupe !).

La première étape a ainsi consisté à définir le nombre maximum de variables définissant un modèle à quinze classes maximum, au risque sinon que les classes comportent trop peu de relations pouvant être mobilisées comme extrapolantes lors de la procédure de hot-deck. **Il s'est avéré qu'il fallait alors se limiter à quatre variables.**

Dès lors, plusieurs classifications ont été testées et a été retenue celle qui permettait d'obtenir le meilleur modèle en utilisant quatre variables et en conservant moins de quinze classes. **Le critère de sélection du modèle a été sa qualité statistique intrinsèque (pouvoir discriminant le plus élevé).** La signification économique des classes ainsi obtenues n'a joué aucun rôle, l'objectif demeurant le seul traitement de la non-réponse.

Pour la fonction *production*, ce modèle a été obtenu à partir des quatre variables suivantes :

- type de la relation (4 modalités)
- critère de sélection du partenaire (10 modalités)
- durée de la relation (3 modalités)
- appartenance ou non du partenaire au même groupe que l'entreprise interrogée (2 modalités)

Le choix des variables pour le modèle, même s'il a été opéré sans logique économique a priori comme rappelé ci-dessus, s'explique finalement assez bien d'un point de vue économique. En effet, le caractère intra ou hors groupe de la relation est extrêmement discriminant, la logique de groupe conduisant à des types de relation particuliers et des principes de sélection du partenaire bien spécifiques. De même, le type de relation est également discriminant pour tout ce qui concerne l'intensité de la relation ou son équilibre. En *production* par exemple, on peut surtout opposer certaines relations de sous-traitance en tant que preneur d'ordre aux autres types de relations.

Ce résultat est plutôt positif même s'il n'était pas recherché a priori. On peut donc réussir à caractériser économiquement les classes ainsi constituées. Le tableau ci-dessous offre une description simplifiée des principales caractéristiques de chaque strate issue du modèle.

Tableau 2 : Description des 12 classes pour la fonction *production*

Principales caractéristiques de chaque classe	Nombre de relations de la classe	Perte d'inertie inter
Le critère de sélection du partenaire est sa proximité	171	106
Le type de relation est la gestion d'une structure commune	125	70
Relation intra groupe de sous-traitance dans laquelle le partenaire a été imposé par le groupe	774	68
Relation de sous-traitance dans laquelle l'entreprise n'a pas choisi son partenaire	630	62
Les relations de faible durée (moins d'un an)	119	58
Le type de la relation est indéfini (modalité "autre")	183	57
Le critère de sélection du partenaire est sa notoriété	186	54
Le critère de sélection du partenaire est la recherche d'un contrat de longue durée	214	50
Le critère de sélection du partenaire est le délai	52	47
Le critère de sélection du partenaire est la complémentarité des compétences entre les partenaires	148	43
Le critère de sélection du partenaire est son prix	217	42
Le critère de sélection du partenaire est ses garanties en termes de qualité	52	38
Total	2871	695

2.2.3. Détermination de la classe d'appartenance de la relation à imputer

A l'issue de l'étape précédente, chacune des 2871 relations de *production* disponibles (correctement renseignées par les entreprises) appartenait donc à l'une des 12 classes.

Par la suite, seules les entreprises ayant décrit toutes les relations qu'elles étaient censées décrire et ayant au moins deux relations pour la fonction *production* ont été retenues. Environ 500 entreprises répondaient à ces critères.

Pour ces entreprises, des probabilités conditionnelles ont été calculées. Il s'agissait de connaître la probabilité d'avoir une deuxième relation de classe X sachant que la classe de la première relation pour cette même entreprise était Y. Des fréquences observées ont donc été déduites les probabilités conditionnelles suivantes.

$P(X/Y) = (\text{nombre d'entreprises dont la relation n}^\circ 2 \text{ appartient à la classe X et la relation n}^\circ 1 \text{ à la classe Y}) / (\text{nombre d'entreprises dont la relation n}^\circ 1 \text{ appartient à la classe Y})$

Tableau 3 : Probabilités conditionnelles pour la fonction *production* et pour la relation n°2

Classe de la première relation	Classe de la seconde relation											
	1	2	3	4	5	6	7	8	9	10	11	12
P (X / Y) (en %)												
1	40.00	0.00	5.00	15.00	0.00	5.00	5.00	0.00	0.00	5.00	20.00	5.00
2	0.00	35.71	14.29	7.14	0.00	7.14	7.14	14.29	0.00	7.14	7.14	0.00
3	1.68	5.04	57.98	10.92	2.52	1.68	5.04	0.84	2.52	5.04	5.88	0.84
4	2.50	0.00	5.00	77.50	0.83	1.67	2.50	4.17	0.00	1.67	3.33	0.83
5	0.00	0.00	10.00	5.00	40.00	5.00	5.00	10.00	0.00	15.00	10.00	0.00
6	4.17	0.00	0.00	12.50	8.33	75.00	0.00	0.00	0.00	0.00	0.00	0.00
7	5.56	0.00	5.56	8.33	5.56	2.78	44.44	8.33	0.00	2.78	16.67	0.00
8	2.70	0.00	5.41	18.92	0.00	2.70	2.70	62.16	0.00	2.70	2.70	0.00
9	0.00	0.00	16.67	0.00	16.67	16.67	0.00	0.00	33.33	0.00	0.00	16.67
10	0.00	8.33	16.67	16.67	0.00	0.00	8.33	8.33	0.00	41.67	0.00	0.00
11	5.41	0.00	8.11	10.81	0.00	2.70	2.70	0.00	5.41	5.41	59.46	0.00
12	0.00	12.50	0.00	0.00	12.50	0.00	0.00	0.00	0.00	12.50	0.00	62.50

Lecture : sachant que la 1^{ère} relation décrite par l'entreprise appartient à la classe 1, la 2^{ème} relation décrite appartient à la classe 1 avec une probabilité de 0,4, à la classe 3 avec une probabilité de 0,05, à la classe 4 avec une probabilité de 0,15, à la classe 6 avec une probabilité de 0,05, à la classe 7 avec une probabilité de 0,05, etc..

Les mêmes calculs ont été faits pour les relations de rang 3 et de rang 1.

Fait à souligner, c'est la classe de la 1^{ère} relation qui avait la probabilité la plus grande d'être la classe d'appartenance des deux autres relations (cf. la diagonale principale du tableau ci-dessus). Autrement dit, c'est toujours la probabilité $P(X/X)$ qui était la plus élevée et pour la moitié des classes elle représentait même plus de 50% des cas. Ceci venait au demeurant confirmer les conclusions tirées des rappels d'entreprises qui n'avaient pas décrit suffisamment de relations : les relations manquantes étaient majoritairement, mais pas systématiquement, des relations du même type que celle décrite. Ainsi, la cause principale de ce type de non-réponse partielle était le peu d'envie de l'entreprise à recopier une nouvelle fois une description déjà donnée.

Ce résultat venait donc valider la démarche choisie : **le comportement des répondants et des non-répondants semblait donc peu éloigné à ce niveau. Il était donc légitime de se fonder sur le comportement des entreprises répondantes pour imputer les relations absentes.** Ceci validait donc l'un des quatre grands principes du traitement de la non-réponse présentés en introduction.

2.2.4. Estimation des relations absentes

Nous disposions donc d'une relation et de sa classe d'appartenance pour chaque fonction. En utilisant les probabilités conditionnelles calculées précédemment, nous étions donc en mesure de définir la classe de la (ou des) relations(s) à estimer en utilisant un processus aléatoire. En d'autres termes, ces classes ont été déterminées par un tirage à probabilités inégales, ces dernières étant celles calculées précédemment.

Exemple

Supposons que devait être imputée la relation de rang 2 d'une entreprise dont la première relation appartenait à la classe n°6.

Un numéro aléatoire entre 0 et 100 avait été affecté à chaque relation à imputer. Supposons que pour la relation n°2 à estimer, ce numéro aléatoire ait été : $A=39$.

Du tableau n°3 précédent, on déduit :

- si $A \in [0,4.17]$ alors la relation n°2 à imputer devait relever de la classe 1
- si $A \in [4.17,16.67]$ alors la relation n°2 à imputer devait relever de la classe 4
- si $A \in [16.67,25]$ alors la relation n°2 à imputer devait relever de la classe 5
- si $A \in [25,100]$ alors la relation n°2 à imputer devait relever de la classe 6

Soit dans la cas présent ($A=39$), la classe de la relation n°2 aurait été la classe 6

Une fois la classe de la relation à imputer connue, son estimation était réalisée via un hot-deck stratifié.

Les strates du hot-deck croisaient les trois variables suivantes :

- classe de la relation à estimer
- APE de l'entreprise en NES 16
- appartenance ou non de l'entreprise à un groupe.

Pour que la procédure d'imputation par hot-deck soit possible, il est nécessaire que le nombre de « donneurs » potentiels soit suffisant par rapport au nombre de relations à estimer.

Les deux tableaux montrent que dans le cas présent, cette procédure était applicable.

Tableau 4: Distribution des rapports entre le nombre de relations à imputer et le nombre de donneurs

Quantile	Rapport
Minimum	0.06
10%	0.2
1er quartile	0.2
Médiane	0.3
3e quartile	0.5
Maximum	3,3

Ainsi, pour plus de la moitié des strates, il y a trois fois plus de donneurs (extrapolantes) que de relations à extrapoler.

Tableau 5: Nombre de relations extrapolantes (donneurs) par strate

Quantile	Nombre d'extrapolantes
Minimum	1
10%	2
1er quartile	6
Médiane	16
3e quartile	36
Maximum	378

Ainsi, pour plus des $\frac{3}{4}$ des strates il y avait au moins 6 relations « extrapolantes » potentielles et pour plus des $\frac{2}{3}$ il y en avait au moins 10.

2.2.5. Résultat de la procédure d'imputation

Le tableau ci-dessous présente le résultat de ce traitement de la non-réponse pour chaque fonction.

Tableau 6: Les résultats de l'imputation

	Production	Approvisionnement	Commercialisation	Services auxiliaires	R&D	Total
Nombre de relations décrites	2871	3552	2168	1825	1349	11765
Nombre de relations imputées	735	917	513	370	260	2795
Part des relations imputées (%)	20%	21%	19%	17%	16%	19%

Dans le fichier final, environ une relation sur cinq (19%) a donc été imputée. Ce chiffre est assez important mais, comme vont le démontrer les résultats suivants, ces corrections ne modifient pas de façon significative les résultats finaux de l'enquête.

2.2.6. Variabilité de l'estimation des non-réponses partielles

L'estimation de la variance générée par cette imputation de la non-réponse a été faite de façon empirique.

Elle a été estimée à partir de la génération de 100 hot-deck différents. Les résultats de chaque procédure d'estimation (100 au total) ont ensuite été agrégés aux résultats des relations correctement décrites.

Le tableau suivant présente pour chaque modalité de réponse de la fonction *production* :

- la fréquence observée sur les relations correctement décrites initialement,
- la moyenne des fréquences calculées après incorporation des 100 hot-deck. Autrement dit, les moyennes de la 3^{ème} colonne sont calculées sur l'ensemble des relations (imputées et non imputées)
- et enfin l'écart type de ces fréquences

L'écart type issu de cette procédure est de l'ordre de 0,3 point pour les modalités. Ainsi, l'intervalle de confiance des résultats est de l'ordre du point (avec un seuil de significativité à 5%).

Ce résultat est très satisfaisant d'autant que la moyenne observée en tenant compte du hot-deck est souvent très proche (inférieur à 0,2 point) de la valeur initialement observée.

Ces résultats confortent donc la méthode choisie, le traitement de la non-réponse n'induisant pas une forte variabilité des résultats.

D'autre part, comme on a pu le constater précédemment, ce faible écart-type ne provient pas d'un nombre limité d'extrapolantes (donneurs) mais bien d'une grande homogénéité des strates utilisées pour les hot-deck. En effet, un faible nombre d'« extrapolantes » aurait mécaniquement réduit l'écart type. Dans le cas présent, le taux de recouvrement des différents hot-deck était toujours très faible ; c'est-à-dire que le nombre de relations effectivement choisies comme extrapolantes et qui s'avéraient être communes à deux procédures de hot-deck étaient rares.

L'estimation de la variance due à la procédure d'estimation des non-réponses partielles semble donc assez robuste. Elle peut donc être considérée comme un bon indicateur de la qualité du processus mis en place.

Tableau 7: Les résultats de l'imputation en termes de fréquence et de variabilité des résultats

Variables (et modalités de réponse)	Fréquence observée sur les relations correctement décrites (en %)	Fréquence moyenne sur 100 hot-deck (en %)	Ecart-type des fréquences après 100 hot-deck (en %)
Nature du partenaire			
Entreprise	93,1	93	0,17
Groupement d'entreprises	6,8	6,8	0,17
Groupe			
Relations intra groupe	41,9	40,8	0,31
Relations hors groupe	58,1	59,1	0,31
Secteur du partenaire			
Commerce	8,6	8,5	0,19
Service	9,5	9,5	0,2
Industrie	72,1	71,9	0,28
Iaa	1,8	1,7	0,1
Transport	3	3,1	0,13
Construction	4,9	4,9	0,16
Localisation du partenaire			
Echelon local	13,2	13,1	0,23
Même région	20,9	20,9	0,27
Autre région	34,1	34,2	0,29
UE	22,3	22,1	0,28
USA	3,2	3,1	0,11
Japon	0,3	0,3	0,04
Asie	1,3	1,3	0,07
Autre région	4,3	4,3	0,14
Critères (2 au plus) de sélection du partenaire			
Choix guidé par le groupe	34,8	33,5	0,29
Moyens techniques	22,4	22,5	0,31
Notoriété	6,7	7,1	0,17
Prix	12	12,3	0,24
Respect des délais	6,1	6,7	0,18
Proximité	6,1	6,1	0,16
Complémentarité	12,3	12,6	0,26
Contrat de longue durée	9,3	9,4	0,18
Sans objet (chois opéré par le partenaire)	18,6	18,3	0,19
Type de la relation			
Mise en commun de moyen	15,6	15,2	0,21
Sous-traitance	67,3	67,2	0,32
Structure commune	6,9	6,8	0,16
Autre	10,2	10,6	0,21
Raison de mise en place de la relation			
Mode imposé par groupe	33,1	32,1	0,29
Economie d'échelle	18,7	18,5	0,26
Accès à de nouveaux marchés	30,1	30,4	0,34
Rentabiliser un investissement	15,8	15,8	0,26
Absence des compétences	13	13,3	0,25
Absence des équipements	11,8	12,1	0,25
Recherche de flexibilité	14,2	14,3	0,24
Durée de la relation			
Moins d'1 an	4,6	4,6	0,11
De 1 à 5 ans	30,2	30,6	0,35
Plus de 5 ans	65,2	64,6	0,35
Leader de la relation			
Vos conditions sont appliquées	13,6	13,6	0,26
ses conditions sont appliquées	26	25,9	0,31
Equilibre entre les partenaires	60,4	60,3	0,34

2.3. Les limites du modèle retenu

Une des limites de la méthode utilisée concerne la définition des classes de relations. Il était nécessaire de retenir un modèle dans lequel le nombre de classes était limité (afin de disposer de suffisamment de relations extrapolantes par strates) et dont le pouvoir explicatif était suffisant. De ce fait, il n'a pas été possible de retenir plus de 4 variables alors que les relations étaient caractérisées par 12 variables. En effet, avec plus de 4 variables, il n'était pas possible d'obtenir un modèle suffisamment discriminant avec moins de 20 classes. Par ailleurs, même en ne retenant que 4 variables, le meilleur modèle, qui a été retenu, n'était pas d'excellente qualité vu que la perte d'inertie inter-classes n'était que de 695 sur 1000.

Un autre point faible concerne le calcul des probabilités conditionnelles, établi sur seulement un peu plus de 500 entreprises.

Enfin cette procédure a un dernier inconvénient dont il faudra tenir compte lors de l'analyse des descriptions individuelles des relations. Par construction, le modèle choisi utilise une certaine typologie des relations. Or, comme il a été vu plus haut, l'un des objectifs de cette enquête est de proposer une nouvelle typologie de relations. Il faudra alors être vigilant afin que la procédure d'imputation des non-réponses ne biaise pas l'analyse finale en mettant d'abord en évidence les classes justement utilisées pour l'extrapolation des non-réponses partielles. Il s'agirait alors d'un "classique" artefact statistique.

3. Les entreprises dont l'absence de relation paraissait suspecte

3.1. Présentation du problème

Il s'agissait d'entreprises connues, grâce à l'enquête annuelle d'entreprises (EAE), comme étant donneuses ou preneuses d'ordre et qui n'avaient déclaré aucune relation dans l'enquête ERIE.

Le champ des relations à prendre en compte (explicité en première page du questionnaire) n'a pas toujours été bien compris par les entreprises. Ainsi, alors qu'il était clairement indiqué que toutes les relations de sous-traitance relevaient du champ de l'enquête, la mention qui était faite presque simultanément dans la "notice explicative" que l'enquête s'intéressait avant tout aux relations impliquant un minimum de coopération a entraîné des erreurs de réponse (sous forme de non-réponses) : telle entreprise sous-traitante, considérant que la relation avec son donneur d'ordre n'était pas coopérative, déclarait alors dans l'enquête ERIE n'avoir aucune relation relevant du champ de l'enquête.

L'EAE a un volet sur la sous-traitance, grâce auquel sont repérées les entreprises sous-traitantes ou donneuses d'ordre. Grâce à cette information exogène à l'enquête, certaines réponses mentionnant aucune relation étaient considérées comme suspectes. Un échantillon d'entreprises dans cette situation a ainsi été rappelé, la charge qu'aurait représentée le rappel de toutes les entreprises concernées ayant été jugée trop grande.

L'échantillon a été stratifié selon leur degré de sous-traitance (ou de donneur d'ordre).

Ainsi, les entreprises, a priori concernées par ces rappels, ont été classées selon l'intensité de leur « dépendance » observée dans l'enquête structurelle (EAE). Trois niveaux de preneur d'ordre et trois de donneur d'ordre (cf. tableau n°8 ci-dessous) ont ainsi été définis : chaque entreprise étant affectée à une catégorie de preneur d'ordre et une catégorie de donneur d'ordre.

Un échantillon a ensuite été tiré dans chaque catégorie parmi les entreprises dont l'absence de relations déclarées dans ERIE était considérée comme suspecte. Ainsi, 490 entreprises devaient être rappelées par les gestionnaires d'enquête pour lever l'incohérence entre leur réponse à l'enquête ERIE et celle fournie à l'EAE. Toutefois, faute de temps, tous les recontacts n'ont pu

avoir lieu, seuls 225 (sur 490) ayant pu être réalisés ; ceci a fragilisé quelque peu la procédure d'imputation des non-réponses.

Tableau 8 : Les différentes catégories d'entreprises dont l'absence de relations déclarées dans ERIE apparaissait comme suspecte (P=preneurs d'ordre ; D=donneurs d'ordre)

P1	Entreprises ayant déclaré, dans l'EAE, réaliser au moins 50 % de leur chiffre d'affaires, en tant que preneur d'ordre, pour chacun des deux derniers exercices comptables
P2	Entreprises, preneuses d'ordre, ayant déclaré dans l'EAE réaliser moins de 50 % de leur chiffre d'affaires, en tant que preneur d'ordre, pour au moins un des deux derniers exercices comptables
P3	Entreprises non sous-traitantes, selon l'EAE, au cours des deux derniers exercices
D1	Entreprises répertoriées comme donneuses d'ordre dans le répertoire statistique de l'industrie (Ful)
D2	Entreprises ayant déclaré, dans l'EAE, un montant de sous-traitance en tant que donneur d'ordre, au moins une des deux dernières années
D3	Entreprises considérées comme non donneuses d'ordre selon l'EAE

Pour chaque entreprise rappelée, il s'agissait de déterminer parmi les situations mentionnées ci-dessous laquelle était la bonne et d'obtenir, le cas échéant, les corrections souhaitables :

- l'entreprise a bien des relations de sous-traitance (preneur ou donneur d'ordre) mais a considéré, à tort, que celles-ci n'entraient pas dans le champ de ERIE : si tel était le cas, l'objectif était d'obtenir la réponse corrigée ;
- l'entreprise n'a pas de relation de sous-traitance et c'est l'enquête structurelle (EAE) qui comporte, de fait, une erreur : dans ce cas, la réponse de l'entreprise n'était plus considérée comme « suspecte » dans ERIE.

3.2. Présentation des traitements mis en œuvre et variance associée

L'hypothèse faite initialement, au moment du rappel des entreprises, était que certaines d'entre elles n'avaient pas compris que toutes les relations de sous-traitance étaient à prendre en compte dans ERIE. Ainsi l'objectif initial, lors du rappel, était de corriger uniquement les réponses faites pour la fonction *production*¹ par les entreprises preneuses d'ordre et celles relatives à la fonction *approvisionnement*² par les entreprises donneuses d'ordre. Cependant, les réponses des entreprises rappelées sont venues perturber cet a priori. En effet, plusieurs entreprises qui n'avaient pas spontanément décrit de relations, ont profité de ce rappel pour décrire des relations dans toutes les fonctions, donc au-delà des seules fonctions de production ou d'approvisionnement.

Dès lors, plusieurs possibilités d'extrapolation de ces non-réponses étaient envisageables ; les deux problématiques suivantes ont été testées et détaillées ci-dessous :

- Méthode 1 : **traiter uniquement et indépendamment les deux fonctions *production* et *approvisionnement*** : autrement dit, redresser les éventuelles non-réponses de la fonction *production* en fonction du degré de preneur d'ordre de l'entreprise (P1, P2 et P3), et ensuite redresser celles de la fonction *approvisionnement* en fonction du degré de donneur d'ordre de l'entreprise (D1, D2 et D3) ; mais également, ne redresser aucune autre possible non-réponse dans le cadre d'une autre fonction.

ou

- Méthode 2 : **redresser en totalité et simultanément la réponse de l'entreprise** : autrement dit, redresser l'ensemble des fonctions de l'entreprise en une seule fois, en tenant compte simultanément des degrés de preneur et de donneur d'ordre de l'entreprise (beaucoup d'entreprises, dans certains secteurs, sont à la fois sous-traitantes et donneuses d'ordre). Ainsi les entreprises étaient réparties en 9 groupes (P1D1, P1D2 etc.).

¹ La fonction production contenait par définition l'ensemble des relations de sous-traitance en tant que preneur d'ordre

² La fonction approvisionnement contenait par définition l'ensemble des relations de sous-traitance en tant que donneur d'ordre

Ces deux méthodes se basaient toutefois sur le même principe d'extrapolation :

- **étape 1 : décision pour chaque entreprise "suspecte" de redresser ou non ses réponses (non-réponses en l'occurrence)** selon son degré de preneur et/ou donneur d'ordre. Dans le cadre de la méthode 1, cette décision, pour chaque entreprises suspecte, était prise indépendamment pour la fonction *production* et pour la fonction *approvisionnement*. Alors que pour la méthode 2 il s'agissait de choisir les entreprises qui verraient leur réponse redressée dans leur globalité.
- **étape 2 : extrapolation proprement dite (imputation des non-réponses) par hot-deck** des entreprises à redresser. Dans la méthode 1, l'extrapolante était toute une fonction (*production* ou *approvisionnement*) d'une entreprise alors que dans la méthode 2 l'extrapolante était une entreprise.

3.2.1. Présentation de la méthode 1

Seules les fonctions *production* des entreprises preneuses d'ordre et *approvisionnement* des entreprises donneuses d'ordre ont été corrigées par cette méthode. Elle ne prenait donc pas en compte le fait que certaines entreprises rappelées avaient éventuellement décrit des relations dans toutes les fonctions.

De plus, cette méthode supposait une corrélation positive entre le degré de preneur ou donneur d'ordre de l'entreprise et son comportement de réponse.

Les entreprises avaient donc été regroupées selon leur degré de preneur d'ordre (P1, P2 et P3) pour le redressement de la fonction *production* et selon leur degré de donneur d'ordre (D1, D2 et D3) pour le redressement de la fonction *approvisionnement*.

Le redressement (imputation) par hot-deck a ensuite été réalisé indépendamment pour les fonctions *production* et *approvisionnement*.

Ainsi une entreprise dont la réponse avait été jugée erronée (absence de relations déclarées jugée suspecte) avait pu voir sa fonction *production* corrigée par recopie des données d'une entreprise de même catégorie de preneur d'ordre (P1, P2 ou P3) et sa fonction *approvisionnement* corrigée par recopie des données d'une autre entreprise de même catégorie de donneur d'ordre (D1, D2 ou D3).

3.2.1.1. Analyse des entreprises rappelées

Dans cette partie, seuls les résultats concernant la fonction *production* sont présentés. Les mêmes traitements ont été réalisés pour la fonction *approvisionnement*.

Les catégories de preneur et de donneur d'ordre utilisées par la suite sont celles définies dans le tableau n°8.

Tableau 9 : Réponses des entreprises (dans ERIE) avant et après les rappels, en fonction de la catégorie de preneur d'ordre des entreprises

Catégorie de preneur d'ordre	Réponse initiale des entreprises			Réponse des Entreprises rappelées ³		
	Sans relation	Avec relation	Total	Sans relation ⁴	Avec relation ⁵	Total
Fortement	231 30.2 %	535 69.8 %	766	6 15%	34 85%	40
Peu	200 28.3 %	506 71.7 %	706	20 83.3 %	4 16.7 %	24
Pas du tout	801 31.5	1742 68.5	2543	52 49.5 %	53 50.5 %	105
Total	1232 30.7 %	2783 69.3 %	4015	78 46 %	91 54 %	169

Lecture : parmi les 706 entreprises préalablement repérées par l'enquête annuelle d'entreprise comme "peu" sous-traitante, 28.3% avaient spontanément déclaré dans ERIE ne pas avoir de relation avec une autre entreprise (71.7% avaient déclaré le contraire). Parmi les 200 qui n'avaient spontanément déclaré aucune relation, 24 ont fait l'objet d'un rappel ; lors de ce rappel, 83.3% d'entre elles ont confirmé cette absence de relation, 16.7% modifiant en revanche leur réponse initiale.

³ les entreprises rappelées ont été sélectionnées par échantillonnage parmi les entreprises s'étant déclarées initialement sans relation

⁴ pas de correction de leur réponse initiale

⁵ correction de leur réponse initiale

Ce tableau illustre que l'hypothèse initiale selon laquelle certains preneurs d'ordre avaient omis de décrire leurs relations de sous-traitance était fondée. Cela confirme donc le sentiment ressenti lors des tests en entreprises, à savoir que les preneurs d'ordre ne considéraient pas leurs relations de sous-traitance comme d'authentiques relations du fait de l'absence de collaboration avec le donneur d'ordre.

En effet, d'après les réponses initiales, les entreprises sous-traitantes ne paraissaient pas avoir une propension à avoir des relations supérieure aux autres : les entreprises sans relation représentant environ 30% des entreprises quelle que soit leur catégorie de preneur d'ordre. Ceci était surprenant vu que l'on s'attendait à ce que la totalité des preneurs d'ordre déclarent au moins une relation en *production*.

De plus, l'analyse des rappels d'entreprises montre que les entreprises fortement sous-traitantes ont plus souvent corrigé leur réponse que les autres (85%, cf. tableau 9).

Ainsi, en appliquant directement les conclusions des rappels, 85 % des réponses des entreprises fortement preneuses d'ordre et sans relation "spontanée" dans ERIE devaient être redressées, car considérées avec au moins une non-réponse partielle. Au final, il ne devait donc plus rester qu'environ 4,5%⁶ des entreprises fortement preneuses d'ordre considérées sans relations dans ERIE.

Toutefois, ce premier tableau ne permet pas de conclure totalement. En effet, l'analyse faite ici ne prend en compte que la correction de la réponse par l'entreprise lors de son rappel, sans s'intéresser au contenu même de cette correction.

Le tableau suivant détaille la nature des relations déclarées par les entreprises lors du rappel (il ne s'agit toujours que des entreprises repérées par ailleurs comme sous-traitantes et sans relations déclarées dans l'enquête ERIE) ; il s'agit donc d'un zoom sur les 91 entreprises du tableau 9.

Tableau 10 : Réponses des entreprises avant et après les rappels pour la fonction *production* selon la catégorie de preneur d'ordre des entreprises

Catégorie de preneur d'ordre	Réponse initiale des entreprises			Réponse des entreprises rappelées		
	sans relation en <i>production</i>	avec au moins une relation en <i>production</i>	Total	Toujours sans relation en <i>production</i>	avec au moins une relation en <i>production</i>	Total
Fortement	89 16 %	446 84 %	535	2 6 %	32 94 %	34
Peu	160 39 %	346 61 %	506	2 50 %	2 50 %	4
Pas du tout	936 54 %	806 46 %	1742	41 77 %	12 23 %	53
Total	1185 43 %	1598 57 %	2783	45 49 %	46 51 %	91

A priori, le rappel des entreprises preneuses d'ordre devait se traduire par une correction de leur fonction *production*. Ceci est avéré pour les entreprises fortement preneuses d'ordre puisque, parmi celles qui ont corrigé leur réponse, plus de neuf entreprises sur dix ont rajouté des relations en *production*.

En outre, comme pressenti, moins d'une entreprise sur quatre « pas du tout » preneuse d'ordre a corrigé sa fonction *production*. Si ces entreprises ont été rappelées initialement, c'est parce qu'elles étaient donneuses d'ordre a priori⁷. Ce n'est donc pas une surprise que de voir leur fonction *production* inchangée, au contraire.

⁶ Le 4.5% est obtenu en multipliant la part d'entreprises fortement preneuse d'ordre sans relation (30.2%) par le taux d'entreprises non corrigées de cette catégorie (15%).

⁷ Près de 60% de ces entreprises ont alors corrigé leur fonction approvisionnement.

Le résultat sur les entreprises répondantes est également intéressant car il confirme bien cette fois la corrélation entre le fait d'être preneur d'ordre et celui d'avoir au moins une relation en *production*. **En effet, il apparaît que plus une entreprise est fortement preneuse d'ordre (au sens de la part de son chiffre d'affaires réalisé en sous-traitance) et plus elle a une probabilité importante d'avoir au moins une relation en *production* . Dès lors, il semble logique d'utiliser le degré de preneur d'ordre comme critère de classification pour obtenir des groupes de comportement homogène.**

Ces différents éléments ont donc été utilisés pour le redressement.

3.2.1.2. Principe du redressement adopté

Les réponses des rappels d'entreprises ont donc été utilisées pour définir la proportion d'entreprises pour lesquelles la fonction *production* devait être corrigée (relations à extrapoler). Certes, le nombre de réponses n'était pas très important mais les réponses allaient dans le sens attendu et de façon significative ; ces informations ont donc été mobilisées.

Ainsi, une entreprise "fortement" preneuse d'ordre a donc eu une probabilité de 0,8⁸ de voir sa fonction *production* redressée, la probabilité étant de 0,25 pour une entreprise "peu" preneuse d'ordre et de 0,1 pour une entreprise "pas du tout" preneuse d'ordre.

Certaines différences ont été notées dans les descriptions de relations (caractéristiques des relations décrites) entre les entreprises "bonnes" répondantes initialement et les entreprises rappelées (cf. les deux premières colonnes du tableau 16). Toutefois elles sont principalement dues à des différences structurelles entre les deux populations. En particulier, parmi les entreprises rappelées, 67% étaient fortement preneuses d'ordre, contre 18% seulement parmi les entreprises répondantes. Les tests de comparaison des fréquences entre ces deux populations n'ont pas pu être effectués en tenant compte de cette différence de structure du fait d'effectifs trop faibles.

De plus, il n'était pas possible d'utiliser uniquement les réponses des 46 entreprises rappelées comme extrapolantes, ce nombre étant bien trop faible par rapport au nombre d'entreprises à corriger.

Contrairement à l'objectif initial, les rappels n'ont donc pas permis de conclure à une réelle différence, quant aux caractéristiques des relations décrites, entre les réponses spontanées des entreprises et celles des entreprises rappelées. De ce fait, les imputations des relations "manquantes" ont été faites sous l'hypothèse de "relation identique" entre les entreprises non suspectes et celles des entreprises à extrapoler. Seul le comportement de réponse, et donc le taux de correction, a été déduit des rappels.

Ainsi, les entreprises servant d'extrapolantes pour le hot-deck étaient d'une part les entreprises ayant décrit des relations de *production* dans leur réponse originelle et d'autre part les entreprises "sans relation suspecte" ayant fait l'objet d'un rappel et ayant corrigé leur réponse (en déclarant alors, et en les décrivant, des relations).

Les strates du hot-deck ont croisé les variables suivantes (28 strates effectives sur 30 possibles) :

- catégorie de preneur d'ordre (trois modalités)
- activité en Nes16 (cinq modalités)
- appartenance ou non à un groupe (deux modalités)

⁸ 0,8 est le produit de la part des entreprises P1 ayant corrigé leur réponse (0.85) par la part des entreprises P1 ayant corrigé leur fonction production parmi les entreprises P1 qui ont corrigé leur réponse (0.94).

L'extrapolation s'est déroulée en deux étapes :

1. décider si oui ou non la réponse initiale (absence de relations) devait être redressée. Pour ce faire, le taux de correction par strate, fonction du niveau de preneur d'ordre comme vu précédemment, a été utilisé. La décision était prise à l'aide d'une procédure aléatoire⁹ ;
2. si la réponse devait être corrigée, l'imputation était faite par hot-deck stratifié. C'est-à-dire que la fonction *production* d'une entreprise appartenant à la même strate que l'entreprise à extrapoler et sélectionnée aléatoirement était recopiée dans la fonction *production* de l'entreprise à redresser.

L'analyse de la variance de cette procédure d'imputation est donnée au point 3.2.4.

3.2.2. Présentation de la méthode 2

Bien qu'initialement les rappels ne visaient à corriger les seules non-réponses (supposées) des fonctions *production* et *approvisionnement*, il s'est avéré qu'un certain nombre d'entreprises rappelées a déclaré des relations dans d'autres fonctions, comme l'illustre le tableau ci-dessous.

Tableau 11 : Fonctions corrigées par les entreprises rappelées

	<i>Production</i>	<i>Approvisionnement</i>	<i>Commer- cialisation</i>	<i>Services auxiliaires</i>	<i>R&D</i>
Nombre d'entreprises ayant corrigé leur réponse	46	54	7	7	8
Part (en %) des entreprises rappelées	51	59	8	8	9

Ce rappel avait donc permis de corriger deux types d'entreprises et donc de non-réponses :

- des entreprises qui n'avaient pas compris que l'ensemble des relations de sous-traitance faisait partie du champ de l'enquête ERIE (non-réponse par incompréhension) ;
- des entreprises sous-traitantes qui s'étaient déclarées à tort sans relation par refus "classique" de réponse (plus de 10% des entreprises rappelées)¹⁰.

Aussi, si la première méthode (cf. paragraphe 3.2.1) permettait de corriger le premier type d'entreprises, elle ne prenait pas du tout en compte le deuxième type mis en évidence par les rappels.

L'objectif de cette deuxième méthode était justement d'essayer de prendre en compte ces deux causes de mauvaise réponse.

Il n'était toutefois pas possible a priori de distinguer ces deux types de non-réponse. De plus si les entreprises du premier type ne corrigeaient que les fonctions *production* et *approvisionnement*, fonctions contenant l'ensemble des relations de sous-traitance, les autres pouvaient quant à elles vouloir corriger l'ensemble de leurs fonctions. A partir de là, un redressement limité aux seules fonctions *production* et *approvisionnement* risquait de biaiser les résultats et éventuellement de diminuer une corrélation entre fonctions observée sur les entreprises répondantes. C'est pourquoi

⁹ Par exemple, pour les entreprises de la catégorie P1, comme 80% des réponses devaient être corrigées, si le nombre aléatoire tiré pour l'entreprise était inférieur à 0.8, la réponse de l'entreprise était redressée, sinon elle n'était pas modifiée.

¹⁰ Le questionnaire ERIE pouvait en effet favoriser certaines stratégies de non-réponse : si une entreprise se déclarait sans relation, elle n'avait plus à répondre qu'à une seule question ce qui était particulièrement rapide et la protégeait vis-à-vis du contentieux puisqu'elle avait répondu.

il a été décidé de chercher à redresser par hot-deck la totalité de la réponse de l'entreprise et non plus uniquement les fonctions *production* et *approvisionnement*. Les principes de ces corrections de réponse sont décrits ci-dessous.

3.2.2.1. Analyse des entreprises rappelées

Un même principe que celui présenté au point 3.2.1.1 a été suivi. Seules les strates ont changé. Elles croisaient, ici, les catégories de preneur et de donneur d'ordre décrites dans le tableau 8 (soient 9 classes selon le degré de preneur et de donneur d'ordre).

En effet, pour cette 2^e méthode, l'objectif était d'extrapoler "globalement" les fonctions de l'entreprise et non plus de procéder séquentiellement et indépendamment : d'abord la fonction *production* puis la fonction *approvisionnement*.

Toutefois, comme pour la méthode précédente, ce sont les catégories de preneur et donneur d'ordre qui ont permis de déterminer si la réponse initiale devait ou non être corrigée. Si correction il devait y avoir, l'entreprise « extrapolante » était à la fois de la même catégorie de preneur et donneur d'ordre que l'entreprise extrapolée.

Tableau 12 : Réponses des entreprises avant et après les rappels en fonction des catégories de preneur d'ordre et donneur d'ordre des entreprises rappelées

Catégorie de preneur d'ordre	Catégorie de donneur d'ordre	Réponses initiale (spontanée) des entreprises			Réponses des entreprises après rappel		
		Sans relation	Avec relation	Total	Sans relation	Avec relation	Total
P1	D1	1 12.5 %	7 87.5 %	8	0	0	0
P1	D2	205 30.6 %	465 69.4 %	670	4 12.1 %	29 87.9 %	33
P1	D3	25 28.4 %	63 71.6 %	88	2 28.6 %	5 71.4 %	7
P2	D1	1 3.6 %	27 96.4 %	28	0 0%	1 100%	1
P2	D2	165 27.7 %	431 72.3 %	596	15 88.2 %	2 17.8 %	17
P2	D3	34 41.5 %	48 58.5 %	82	5 83.3 %	1 16.7 %	6
P3	D1	27 12.2 %	194 87.8 %	221	1 6.7 %	14 93.3 %	15
P3	D2	516 29.6 %	1226 70.4 %	1742	51 56.7 %	39 43.3 %	90
P3	D3	258 45.5 %	322 55.5 %	580	0	0	0
Total		1232 30.7 %	2783 69.3 %	4015	78 46%	91 54 %	169

En règle générale, ce tableau confirme plutôt bien l'hypothèse a priori, à savoir que plus les entreprises sont fortement preneuses ou donneuses d'ordre et plus elles corrigent leur réponse initiale en déclarant finalement avoir des relations.

Vu la définition adoptée pour les entreprises fortement preneuses ou donneuses d'ordre et les réponses obtenues à l'issue des rappels, l'absence totale de relation pour ces entreprises paraît peu défendable. C'est pourquoi un fort taux de correction pour ces entreprises a été choisi. Le taux finalement retenu a été de 0,9.

Pour les autres catégories, le taux de correction était strictement fondé sur les résultats des rappels, en regroupant toutefois les catégories pour lesquelles il y avait peu d'entreprises.

Ainsi il a été décidé que pour les entreprises "peu" preneuses ou donneuses d'ordre, un taux de correction de 0,4 serait appliqué, le taux de 37% ayant été constaté sur les entreprises rappelées.

Les entreprises ni preneuses ni donneuses d'ordre n'avaient aucune raison, quant à elles, d'être redressées a priori. Parmi ces dernières, il en existait sans doute qui n'avaient pas totalement compris le questionnaire. Toutefois cette hypothèse n'a pas pu être vérifiée car l'échantillon des entreprises rappelées ne contenait aucune entreprise de ce type. Ne pouvant définir un taux de correction pour ces entreprises¹¹, il a donc été décidé de ne pas les corriger.

3.2.2.2. Principe du redressement adopté

Le même principe de redressement que précédemment a été utilisé. Seules les strates du hot-deck ainsi que la probabilité de correction par strate ont changé.

Les probabilités de corrections des réponses initiales ont finalement été les suivantes :

Tableau 13 : Taux de correction des entreprises sans relation déclarée a priori, selon leur degré de preneur d'ordre et/ou donneur d'ordre

Catégorie de sous-traitant	Catégorie de donneur d'ordre	Taux de correction
P1	D1	90%
P1	D2	90%
P1	D3	90%
P2	D1	90%
P2	D2	40%
P2	D3	40%
P3	D1	90%
P3	D2	40%
P3	D3	0%

Par la suite, la correction, si elle avait lieu d'être, était réalisée par hot-deck total¹² stratifié selon les catégories de preneur et donneur d'ordre (3 modalités chacune), l'activité principale (5 modalités en Nes16) et le statut en termes d'appartenance à un groupe (2 modalités).

La validité de la procédure de hot-deck a été vérifiée comme précédemment (cf. paragraphe 2.2.4).

¹¹ Ces entreprises représentent 18% des entreprises totales et 21% des entreprises sans relation dans ERIE.

¹² La réponse complète de l'extrapolante était imputée à l'entreprise extrapolée.

3.2.3. Choix de la méthode

La méthode finalement retenue est la méthode n°2. Les raisons de ce choix sont les suivantes :

- les résultats en termes de variance étaient quasiment identiques¹³.
- Les entreprises fortement donneuses ou preneuses d'ordre étaient les entreprises les plus souvent corrigées. Or ces entreprises avaient en majorité et deux fois plus souvent que les autres des relations uniquement en *production* ou uniquement en *approvisionnement* ou uniquement pour ces deux fonctions (50 % contre 25 % dans la population). Ainsi pour plus de la moitié de ces entreprises, seules les fonctions *production* et *approvisionnement* ont été corrigées. On rejoignait ainsi les résultats de la méthode 1.
- La méthode 2 avait l'avantage de prendre en compte les entreprises n'ayant pas compris le questionnaire ou ne voulant pas y répondre sincèrement.
- La méthode 2 permettait de ne pas casser une éventuelle corrélation inter-fonction.

La partie suivante détaille les résultats obtenus ainsi que la variabilité des résultats induite par la méthode.

3.2.4. Résultats obtenus et variances observées

3.2.4.1. L'ampleur des corrections

Après la collecte, il y avait 1232 entreprises sans relation. Parmi ces dernières, 510 ont finalement été corrigées (c'est-à-dire se sont vu attribuer au moins une relation dans une fonction).

Tableau 14 : Les résultats de cette imputation par fonction

	<i>Production</i>	<i>Approvisionnement.</i>	<i>Commerce</i>	<i>Services Auxiliaires</i>	<i>R&D</i>	Total
Nombre d'entreprises répondantes	1702	2010	1335	1155	914	2915
Nombre d'entreprises redressées	338	331	193	161	120	510
Nombre de relations des répondantes	3606	4469	2681	2195	1609	14560
Nombre de relations « créées »	733	773	368	319	222	2415

Ce tableau confirme bien que les fonctions *approvisionnement* et *production* ont été celles qui ont été le plus redressées (plus d'un quart des entreprises sans relations ont été redressées contre moins de 15% pour les autres fonctions). Ce résultat est conforme à l'hypothèse faite à l'origine puisque ce sont ces deux fonctions qui contiennent les relations de sous-traitance.

3.2.4.2. La variance du tableau des données de cadrage général

L'imputation des entreprises "sans relation à tort" concernait à la fois les données de cadrage général et les descriptions individuelles associées.

¹³ Des tests de stratifications plus fines dans le cas de la méthode 1 qui devait prendre en compte les différences observées sur les descriptions individuelles des entreprises rappelées par rapport au autres ont été réalisés. Mais ils n'ont pas permis une réduction de la variabilité des résultats.

Concernant le tableau de cadrage général, les résultats observés en termes de variance ne sont pas très satisfaisants. Toutefois, ce résultat est à relativiser tant la variabilité "originelle" au sein de chaque strate était importante comme le montre le tableau ci-dessous.

Tableau 15 : Variance des données de cadrage général

	Entreprises répondantes		Entreprises rappelées		Entreprises extrapolées Méthode 1				Entreprises extrapolées Méthode 2			
	Moy	E-T	Moy	E-T	Moyenne		Ecart-type		Moyenne		Ecart-type	
					Moy	E-T	Moy	E-T	Moy	E-T	Moy	E-T
Nombre total de relations	17,6	58,3	63,9	147,6	22,1	3,1	66,4	18,5	20,1	3,5	61	21
dont hors groupe	14,3	55,8	60,8	148,1	20,5	3,1	65,5	18,5	18,1	6,4	59,6	20,8
dont intra groupe	3,3	11,6	3	14,7	1,6	0,4	7,7	2,4	2	0,5	8,8	2,3
Part totale	48,7	39,5	67,6	39,5	56,9	2	39,1	0,6	53	2,7	39,5	0,8
dont hors groupe	26,9	35,6	59,2	43,9	45,2	2,1	40,5	0,7	39,6	2,5	39,7	0,8
dont intra groupe	21,8	34,1	8,4	23,2	11,7	1,4	27,1	1,9	13,4	1,5	28,5	1,9

Lecture : Les entreprises répondantes avaient en moyenne 17,6 relations en production avec un écart type de 58,3. Après rappel, les entreprises rappelées avaient en moyenne 63,9 relations en production avec un écart type de 147,6. Pour la méthode 1, à partir des 100 hot-deck générés, les entreprises extrapolées avaient en moyenne 22,1 relations avec un écart-type moyen de 66,4. Ces deux estimateurs avaient respectivement comme écarts-types, 3,1 et 18,5.

Remarque :

Cette hétérogénéité des données de cadrage général, au sein de chaque strate (APE en Nes36 croisée avec la taille des entreprises), a empêché l'utilisation de la moyenne comme caractéristique de tendance centrale lors de l'exploitation des données. Les analyses ont donc utilisé des classes définies à partir de la distribution de la variable étudiée. Par exemple la population des entreprises pouvait être répartie en quatre classes : les entreprises sans relation, avec de 1 à 5 relations, de 6 à 10 relations et avec 11 relations et plus.

La variabilité générée par l'extrapolation n'est pas un indicateur robuste de la qualité de cette dernière, tant la dispersion observée dans la population des répondantes est importante. Il n'a pas été possible de trouver des strates de réponses homogènes pour ces variables. Ces résultats n'ont donc pas remis en cause la procédure de redressement envisagée.

3.2.4.3. La variance au niveau des descriptions individuelles

La variance générée par le processus de hot-deck a été calculée de la même façon qu'au point 2 pour les descriptions individuelles, à savoir par génération de 100 hot-deck différents.

Le processus d'estimation de la variance a été considéré comme suffisamment robuste (la procédure de hot-deck étant légitime) pour que cette dernière soit utilisée comme un bon indicateur de la qualité du processus mis en place ; la faible variance traduisant bien l'homogénéité des strates du hot-deck.

En termes de variance, le tableau suivant présente les résultats observés pour chaque modalité de réponse :

- pour les entreprises répondantes avant imputation
- pour les entreprises rappelées
- pour les entreprises corrigées (moyenne des 100 hot-deck et écart-type associé), méthodes 1 et 2.

Tableau 16 : Fréquences et Variance des descriptions individuelles

Sont grisées dans ce tableau, les modalités de réponses pour lesquelles il y a une forte différence entre les réponses initiales et les réponses des entreprises extrapolées.

Variables (et modalités de réponse)	Fréquence observée sur les entreprises répondantes	Fréquence observée sur les entreprises rappelées	Méthode 1		Méthode 2	
			Fréquence moyenne à l'issue des 100 hot-deck	Ecart type des fréquences à l'issue des 100 hot-deck	Fréquence moyenne à l'issue des 100 hot-deck	Ecart type des fréquences à l'issue des 100 hot-deck
Nature du partenaire						
Entreprise	93,1	96	93,9	1,2	93,4	1,3
Groupement d'entreprises	6,8	4	6,1	1,2	6,6	1,3
Groupe						
Relations intra groupe	41,9	22,4	20,8	2,1	25,3	2,2
Relations hors groupe	58,1	77,6	79,2	2,1	74,7	2,2
Secteur du partenaire						
Commerce	8,6	1,3	7,3	1,2	7,3	1,4
Service	9,5	6,6	8,2	1,5	9,1	1,4
Industrie	72,1	88,2	73,5	2,4	73,8	2,3
Iaa	1,8	1,3	1,1	0,6	1,2	0,6
Transport	3	1,3	3,5	1	3,6	1
Construction	4,9	1,3	6,3	1,4	4,7	1,1
Localisation du partenaire						
Echelon local	13,2	14,5	15,6	1,8	15,1	1,7
Même région	20,9	21	25,7	2	26,7	2,4
Autre région	34,1	36,8	36,7	2	35,6	2,2
UE	22,3	17,4	16,1	1,7	1,6	2
USA	3,2	6,6	1,8	0,7	2,2	0,6
Japon	0,3	0	0,3	0,1	0,3	0,1
Asie	1,3	1,3	0,7	0,4	0,7	0,3
Autre région	4,3	1,3	2,7	0,7	2,7	0,8
Critères (2 au plus) de sélection du partenaire						
Choix guidé par le groupe	34,8	21,1	16	1,8	20,7	2,2
Moyens techniques	22,4	10,5	14,1	1,9	17,6	1,8
Notoriété	6,7	6,6	7,7	1,4	9,8	1,8
Prix	12	2,7	11,1	1,6	13,9	2
Respect des délais	6,1	4	5,5	1,2	6,9	1,3
Garanties en termes de qualité	4,6	5,3	4,1	1	7,6	1,5
Proximité	6,1	6,6	7,4	1,3	5	1,1
Complémentarité	12,3	9,2	9	1,4	11,3	1,5
Contrat de longue durée	9,3	9,2	10,4	1,6	10,7	1,4
Sans objet (chois opéré par le partenaire)	18,6	44,7	39,6	2,8	27,7	2,6
Type de relation						
Mise en commun de moyen	15,6	5,2	7,5	1,4	9,8	1,7
Sous-traitance	67,3	85,5	82,8	2,1	78	2,4
Structure commune	6,9	2,7	3,7	0,9	4,9	1,2
Autre	10,2	6,6	5,9	1,3	7,3	1,2
Raison de mise en place de la relation						
Mode imposé par groupe	33,1	19,8	18	2,1	20,5	2,1
Economie d'échelle	18,7	11,8	12,7	2,1	13,9	1,8
Accès à de nouveaux marchés	30,1	52,6	44,2	3,1	41	2,7
Rentabiliser un investissement	15,8	35,5	23,8	2,8	21,8	2,5
Absence des compétences	13	10,5	11,8	1,7	13,1	1,7
Absence des équipements	11,8	4	11	1,8	11,9	1,8
Recherche de flexibilité	14,2	7,9	11,9	1,7	12,7	1,7

Tableau 16 : Fréquences et Variance des descriptions individuelles (suite et fin)

Sont grisées dans ce tableau, les modalités de réponses pour lesquelles il y a une forte différence entre les réponses initiales et les réponses des entreprises extrapolées.

Variables (et modalités de réponse)	Fréquence observée sur les entreprises répondantes	Fréquence observée sur les entreprises rappelées	Méthode 1		Méthode 2	
			Fréquence moyenne à l'issue des 100 hot-deck	Ecart type des fréquences à l'issue des 100 hot-deck	Fréquence moyenne à l'issue des 100 hot-deck	Ecart type des fréquences à l'issue des 100 hot-deck
Durée de la relation						
Moins d'1 an	4,6	1,3	4,4	1,1	4,8	1,2
De 1 à 5 ans	30,2	35,5	28,2	2,4	28,7	2,8
Plus de 5 ans	65,2	63,2	67,3	2,6	66,4	2,8
Leader de la relation						
Vos conditions sont appliquées	13,6	10,5	11,3	1,7	12	1,7
ses conditions sont appliquées	26	38,2	33	2,6	29,4	2,1
Equilibre entre les partenaires	60,4	51,3	55,6	2,9	58,6	2,6
Intensité de la relation						
Relation stratégique	53,5	44,7	51	2,7	51,9	2,3
Coopération importante	40,1	43,4	38,7	2,9	38,4	2,7
Mise en place d'un mode de communication spécifique	13,9	6,6	12,9	2	13,3	1,9
Prise de risque partagée	13,2	6,6	11,1	1,6	11,3	1,6
Investissement matériel	17,3	5,3	16,9	2	15,9	1,8
Contrat écrit	32,8	18,4	29,9	2,6	29,9	2,7
Aucune affirmation	9,3	6,6	12,8	2	12,7	1,7
Quel rôle joue l'entreprise dans la relation ?						
Conception	40,6	35,5	33,8	2,7	36,2	2,4
approvisionnement	33,7	40,8	37,6	3	36,3	2,7
Réalisation du produit	80,2	86,8	89,7	1,6	86,9	1,8
Commercialisation	10,9	0	5,1	1,2	13,1	1,7
Autre	10,3	11,8	10,8	1,8	11,1	1,6
Si vous êtes sous-traitant sous quelle marque sont commercialisés les produits ?						
Votre marque	36,3	56,6	44,8	3,2	40,7	2,9
Sa marque	29	29	36	2,6	35,2	2,7

3.2.4.4. Différences entre entreprises répondantes et entreprises extrapolées

La colonne « Fréquence observée sur les entreprises rappelées » du Tableau 16 ne concerne que 46 entreprises ; les résultats ne sont donc pas très robustes. En revanche, les écarts entre les réponses des entreprises répondantes et celles des entreprises extrapolées sont eux significatifs (lignes grisées dans le tableau ci-dessus). Ils s'expliquent par les différences structurelles existant initialement entre ces deux populations.

Ces différences sont essentiellement dues à deux facteurs :

- la part d'entreprises hors groupe beaucoup plus importante parmi les entreprises à redresser
- les comportements différents en termes de relations selon le niveau de sous-traitance.

En effet, si parmi les répondantes, les entreprises indépendantes (hors groupe) représentaient moins de 20% des entreprises, elles étaient près de 50% parmi les entreprises sans relation et 44% parmi les entreprises finalement extrapolées. Ce résultat explique en partie les différences

importantes entre les entreprises extrapolées et les autres pour les modalités des variables relatives à l'appartenance à un groupe¹⁴.

Par ailleurs, les autres différences sont dues à une surreprésentation des relations de sous-traitance parmi les entreprises extrapolées (83% contre 67% parmi les répondantes initiales). En effet, les entreprises fortement preneuses d'ordres sont deux fois plus nombreuses parmi les entreprises extrapolées que dans la population totale. Ce sont également elles qui ont le plus de relations et pour lesquelles la part des relations de sous-traitance en tant que preneur d'ordre est la plus forte.

Les modalités de réponses relatives à la sous-traitance sont alors sur-représentées parmi les entreprises extrapolées et vice versa. Par exemple, il est logique de voir le critère de sélection du partenaire "ses moyens techniques" diminuer au profit de la modalité "sans objet". En effet, un grand nombre de sous-traitants ne choisissent pas leur partenaire mais sont sélectionnés par ce dernier. Et quand bien même ils choisiraient leur donneur d'ordre ce ne serait pas pour leurs compétences techniques qui les indiffèrent a priori.

Ce résultat est en outre plutôt rassurant. En effet, cette correction des réponses visait avant tout à corriger les réponses supposées erronées des entreprises sous-traitantes. Dès lors, il est logique que ce traitement favorise la description de relations de sous-traitance en production.

3.3. Critiques de la procédure mise en place

Ce redressement (imputation de non-réponses partielles) est non négligeable puisqu'il a concerné environ 10% des entreprises interrogées et que son impact sur les résultats est important puisqu'il s'ensuit une réduction de près de 40 % du nombre d'entreprises sans relation.

Toutefois, vu les résultats des rappels effectués lors de la collecte auprès de l'échantillon d'entreprises concernées, ce redressement était indispensable. Il a permis de corriger les réponses :

- des entreprises qui n'avaient pas compris que l'ensemble des relations de sous-traitance relevaient du champ de l'enquête (type 1)
- des entreprises qui n'avaient pas compris le questionnaire (type 2)
- des entreprises qui avaient sciemment mal répondu (type 3).

En outre, les entreprises avaient été "repérées" par leur niveau de sous-traitance dans l'EAE, permettant alors de définir les entreprises à "corriger". Le fait qu'au final ce soit les fonctions *production* et *approvisionnement*, fonctions contenant l'ensemble des relations de sous-traitance, qui ont été corrigées et qu'en *production* plus de 80% des relations décrites pour ces entreprises extrapolées soient des relations de sous-traitance valide le modèle choisi.

Enfin la variance calculée est raisonnable même si cette dernière n'a été estimée que de façon empirique.

La limite de ce traitement concerne le nombre d'entreprises rappelées. Il demeure faible. C'est la limite principale de cette procédure. Un plus grand nombre de rappels aurait en effet permis d'améliorer la procédure sur deux points essentiellement :

- affinement des probabilités de correction ; ces dernières ont en effet un poids très important sur la détermination finale du nombre d'entreprises sans relation aujourd'hui dans l'industrie. Pour certaines catégories le faible nombre d'entreprises rappelées n'a pas permis une détermination immédiate du taux de correction. Ce dernier a du être estimé sur une population plus large et donc moins précise.

¹⁴ Il s'agit des modalités relatives à la question sur l'appartenance ou non du partenaire au même groupe ainsi que les modalités « choix guidé par le groupe » pour la raison de sélection du partenaire et « mode d'organisation imposé par le groupe » pour la raison de mise en place de la relation.

- Il aurait permis de n'utiliser comme « extrapolante » que des entreprises rappelées. Ainsi s'il existait une spécificité des entreprises rappelées par rapport aux entreprises répondantes initiales, ces différences auraient pu être prises en compte.

En revanche, même avec plus d'entreprises rappelées, une dernière difficulté de ce traitement n'aurait pu être levée. Elle concerne la différenciation des entreprises de type 1 par rapport à celles de type 2 et 3 vue ci-dessus. En effet, pour les entreprises de type 1 seules les fonctions *production* et *approvisionnement* auraient dû être corrigées, alors que, pour les autres entreprises, toutes les fonctions étaient susceptibles d'être modifiées. La distinction entre ces trois populations n'étant pas possible, la solution adoptée a été une possible correction de l'ensemble des fonctions. Il était difficile de faire mieux vu qu'aucun lien n'a été mis en évidence entre les fonctions corrigées et le niveau de sous-traitance, seul élément tangible à notre disposition au moment de ce traitement.

Une autre critique de cette partie concerne l'utilisation d'une source auxiliaire concernant la seule sous-traitance. En effet, ce traitement des entreprises sans relations aurait pu donner des résultats différents si d'autres raisons de suspicion de mauvaise réponse avaient pu être mises en avant. Si une autre source avait, par exemple, permis d'identifier des entreprises devant avoir des relations en commercialisation ou services auxiliaires par exemple, les redressements des entreprises sans relation en auraient été différents. Il aurait pu être possible de corriger indépendamment chaque fonction. La population des entreprises corrigée aurait été différente ainsi que les redressements. Et en conséquence, l'estimation du nombre d'entreprises sans relation aurait été meilleur.

Enfin, le fait qu'initialement aucune entreprise ni preneuse ni donneuse d'ordre n'ait été rappelée à également pénalisé la procédure. En effet aucune réponse d'entreprises de cette catégorie n'a pu être corrigée au final, alors qu'il y avait parmi elles des entreprises de type 2 et 3. Ce biais était toutefois inévitable car il n'était pas possible sans rappel d'estimer le taux d'entreprises à corriger.

Conclusion

Ces deux exemples de redressement de non-réponses ou de réponses erronées mettent en évidence la valeur ajoutée des rappels d'entreprises pour les traitements de la non-réponse. Ils ont en effet permis :

- soit de disposer d'une information minimale pour chaque entreprise (au moins une description individuelle connue), information mobilisable pour la procédure de redressement,
- soit d'obtenir des informations concernant les entreprises non-répondantes partielles et ainsi de tenir compte des éventuelles différences de comportement entre les non-répondantes et les autres.

Pour beaucoup d'enquêtes auprès des entreprises, et notamment l'EAE, le comportement des entreprises non-répondantes, pour les variables d'intérêt, est supposé identique à celui des répondantes dans le cadre de la non-réponse totale tout au moins. Dans cet exemple, le rappel d'un échantillon d'entreprises a permis dans la majorité des cas de valider cette hypothèse. Malheureusement, comme on a pu le constater plus haut, le nombre limité de rappels n'a pas permis d'aller jusqu'au bout des choses ; il n'a notamment pas été possible de n'utiliser que le résultat des entreprises rappelées pour redresser les autres.

Ce constat confirme la recommandation habituellement faite lors de la réalisation d'enquêtes à savoir qu'il faut avoir décidé, au moins dans ses grandes lignes, dès le lancement de l'enquête des techniques de traitement de la non-réponse que l'on compte utiliser. Pour ERIE par exemple, la consigne d'obtenir au moins une description individuelle par fonction concernée avait été donnée dès le lancement de l'enquête.

D'autre part, il est important dès le début de la collecte d'analyser, via des tableaux de bord, les premiers retours de questionnaires. Ces derniers permettent en effet de mettre en évidence des problèmes éventuellement non anticipés ou alors de confirmer des problèmes pressentis. Pour ERIE, ces tableaux de bord ont permis de confirmer la réticence, rencontrée lors des tests en entreprises, qu'éprouvaient les sous-traitants à considérer leurs relations de sous-traitance comme faisant partie du champ de l'enquête.

Concernant les méthodes de traitement mises en place, il s'agit de techniques se rapprochant de celles du plus proche voisin [6] qui se basent sur du hot-deck stratifié. L'originalité se situe plus dans l'utilisation de modèles probabilistes, soit pour définir la classe de la relation à redresser soit pour définir si oui ou non la réponse devait être redressée. La critique à ce niveau concerne alors le trop faible nombre d'entreprises utilisées pour définir ces modèles. La loi des grands nombres était difficilement applicable pour certaines strates ; c'est pourtant l'hypothèse qui a dû être faite.

Toutefois, les résultats obtenus valident d'une certaine manière les méthodes utilisées. La qualité de ces procédures réside d'ailleurs principalement dans la mise en évidence de strates de réponses homogènes d'une part et dans la mobilisation du maximum de l'information disponible sur les entreprises à redresser d'autre part.

Enfin, un point faible de cette étude reste le calcul empirique de la variance qui n'a en outre été réalisé qu'à un niveau agrégé. Il a toutefois le mérite de donner un ordre de grandeur de la variabilité générée. De plus, il a permis de valider les méthodes choisies. En effet, la faible variabilité des résultats observés traduisait l'homogénéité des strates utilisées pour les procédures de hot-deck.

Bibliographie

- [1] CARON N. « Les principales techniques de correction de la non-réponse, et les modèles associés », document de travail Insee, méthodologie statistique n° 9604, 1996
- [2] COTTON F., HESSE C. « Tirages coordonnés d'échantillons », document de travail INSEE de la direction des statistiques d'entreprise, E9206, 1992
- [3] ARDILLY P. « Les techniques de sondage », Edition Technip 1992
- [4] SAPORTA G. « *Probabilités, analyse des données et statistique* », TECHNIP 1990 [23 SAP 00 B]
- [5] VOLLE M. « *Analyse des données* », ECONOMICA [23 VOL 00 A]
- [6] RANCOURT E. « l'estimation de la variance en présence d'imputation : concepts et méthodes », recueil des résumés de communication des XXVIII^e journées de statistique, ASU, 628-634, 1996.