

2m11.3331.1

**HEC MONTRÉAL
AFFILIÉE À L'UNIVERSITÉ DE MONTRÉAL**

**Modèle de détection de la fraude dans les états financiers
d'entreprises publiques**

par

Frédéric Martineau

Sciences de la gestion

*Mémoire présenté en vue de l'obtention
du grade de maîtrise ès sciences
(M. Sc.)*

Jun 2005
© Frédéric Martineau, 2005



m 2005
no 81

**DÉCLARATION DE L'ÉTUDIANTE, DE L'ÉTUDIANT
ÉTHIQUE EN RECHERCHE AUPRÈS DES ÊTRES HUMAINS**

Recherche sans collecte directe d'informations

Cette recherche n'impliquait pas une collecte directe d'informations auprès de personnes (exemples : entrevues, questionnaires, appels téléphoniques, groupes de discussion, tests, observations participantes, communications écrites ou électroniques, etc.).

Cette recherche n'impliquait pas une consultation de documents, de dossiers ou de banques de données existants qui ne font pas partie du domaine public et qui contiennent des informations sur des personnes.

Titre de la
recherche :

Modèle de détection de la fraude dans
les états financiers d'entreprises publiques

Nom de l'étudiante,
de l'étudiant :

Frédéric Martineau

Signature :

Frédéric Martineau

Date :

2005-09-22

RÉSUMÉ

Dans ce mémoire, nous allons développer un modèle de détection de la fraude dans les états financiers. Notre échantillon est composé d'entreprises ayant commis une fraude lesquelles ont été obtenues par le biais des *Accounting and Auditing Enforcement Releases*, émis par la *Securities and Exchange Commission*, aux États-Unis. Un ensemble de variables prédictives financières, reliées à la gouvernance et aux motivations pour commettre une fraude est utilisé pour prédire la présence ou l'absence de fraude. La performance du partitionnement récursif est comparée à celle de trois autres méthodes de classification : l'analyse discriminante linéaire, la régression logistique et les réseaux de neurones. Deux mesures sont utilisées pour comparer la performance des méthodes : le taux de bonne classification et le coût espéré de mauvaise classification qui sont calculés, lorsque possible, à partir de différentes probabilités *a priori* de fraude et de coûts relatifs de mauvaise classification. Nos résultats indiquent que le partitionnement récursif permet d'atteindre, en général, de meilleurs taux de bonne classification que les trois autres méthodes hors-échantillon. Cependant, les taux de bonne classification ont tendance à être plus instables d'un échantillon de validation croisée à l'autre. De manière plus définitive, le partitionnement récursif engendre, à quelques exceptions près, de plus faibles coûts espérés de mauvaise classification que les trois autres méthodes hors-échantillon. Ces résultats sont aussi plus stables.

TABLE DES MATIÈRES

INTRODUCTION	1
CHAPITRE 1. - MISE EN CONTEXTE	4
1.1. - Coûts	4
1.2. - Fréquence	5
1.3. - Confiance du public	6
1.4. - Efficience des marchés financiers	6
1.5. - Vérificateurs externes	7
1.5.1. - Obligation professionnelle	7
1.5.2. - Poursuites et sanctions réglementaires	9
1.5.3. - Primes d'assurance	10
1.5.4. - Manque de formation et d'expérience	10
1.5.5. - Efficacité et efficience du processus annuel de vérification	11
1.6. - Investisseurs	11
1.7. - Agences de réglementation	12
CHAPITRE 2. - REVUE DE LA LITTÉRATURE	14
2.1. - Les données	14
2.2. - Les variables	17
2.2.1. - Variables financières	17
2.2.2. - Gouvernance	19
2.2.3. - Initiés	23
2.3. - Les modèles	24
2.3.1. - Régression	25
2.3.2. - Réseaux de neurones	35
2.3.3. - Systèmes experts	39
CHAPITRE 3. - PRÉSENTATION DES DONNÉES	44
3.1. - Méthode de construction de l'échantillon	44
3.1.1. - Entreprises ayant commis une fraude comptable	44
3.1.2. - Entreprises de contrôle	46
3.1.3. - Données	49
3.2. - Variables prédictives	50
3.2.1. - Variables financières	50
3.2.1.1. - Composition de l'actif	50
3.2.1.2. - Croissance	52
3.2.1.3. - Liquidité	53
3.2.1.4. - Opportunités de croissance	53
3.2.1.5. - Productivité	54
3.2.1.6. - Qualité des bénéfécies	55
3.2.1.7. - Rentabilité	56
3.2.2. - Gouvernance	56
3.2.2.1. - Équipe de direction	57
3.2.2.2. - Conseil d'administration	57
3.2.2.3. - Comité de vérification	59

3.2.2.4. - Firme de vérification	59
3.2.3. - Motivations pour commettre une fraude	60
3.2.3.1. - Besoins de financement externe	61
3.2.3.2. - Respect des clauses de convention de prêt	61
3.2.4. - Autre	62
3.3. - <i>Statistiques descriptives</i>	63
3.4. - <i>Analyse de corrélation</i>	66
CHAPITRE 4. - DESCRIPTION DES MODÈLES	70
4.1. - <i>Analyse discriminante linéaire</i>	71
4.1.1. - Présentation générale	71
4.1.2. - Description des modèles	73
4.2. - <i>Régression logistique</i>	76
4.2.1. - Présentation générale	76
4.2.2. - Description des modèles	77
4.3. - <i>Partitionnement récursif</i>	80
4.3.1. - Présentation générale	80
4.3.2. - Description des modèles	82
4.4. - <i>Réseaux de neurones</i>	86
4.4.1. - Présentation générale	86
4.4.2. - Description des modèles	89
CHAPITRE 5. - DESCRIPTION DES RÉSULTATS	96
5.1. - <i>Taux de bonne classification</i>	97
5.1.1. - Analyse discriminante linéaire	98
5.1.2. - Partitionnement récursif	102
5.1.3. - Régression logistique	105
5.1.4. - Réseaux de neurones	109
5.2. - <i>Coûts espérés de mauvaise classification</i>	112
5.2.1. - Analyse discriminante linéaire	114
5.2.2. - Partitionnement récursif	115
5.2.3. - Régression logistique	117
5.2.4. - Réseaux de neurones	119
CONCLUSION	122
BIBLIOGRAPHIE	126
ANNEXES	130

LISTE DES TABLEAUX

Tableau 1 : Statistiques descriptives sur les entreprises du groupe 1 (n=95) et du groupe 2 (n=95)	47
Tableau 2 : Autres caractéristiques sur les entreprises du groupe 1 (n=95) et du groupe 2 (n=95) et sur le processus de contrôle	48
Tableau 3 : Nombre de valeurs médianes imputées et nombre d'entreprises affectées dans le groupe 1 (n=95) et le groupe 2 (n=95)	49
Tableau 4 : Coefficients des modèles d'analyse discriminante linéaire	74
Tableau 5 : Coefficients des modèles de régression logistique	78
Tableau 6 : Importance des variables dans les modèles de partitionnement récursif	84
Tableau 7 : Contribution des variables prédictives dans les réseaux de neurones	89
Tableau 8 : Importance des variables prédictives dans les méthodes d'analyse discriminante linéaire (ADL), de régression logistique (RL), de partitionnement récursif (PR) et de réseaux de neurones (RN)	92
Tableau 9 : Taux de bonne classification moyens (écart type) des modèles d'analyse discriminante linéaire (ADL), de partitionnement récursif (PR), de régression logistique (RL) et de réseaux de neurones (RN) dans leur scénario de base respectif dans les échantillons d'estimation et de validation (%)	98
Tableau 10 : Coûts espérés de mauvaise classification moyens (écart type) des modèles d'analyse discriminante linéaire (ADL), de partitionnement récursif (PR), de régression logistique (RL) et de réseaux de neurones (RN) dans leur scénario de base respectif dans les échantillons d'estimation et de validation (%)	114
Tableau 11 : Statistiques descriptives	135
Tableau 12 : Matrice de corrélation du groupe 1	137
Tableau 13 : Matrice de corrélation du groupe 2	138
Tableau 14 : Matrice de corrélation des groupes 1 et 2	139
Tableau 15 : Résultats des modèles d'analyse discriminante linéaire	143
Tableau 16 : Résultats du premier modèle de régression logistique	144
Tableau 17 : Résultats du deuxième modèle de régression logistique	145

Tableau 18 : Résultats du troisième modèle de régression logistique	146
Tableau 19 : Résultats du quatrième modèle de régression logistique	147
Tableau 20 : Résultats du cinquième modèle de régression logistique	148
Tableau 21 : Taux de bonne classification moyens (écart type) des modèles d'analyse discriminante linéaire	149
Tableau 22 : Coûts espérés de mauvaise classification moyens (écart type) des modèles d'analyse discriminante linéaire	151
Tableau 23 : Taux de bonne classification moyens (écart type) des modèles de partitionnement récursif	152
Tableau 24 : Coûts espérés de mauvaise classification moyens (écart type) des modèles de partitionnement récursif	154
Tableau 25 : Taux de bonne classification moyens (écart type) des modèles de régression logistique	155
Tableau 26 : Coûts espérés de mauvaise classification moyens (écart type) des modèles de régression logistique	156
Tableau 27 : Taux de bonne classification moyens (écart type) des modèles de réseaux de neurones	159
Tableau 28 : Coûts espérés de mauvaise classification moyens (écart type) des modèles de réseaux de neurones	160

LISTE DES FIGURES

Figure 1 : Exemple d'arbre de classification comprenant cinq nœuds dont trois sont des nœuds terminaux	81
Figure 2 : Arbre de classification développé dans le scénario de base à partir du premier échantillon de validation croisée	83
Figure 3 : Architecture d'un réseau neurones	86
Figure 4 : Éléments de base d'un neurone	88
Figure 5 : Arbre de classification développé dans le scénario de base à partir du premier échantillon de validation croisée	140
Figure 6 : Arbre de classification développé dans le scénario de base à partir du deuxième échantillon de validation croisée	140
Figure 7 : Arbre de classification développé dans le scénario de base à partir du troisième échantillon de validation croisée	141
Figure 8 : Arbre de classification développé dans le scénario de base à partir du quatrième échantillon de validation croisée	142
Figure 9 : Arbre de classification développé dans le scénario de base à partir du cinquième échantillon de validation croisée	142

REMERCIEMENTS

Je tiens d'abord à remercier ma directrice de recherche, Mme Narjess Boubakri, et mon co-directeur de recherche, M. Jean Roy, pour leur support, leurs conseils et leur disponibilité. Sans eux, ce travail n'aurait évidemment pas été possible.

Un merci tout spécial à Mohamed Jabir qui m'a aidé à de nombreuses reprises lors de la mise sur pied de l'échantillon qui est utilisé dans ce mémoire.

Je veux enfin remercier ma famille et mes amis qui m'ont permis, par leurs encouragements tout au long de mes études, et, en particulier, au cours de la dernière année, de réaliser cette tâche. Votre soutien a été apprécié plus que vous ne pouvez l'imaginer.

À ma famille

INTRODUCTION

Les années 2001 et 2002 ont été marquées, aux États-Unis, par une série de scandales financiers impliquant quelques-unes des plus grandes entreprises publiques américaines : Enron, WorldCom et Adelphia, pour n'en nommer que trois. Comme la taille des entreprises mêlées à ces malversations, les montants des fraudes étaient considérables, variant de quelques centaines de millions de dollars dans un cas à plusieurs milliards de dollars dans l'autre. Il n'en fallait pas plus pour qu'une sérieuse crise de confiance ébranle le monde des affaires américain. Les investisseurs et le public, en général, abasourdis par les montants en jeu, choqués par l'absence de scrupules des gestionnaires, se sont posé de nombreuses questions : comment des manipulations comptables ont-elles pu atteindre une telle ampleur sans que les membres du conseil d'administration de ces entreprises, leur vérificateur ou les agences de réglementation, telles que la SEC, chargée de la surveillance des marchés boursiers américains, ne s'en aperçoivent auparavant? Les lois, normes professionnelles et autres règles en vigueur, établies dans bien des cas depuis des décennies - par exemple, le *Securities Exchange Act* est entré en fonction en 1934 - sont-elles toujours adéquates en ce début de 21^e siècle?

À toutes ces questions s'en ajoute une autre, en lien direct avec ce travail, qui est la suivante : existe-t-il un moyen, à la disposition d'une personne extérieure à l'entreprise, qui pourrait lui permettre, à partir de données publiques, de détecter une fraude contenue dans les états financiers lors de ses premiers balbutiements? En d'autres mots, est-il possible de développer un modèle de détection de la fraude comptable efficace, prenant la forme d'un modèle de classification, à l'aide de données provenant du rapport annuel et d'outils statistiques ou d'intelligence artificielle, à l'intention des vérificateurs, des analystes financiers et des investisseurs? C'est ce que nous tâcherons de déterminer. Les chercheurs qui s'intéressent au sujet affirment, pour leur part, qu'il est possible d'y arriver : pour ce faire, il suffit d'avoir recours à un ensemble adéquat de données, de variables et de méthodes de classification.

Par rapport aux autres études, la nôtre aura ceci de particulier : tout d'abord, notre échantillon sera composé de cas de fraude – par « cas de fraude », nous entendons une entreprise qui a commis une fraude comptable - plus récents et qui, selon toute vraisemblance, n'ont jamais été utilisés. Ces cas de fraude sont obtenus à partir des *Accounting and Auditing Enforcement Releases* (AAER), émis par la *Securities and Exchange Commission* (SEC), aux États-Unis, entre octobre 1999 et décembre 2004. Précédemment, les AAER les plus récents utilisés dans la littérature datent de 1997 (Beasley, Carcello, Hermanson et Lapedes, 2000; Dunn, 2004). De plus, le nombre de cas de fraude auquel nous avons recours pour développer les modèles se compare avantageusement à celui de toutes les études portant, de près ou de loin, sur le sujet. En fait, seulement trois études sur la vingtaine recensée avaient un échantillon d'entreprises ayant manipulé frauduleusement leurs états financiers de taille supérieure au nôtre (Dunn, 2004; Fanning et Cogger, 1998; Persons, 1995).

Ensuite, nous aurons recours à un assortiment exclusif de variables financières, reliées à la gouvernance et aux motivations pour commettre une fraude. Comme nous le verrons plus loin, certains auteurs ne s'intéressent qu'à un type particulier de variables. Par ailleurs, ils ne font qu'établir, en général, des relations avec la fraude financière. Ils ne développent donc pas explicitement de modèles de détection. Ainsi, quelques-unes des variables composant notre échantillon n'ont jamais été utilisées ou, encore, l'ont été seulement à une reprise pour développer un modèle de détection de la fraude, alors que d'autres n'ont jamais été combinées dans un même modèle.

Enfin, nous utiliserons une méthode de classification nouvelle à ce champ d'études : le partitionnement récursif. La performance des modèles développés à l'aide du partitionnement récursif sera comparée à celle de modèles construits à partir des méthodes d'analyse discriminante linéaire, de régression logistique et de réseaux de neurones artificiels (réseaux de neurones ci-après). Deux mesures de performance seront utilisées : le taux de bonne classification et le coût espéré de mauvaise classification. Une variété de probabilités *a priori* de fraude et de coûts relatifs de mauvaise classification sera utilisée dans la conception des modèles et le calcul des mesures de performance. Il est à noter, toutefois, que ces hypothèses auront seulement un effet sur le

coût espéré de mauvaise classification des modèles de régression logistique et de réseaux de neurones. Pour ces deux méthodes, nous utiliserons plutôt différents seuils de classification pour calculer les taux de bonne classification. Afin de nous assurer de la validité de nos résultats, nous aurons aussi recours à la validation croisée. Ainsi, nous procéderons à une analyse de la performance des modèles qui se compare avantageusement à celles qui ont été faites auparavant dans la littérature.

La suite de l'étude est divisée de la façon suivante. À la prochaine section, nous procédons à une mise en contexte. Il sera essentiellement question de l'intérêt de développer un modèle de détection de la fraude contenue dans les états financiers. À la troisième section, nous allons présenter une revue de la littérature pertinente. Une présentation détaillée des données utilisées pour développer les modèles sera ensuite effectuée à la quatrième section. En particulier, nous y traiterons de la méthode de construction de l'échantillon, des variables prédictives et des justifications théoriques derrière leur utilisation, de leurs statistiques descriptives et de la corrélation entre ces variables. La cinquième section portera sur les modèles. Nous y ferons une présentation générale des méthodes et y décrirons les modèles conçus. Les résultats seront présentés et analysés à la section six. Enfin, la conclusion de l'étude et quelques avenues de recherche se trouvent à la septième section.

CHAPITRE 1. - MISE EN CONTEXTE

Dans cette partie, nous nous attardons à décrire les raisons motivant le développement d'un modèle de détection de la fraude contenue dans les états financiers. Comme nous le verrons plus en détail, cet intérêt repose principalement sur les caractéristiques et les conséquences de la fraude. En particulier, nous nous intéresserons aux pertes monétaires qu'elle entraîne, à la fréquence à laquelle elle a lieu, et à ses effets, forcément négatifs, sur la confiance du public et l'efficacité des marchés financiers. Par ailleurs, divers groupes d'individus pourraient être intéressés à utiliser un tel modèle de détection, les principaux étant les vérificateurs, les investisseurs et les agences de réglementation.

Avant de discuter de l'intérêt d'un modèle de détection, nous allons définir ce qui est généralement entendu par « fraude contenue dans les états financiers ». La fraude contenue dans les états financiers (*financial statement fraud*), que l'on retrouve aussi sous d'autres appellations dont fraude comptable (*accounting fraud*), fraude commise par les gestionnaires (*management fraud*) et publication d'information financière frauduleuse (*fraudulent financial reporting*), fait référence à la conduite volontaire des dirigeants d'une entreprise qui, par le biais de diverses techniques comptables, brossent un portrait inexact de sa situation financière, trompant ainsi, entre autres groupes, les banquiers, les investisseurs et les vérificateurs (Kerwin, 1995).

1.1. - Coûts

Les conséquences économiques des fraudes, si elles n'en sont pas l'aspect principal, en sont, du moins, un des plus importants, des plus visibles, au même titre que leurs auteurs et que les techniques utilisées pour les commettre. Nous allons donc considérer ce point en premier.

Les statistiques sur les fraudes rappellent toutes, l'une après l'autre, l'ampleur de ce méfait dans notre société. Les fraudes perpétrées par les cols blancs, qui rapportent dix fois plus à leurs auteurs que les crimes traditionnels et qui ont une faible probabilité d'être découvertes et sévèrement punies, engendrent les pertes les plus importantes

lorsque la haute direction d'une entreprise y est directement impliquée (Kerwin, 1995). La *National Commission on Fraudulent Financial Reporting* (NCFRR) (1987) mentionne, au sujet de la fraude contenue dans les états financiers, que « *infrequent though its occurrence arguably may be, its consequences can be widespread and significant* » (p. 1). De manière chiffrée, la fraude coûte à l'économie américaine des centaines de milliards de dollars par année. L'*Association of Certified Fraud Examiners* (ACFE) (2002, cité dans Peterson, 2004) estime que des revenus de 600 G\$ US ont été perdus en 2002 seulement en raison de la fraude et des abus. Cotton (2002, cité dans Rezaee, 2003) estime que les pertes entraînées par les fraudes dans les états financiers commises par Enron, WorldCom, Qwest, Tyco et Global Crossing se chiffrent à 460 G\$ US. À lui seul, l'effondrement d'Enron a entraîné des pertes, sous forme de capitalisation boursière, de l'ordre de 70 G\$ US (Rezaee, 2003). Par ailleurs, malgré la relative rareté des cas de publication d'information financière frauduleuse, qui ne représentent que 5,1 % des cas de fraude, ce qui en fait le type de fraude le moins fréquent, l'ACFE (2002, cité dans Peterson, 2004) souligne qu'ils entraînent tout de même les pertes médianes les plus importantes (4,25 M\$ US).

Les fraudes comptables ont entraîné de telles pertes en raison de la taille parfois importante des entreprises qui les ont commises et de leur nombre qui serait à la hausse.

1.2. - Fréquence

Bossard et Blum (2002) allèguent que la fréquence de la fraude corporative, comme son importance, d'ailleurs, semble en forte augmentation. Le *United States General Accounting Office* (2002), équivalent américain du Bureau du Vérificateur général du Canada, l'a confirmé, en partie, en publiant un rapport qui indique que le nombre de corrections dues à des irrégularités comptables a augmenté substantiellement au cours des dernières années. Deux résultats sont particulièrement probants. D'une part, entre janvier 1997 et juin 2002, le taux de croissance du nombre d'états financiers corrigés en raison d'irrégularités s'est situé à près de 150 %. Par ailleurs, il y est mentionné que, durant la même période, environ une entreprise cotée sur une place boursière sur dix a annoncé au moins une correction.

La fraude contenue dans les états financiers entraîne aussi des conséquences, peut-être encore plus pernicieuses que ses coûts directs, mais certes plus difficiles à quantifier, au niveau de la confiance du public envers les entreprises, en particulier, et les marchés financiers, en général.

1.3. - Confiance du public

Les entreprises publiques, aux États-Unis ou ailleurs, ont, du moins, pour la vaste majorité d'entre elles, des mécanismes de gouvernance adéquats, un processus de publication de l'information transparent, une fonction de vérification interne efficace, *etc.* (Rezaee, 2003). Bien qu'elle n'affecte qu'un nombre restreint de firmes, la fraude comptable, en raison des accusations qui ont été portées et des jugements de culpabilité qui ont été rendus contre des dirigeants de grandes entreprises, a reçu beaucoup d'attention négative, faut-il le préciser, de la part du public, de la presse et des investisseurs ces dernières années. Selon Rezaee (2003), le public est donc devenu plus méfiant envers le monde des affaires. Au milieu des années 1990, Persons (1995) est arrivé, lui aussi, à un constat similaire en ce qui concerne l'effet des scandales financiers qui ont eu lieu à l'époque.

1.4. - Efficience des marchés financiers

Les pratiques comptables illicites faussent l'évaluation de la valeur des entreprises. Par conséquent, l'efficience des marchés est elle aussi affectée par la fraude contenue dans les états financiers.

Rezaee (2003) rappelle que les états financiers doivent être fiables pour qu'une économie parvienne à une allocation efficiente de ses ressources. La qualité de l'information financière publiée par les entreprises est effectivement primordiale, car les décisions d'investissement prises par les participants des marchés financiers sont majoritairement basées sur celle-ci. En apposant leur sceau à l'information dévoilée dans le rapport annuel d'une entreprise, les vérificateurs externes permettent de réduire le risque qu'elle ait été manipulée. Un plus faible risque associé à l'information financière

a pour principal effet de rendre les marchés des capitaux plus efficaces. Ainsi, il s'en suit une diminution du coût du capital qui entraîne elle-même une augmentation du prix des actions. Ainsi, selon Rezaee (2003), tous ont intérêt à ce qu'il y ait prévention et détection de la fraude comptable pour préserver l'intégrité du système financier.

Les vérificateurs externes, les investisseurs et les agences de réglementation pourraient tirer avantage de l'utilisation d'un modèle de détection de la fraude contenue dans les états financiers. Par exemple, une motivation commune à ces trois groupes, que nous allons approfondir ci-bas, ainsi que celles qui leur sont spécifiques, est l'amélioration de l'efficacité et de l'efficience de leurs activités respectives.

1.5. - Vérificateurs externes

Les vérificateurs externes constituent le principal groupe qui pourrait être intéressé par un modèle de détection de la fraude comptable. Le recours à un tel modèle par ceux-ci peut être justifié par l'obligation, formulée dans les normes professionnelles qui les régissent aux États-Unis, de détecter tout cas de fraude significative, par les poursuites et sanctions réglementaires liées à un manquement à cette obligation, par l'importance des primes d'assurance professionnelle à payer, par un manque de formation et d'expérience avec la fraude et, enfin, comme nous l'avons mentionné précédemment, par les améliorations potentielles à l'efficacité et à l'efficience du processus annuel de vérification.

1.5.1. - Obligation professionnelle

L'*American Institute of Certified Public Accountants* (AICPA) publie, par le biais du *Auditing Standards Board*, les normes de vérification comptable dans les *Statements on Auditing Standards* (SAS) qui stipulent, entre autres choses, que les vérificateurs externes ont pour responsabilité d'identifier les situations dans lesquelles les états financiers sont susceptibles d'avoir été manipulés et d'utiliser, pour ce faire, des procédures analytiques quantitatives et qualitatives. Nous nous attarderons aux SAS N°

53, 54, 56, 82 et 99 qui forment l'essentiel des normes de vérification comptable pertinentes.

SAS N° 53, 82 et 99, les deux derniers, en fait, correspondant à une mise à jour du précédent, portent tous sur la responsabilité des vérificateurs externes en ce qui concerne la détection de la fraude contenue dans les états financiers. Plus particulièrement, SAS N° 53 (AICPA, 1988, cité dans Beasley, 1996) requiert explicitement des vérificateurs externes qu'ils garantissent, de manière raisonnable, l'absence d'erreurs significatives (*material misstatements*) dans les états financiers. Ainsi, les vérificateurs ne sont pas entièrement responsables de la présence d'erreurs et d'irrégularités dans les états financiers. Néanmoins, SAS N° 53 augmente de manière significative l'étendue de leur responsabilité par rapport aux normes en vigueur auparavant (Feroz, Kwon, Pastena et Park, 2000).

De son côté, SAS N° 54 (AICPA, 1988, cité dans Ragothaman, Carpenter et Buttars, 1995) affirme que toute erreur due à un acte illégal, comme une fraude, qui affecte de manière significative les états financiers doit être détectée et dévoilée par les vérificateurs externes.

Par ailleurs, il est mentionné dans SAS N° 56 (AICPA, 1988, cité dans Green et Calderon, 1994) que des procédures analytiques doivent être utilisées aux étapes de planification et de révision du processus annuel de vérification afin d'accroître la probabilité qu'une fraude soit détectée. Cette norme requiert l'utilisation de procédures analytiques quantitatives et qualitatives.

SAS N° 82 (AICPA, 1997, cité dans Eining, Jones et Loebbecke, 1997), qui a succédé à SAS N° 53, comme nous l'avons mentionné précédemment, stipule, entre autres choses, que le risque que les états financiers contiennent une erreur due à une fraude doit être estimé par les vérificateurs externes. L'estimation qui en découle, qui doit être faite à partir de facteurs de risque (*red flags*) contenu dans SAS N° 82, est supposée influencer le choix des procédures de vérification qui, à leur tour, devraient garantir de manière raisonnable la détection de l'erreur, le cas échéant.

Finalement, SAS N° 99 (AICPA, 2002, cité dans Peterson, 2004) a introduit de nouvelles normes et exigences pour favoriser la détection de la fraude par les vérificateurs externes. Par ailleurs, il stipule que les résultats des procédures analytiques, qui devaient être considérés, dans le cadre de SAS N° 56, aux étapes de la planification et de la révision de la vérification annuelle, doivent maintenant être utilisés par les vérificateurs externes afin d'établir des liens avec les idées soulevées et les résultats trouvés lors du processus d'estimation du risque de fraude.

1.5.2. - Poursuites et sanctions réglementaires

Les vérificateurs externes ont aussi un intérêt économique à avoir recours à des modèles de détection de la fraude comptable. Un certain nombre d'auteurs ont effectivement trouvé que l'incapacité des vérificateurs à la détecter peut les exposer à des conséquences légales et/ou réglementaires dont l'impact financier peut être substantiel. Stice (1991) allègue que les « *investors and creditors who rely on audited financial statements and subsequently incur losses may allege that their reliance on the audit firm's opinion contributed to the losses* » (p. 518). Persons (1995) arrive, lui aussi, à une conclusion similaire. Il évoque le risque qu'une poursuite soit déclenchée par les actionnaires d'une entreprise contre sa firme de vérification comptable si elle échoue à sa tâche qui est d'offrir une protection contre la présence de fraude. En raison des normes de vérification comptable, les utilisateurs des états financiers considèrent à tort que cette protection est infaillible. D'ailleurs, le nombre de poursuites contre des firmes de vérification comptable a atteint des sommets inégalés auparavant dans l'histoire de la comptabilité au cours de la période 1980-1995 (Ragothaman *et al.*, 1991). En fait, selon Palmrose (1987, cité dans Beasley, 1996), une poursuite sur deux, impliquant des vérificateurs externes, a pour objet une fraude. Ces poursuites ont pour principal effet d'alléger les firmes de vérification, en général, de plusieurs millions de dollars, en plus de miner leur réputation, évidemment. À ce chapitre, l'exemple du cabinet comptable Arthur Anderson est éloquent.

Les vérificateurs externes peuvent aussi être l'objet de sanctions réglementaires. Feroz, Park et Pastena (1991) mentionnent que 85 firmes de vérification comptable (45 %) se

retrouvant dans leur échantillon ont été sanctionnés par la SEC et ce, malgré le fait que certains aient, par exemple, mis à jour les violations des normes de publication de l'information financière commises par leur client. De plus, parmi ces vérificateurs externes, 17 ont été blâmés indirectement pour ne pas avoir pris en considération le risque de fraude posé par leur client.

1.5.3. - Primes d'assurance

Comme nous venons de le voir, les firmes de vérification comptable peuvent être soumises à de coûteuses sanctions légales et réglementaires. Par conséquent, elles ont intérêt à minimiser le risque de faute professionnelle, surtout, comme le rapporte Mednick (1987, cité dans Ragothaman *et al.*, 1995), que les primes d'assurance professionnelle des vérificateurs externes augmentent alors que la couverture offerte, elle, suit plutôt une tendance inverse. Ragothaman *et al.* (1995) signalent même que les vérificateurs externes ne peuvent plus se procurer d'assurance professionnelle auprès de certaines compagnies d'assurance. Cette situation n'est certainement pas étrangère au nombre croissant de poursuites dont les cabinets comptables ont été l'objet au cours des deux dernières décennies.

1.5.4. - Manque de formation et d'expérience

Une fraude comptable est *a priori* difficile à détecter. Ce phénomène est amplifié, notamment, par le manque de formation et d'expérience des vérificateurs externes avec la fraude qui peut être expliqué de deux façons. D'une part, l'offre de cours de vérification portant sur la détection de la fraude dans les universités est réduite (Kerwin, 1995). D'autre part, la recherche d'une efficacité accrue du processus de vérification annuel, laquelle est due à une vive concurrence entre les firmes de vérification comptable, oblige ces dernières à réduire la participation des associés et à augmenter celle de nouveaux comptables qui, forcément, sont moins aptes à détecter une fraude (Kerwin, 1995; Porter et Cameron, 1987, cité dans Fanning et Cogger, 1998).

1.5.5. - Efficacité et efficience du processus annuel de vérification

Pour être intéressant aux yeux des firmes de vérification comptable, un modèle de détection de la fraude doit être efficace. Or, un modèle de détection peut être qualifié d'efficace lorsqu'il permet non seulement de détecter un nombre important d'entreprises ayant commis une fraude, mais aussi de limiter l'émission de faux signaux, un faux signal correspondant, ici, à classer une entreprise n'ayant pas commis de fraude dans ses états financiers dans l'autre groupe. En utilisant un modèle de classification efficace, une firme de vérification comptable pourrait effectuer une meilleure allocation de ses ressources en en déplaçant des processus annuels de vérification qui présentent le moins de risque à ceux qui en présentent le plus. Ainsi, en n'y consacrant ni plus de temps ni plus d'argent, elle pourrait parvenir à réduire l'émission de diagnostics erronés (Green et Choi, 1997). En plus d'être utile lors du processus annuel de vérification des états financiers des clients actuels d'un cabinet comptable, un modèle de détection de la fraude pourrait aussi l'être au moment de l'acceptation ou du rejet de la demande de clients potentiels. La décision finale dépendrait, évidemment, du niveau de risque présenté par l'entreprise, lequel pourrait être estimé par le modèle (Persons, 1995).

1.6. - Investisseurs

Les vérificateurs externes ne sont pas les seuls qui pourraient tirer profit d'un modèle de détection de la fraude. Persons (1995) avance, effectivement, qu'il pourrait présenter un intérêt pour les investisseurs en tant que modèle d'aide à la décision. Le modèle pourrait être appliqué pour analyser l'information financière publiée par un grand nombre d'entreprises et identifier celles présentant un risque de fraude élevé. Ainsi, les investisseurs pourraient éviter d'encourir des pertes en n'achetant pas les actions de ces entreprises ou, au contraire, ils pourraient en profiter en effectuant des ventes à découvert. Feroz *et al.* (1991), Dechow, Sloan et Sweeney (1996) et Beneish (1997) ont obtenu, à ce sujet, des résultats concluants. D'ailleurs, Beneish (1997) a implanté, en fonction des résultats fournis par son modèle dans l'échantillon de validation, des stratégies de placement - vendre à découvert les actions des entreprises ayant violé les

principes comptables généralement reconnus¹ (PCGR) et acheter celles des entreprises de contrôle - qui lui ont permis d'obtenir des rendements anormaux significatifs sur des périodes de 12 et 24 mois commençant quatre mois après la fin de l'année fiscale dans laquelle la violation a eu lieu. Par exemple, les résultats pour les utilisateurs agressifs des réserves (*aggressive accruals*) sont les suivants : en utilisant un coût relatif de mauvaise classification de 1:1², le modèle n'identifie aucune entreprise ayant violé les PCGR. Par conséquent, la stratégie de placement élaborée à partir des résultats de ce modèle perd 3,51 % sur 12 mois et 11,90 % sur 24 mois. Par ailleurs, en utilisant un coût relatif de mauvaise classification de 20:1, le modèle réussit à détecter des entreprises ayant contrevenu aux PCGR. Il permet donc d'implanter une stratégie de placement dont le rendement est de 6,10 % et de 15,20 % sur 12 et 24 mois, respectivement.

L'élaboration de stratégies de placement à partir des résultats d'un modèle de détection de la fraude ne sera intéressante que dans la mesure où, bien entendu, les investisseurs ne croient pas que les marchés financiers sont parfaitement efficaces. Dans le cas contraire, l'information concernant une fraude serait déjà prise en considération dans le prix de l'action d'une entreprise et il serait impossible de réaliser des rendements anormaux en vendant à découvert son action.

1.7. - Agences de réglementation

Les agences de réglementation, telles que la SEC, pourraient aussi être intéressées par un modèle de détection de la fraude contenue dans les états financiers (Persons, 1995). En effet, un modèle semblable pourrait être appliqué pour analyser l'information financière publiée par l'ensemble des entreprises publiques, qui doivent leur soumettre, entre autres documents, leurs états financiers annuels vérifiés, et identifier celles qui les ont potentiellement manipulés. Elles pourraient alors être soumises, dépendamment du niveau de risque qu'elles présentent, à une surveillance accrue ou à une enquête plus en profondeur.

¹ Beneish (1997) s'intéresse à la gestion des bénéfices, mais 47 des 64 firmes composant son échantillon ont tout de même été poursuivies en cour pour fraude.

² Pour plus d'informations sur les coûts relatifs de mauvaise classification, veuillez vous référer au Chapitre 5. – Description des résultats.

À la section suivante, nous procédons à une revue de la littérature pertinente. Nous y traiterons principalement de la source de données dominante, des variables qui pourraient potentiellement être incluses dans notre modèle de détection de la fraude et, enfin, de différents modèles qui ont été développés par le passé.

CHAPITRE 2. - REVUE DE LA LITTÉRATURE

L'intérêt porté à la fraude comptable n'est pas récent. Néanmoins, elle n'est véritablement l'objet d'articles scientifiques que depuis le début des années 1980. Le nombre de textes théoriques portant sur le sujet est, somme toute, limité, alors qu'au contraire, le nombre de textes empiriques, lui, est abondant, en raison notamment des avancées en micro-informatique et, un peu plus tard, en intelligence artificielle. C'est à ce dernier volet de la littérature que nous nous intéressons dans ce travail. Les articles qui le composent peuvent généralement être classés à l'intérieur de trois groupes : les données, les variables et les modèles. Le premier correspond à une critique des articles qui n'ont recours qu'à une seule source de données, tout particulièrement, lorsqu'il s'agit des AAER, publiés par la SEC, aux États-Unis. Le second groupe porte sur les articles dont les auteurs ne s'intéressent qu'à établir des relations entre un type donné de variables et la fraude. Les conclusions de ces études peuvent être utiles lorsque vient le temps de développer un modèle de détection. Le dernier groupe s'intéresse, comme son nom l'indique, aux études dans lesquelles un modèle de détection de la fraude est développé. Ces articles revêtent un double intérêt : non seulement ils permettent de déterminer, parmi l'ensemble des variables prédictives, celles qui ont un pouvoir de classification, mais aussi quelle méthode permet d'atteindre les meilleurs résultats.

2.1. - Les données

Dans cette partie, il sera question de l'étude de Beasley, Carcello et Hermanson (1999), contre laquelle, suite à sa parution, plusieurs voix, dont celles de Briloff (2001) et O'Connell (2001), se sont élevées pour en critiquer les conclusions. Plus particulièrement, les auteurs se sont questionné sur la pertinence d'utiliser les AAER comme seule source de cas de fraude. Cette interrogation est d'intérêt car, comme nous le verrons plus bas, ces derniers constituent généralement la source principale, voire exclusive de données utilisée par les auteurs pour former leur échantillon. Afin d'être en mesure de bien comprendre les critiques soulevées, nous allons d'abord présenter un résumé des conclusions de l'article.

Beasley *et al.* (1999) ont publié un rapport, intitulé *Fraudulent Financial Reporting : 1987–1997 An Analysis of US Public Companies*, pour le compte du *Committee of Sponsoring Organizations of the Treadway Commission*, des États-Unis, sur la fraude contenue dans les états financiers. À partir d'un échantillon composé d'approximativement 200 entreprises reconnues coupables de fraude, sélectionnées à partir des AAER publiés entre 1987 et 1997, les auteurs ont conclu que les entreprises qui commettent une fraude sont généralement de petite taille, leurs actifs et leurs revenus n'excédant pas 75 M\$ US. Ils ont aussi trouvé que 25 % des entreprises ayant commis une fraude n'avaient pas de comité de vérification et que, même lorsqu'il existait, ses membres ne se rencontraient que rarement (une fois par année). De plus, la plupart d'entre eux manquait, de surcroît, d'expérience en finance. Par ailleurs, 60 % des membres du conseil d'administration étaient des employés de l'entreprise ou y étaient liés. Beaucoup étaient inexpérimentés, car 40 % des entreprises n'avaient aucun administrateur siégeant sur un autre conseil d'administration. Les gestionnaires et les administrateurs possédaient aussi, collectivement, près du tiers des actions de l'entreprise. Dans près de la moitié des entreprises, le fondateur et le chef de la direction (*chief executive officer*) actuel étaient la même personne ou le président et chef de la direction initial était toujours en place. Une partie des entreprises qui ont commis une fraude comptable n'étaient pas ou peu rentables avant sa perpétration. Enfin, 56 % des entreprises ayant publié des états financiers trompeurs faisaient affaire avec une grande firme de vérification comptable (*Big Eight* ou *Big Six firms*).

Contrairement à ce qui est avancé par les auteurs du rapport, Briloff (2001) soutient que l'échantillon n'est pas représentatif de la population d'entreprises ayant commis une fraude dans leurs états financiers et, en particulier, des plus gros cas de fraude ayant eu lieu lors de la période mise à l'étude (Phar-Mor, Crazy Eddie, *etc.*). Ses doutes émergent du fait que les entreprises qui composent l'échantillon sont, en général, trop petites (75 % ont des actifs inférieurs à 74 M\$ US des revenus de moins de 54 M\$ US et une capitalisation boursière de moins de 17 M\$ US); que la plus grande entreprise de l'échantillon gonfle indûment les moyennes (33 % pour les actifs, 48 % pour les ventes et 31 % pour la capitalisation boursière); que ses revenus (11 G\$ US) englobent approximativement les revenus des autres entreprises (12 G\$ US); enfin, que peu

d'entreprises sont inscrites sur une place boursière, seulement 20 (15 %) l'étant au *New York Stock Exchange* (NYSE) et 104 (78 %) au comptoir (*over-the-counter*). En somme, Briloff (2001) identifie, de manière générale, une des limites des méthodes d'analyse usuelles de la fraude comptable, c'est-à-dire leur utilisation d'une seule source de cas de fraude, les AAER, qui ne serait pas exhaustive.

O'Connell (2001) a ajouté quelques points intéressants à la critique de Briloff (2001). Tout d'abord, il évoque que plus de 50 % des firmes de l'échantillon étaient en faillite, en défaut de paiement sur leur dette ou en instance d'un important changement de propriété suite à la découverte de la fraude. Ainsi, il mentionne que la seule utilisation des AAER pour enquêter sur la fraude commise dans les états financiers peut empêcher de prendre en considération les cas de fraude impliquant des firmes en bonne santé financière. Par conséquent, il s'interroge sur la possibilité de généralisation des résultats d'une étude, et pas seulement celle de Beasley *et al.* (1999), qui se fie uniquement sur les AAER pour former son échantillon. Par ailleurs, même en supposant que l'échantillon est représentatif de la population d'entreprises ayant eu recours à des pratiques comptables illégales, il soutient que les conclusions de l'étude sont discutables, particulièrement celle en regard à la taille des firmes. En effet, même si cette conclusion était valide, « *it is the "high profile" cases of financial statement fraud that make the front pages of the Wall Street Journal, not a conviction of Company XYZ that no-one has ever heard of* » (p. 171). Il mentionne que ce sont ces derniers cas qui sont d'intérêt et qui doivent être étudiés pour en augmenter la compréhension.

Comme nous l'avons mentionné précédemment, la majorité des auteurs utilisent les AAER comme source de cas de fraude. Or, parmi ceux-ci, certains en ont soulevé les limites. Par exemple, Feroz *et al.* (1991) soulignent que les activités d'application de la loi (*enforcement actions*) de la SEC diffèrent en termes de leur nature et de leur sévérité. Ils rapportent aussi que cette dernière a plus de cibles d'enquête qu'elle ne peut en mener et qu'elle doit donc les limiter aux cas dans lesquels des violations significatives sont présumées avoir eu lieu. Ils notent que les « *formal investigations are both costly and highly visible; thus, the agency ranks candidates for formal investigation according to the probability of success and potentiel message value* » (p. 111-112).

2.2. - Les variables

Quelques auteurs ne développent pas de modèle de détection de la fraude comptable et, ainsi, ne font qu'établir des relations entre des variables explicatives et la fraude. Ils s'intéressent généralement à un type de variables en particulier, reliées à des données financières (DeFond et Jiambalvo, 1991; Grove et Cook, 2004), à la gouvernance (Beasley, 1996; Beasley *et al.*, 2000; Dechow *et al.*, 1996) ou encore aux initiés (Dunn, 2004).

2.2.1. - Variables financières

DeFond et Jiambalvo (1991) cherchent à mettre en évidence les circonstances susceptibles de favoriser le recours à la gestion des bénéfices. Leur échantillon est composé de 41 firmes qui ont corrigé leurs bénéfices passés en raison d'une erreur (dix ont été reconnues coupables de fraude), sélectionnées à partir du *National Automated Accounting Research System* (NAARS) et de *Accounting Trends and Techniques*, sur la période 1976 à 1987, et de 41 firmes de contrôle sélectionnées aléatoirement sur NAARS en fonction de l'année. Les auteurs ne contrôlent donc pas directement pour l'industrie. Les variables auxquelles ils ont recours sont reliées à la structure de propriété, à la croissance des bénéfices, au respect des clauses de convention de prêt, à l'utilisation de PCGR plus « agressifs » et à l'environnement de contrôle. Un modèle de régression logistique est d'abord utilisé pour estimer les coefficients. Les variables dépendantes sont ensuite ré-ordonnées aléatoirement et le modèle est estimé de nouveau 999 fois. Pour chaque variable indépendante, les auteurs obtiennent donc une distribution pour les coefficients. Finalement, ils comparent le coefficient du modèle original aux 999 coefficients subséquents pour déterminer s'il est significatif ou non. Les statistiques descriptives des variables indiquent que toutes les différences de moyennes et de médianes entre les deux groupes sont dans le sens prévu. Cependant, seules les différences entre les variables de croissance des bénéfices (moins élevée pour les firmes qui ont corrigé leurs bénéfices passés en raison d'une erreur que pour les firmes de contrôle) et d'utilisation de PCGR plus agressif (plus élevée) sont statistiquement significatives à un niveau de confiance de 99 %, alors que celles entre les trois variables

reliées à l'environnement de contrôle (moins élevée dans les trois cas) le sont à un niveau de confiance de 95 %. Les résultats du modèle estimé de nouveau 999 fois indiquent que les variables présence d'un détenteur de bloc d'actions, croissance des bénéfices, choix comptables et présence d'un comité de vérification sont statistiquement significatives à un niveau de confiance de 95 %. Les résultats de la régression logistique initiale sont semblables. Enfin, les auteurs ont estimé un modèle en n'utilisant que les dix cas de fraude et dix firmes de contrôle. Les résultats de la régression sont similaires, sauf en ce qui a trait à la variable firme de vérification qui est maintenant statistiquement significative à un niveau de confiance de 90 %.

Pour leur part, Grove et Cook (2004) évaluent l'utilité de facteurs de risque, principalement quantitatifs, pour détecter la manipulation des bénéfices et/ou la fraude chez quatre des plus grandes entreprises impliquées dans les scandales financiers des dernières années : Enron, WorldCom, Global Crossing et Qwest. Les variables financières qu'ils utilisent proviennent de trois sources. Tout d'abord, parmi les cinq ratios du modèle de Beneish (1999), deux sont de bons indicateurs : l'indice de marge brute (facteur de risque pour Enron et Global Crossing; possiblement pour WorldCom et Qwest) et l'indice de croissance des ventes (facteur de risque pour Enron et Global Crossing; possiblement pour Qwest). Ensuite, parmi les ratios-clés utilisés par les investisseurs, leurs résultats indiquent que quelques-uns sont utiles. Les ratios de la valeur au marché (*market to book ratio*) et du cours-bénéfice (*price to earnings ratio*), faisant partie des ratios d'évaluation, signalent la présence d'une fraude chez Enron. Tous les ratios de rentabilité (marge nette, croissance des ventes et croissance des bénéfices) et d'efficacité des gestionnaires (rendement de l'actif et rendement des fonds propres) qu'ils ont analysés sont pertinents, car ils envoient tous des signaux positifs pour les quatre entreprises. Parmi les ratios reliés à la situation financière, le ratio de liquidité générale peut être considéré comme un facteur de risque pour WorldCom, Global Crossing et Qwest. Enfin, les deux ratios recommandés par des analystes financiers et des vendeurs à découvert se révèlent particulièrement utiles selon les auteurs. En effet, la mesure de qualité des bénéfices signale des problèmes chez les quatre entreprises, alors que le taux d'impôt effectif (*effective cash tax rate*) le fait chez deux d'entre elles (Enron et WorldCom). Par ailleurs, Grove et Cook affirment qu'il

peut être intéressant d'avoir recours à un certain nombre de variables, dont quelques-unes non financières, pour améliorer la détection de problèmes comptables. Ils ont noté, entre autres, qu'une importante chute du prix de l'action (facteur de risque pour les quatre entreprises), que la démission d'un ou de plusieurs hauts dirigeants (facteur de risque pour Enron et Qwest), qu'une augmentation du nombre de transactions d'initiés (facteur de risque pour les quatre entreprises), que la présence d'un système comptable complexe et opaque (facteur de risque pour Enron et Qwest) et que la présence d'un chef de la direction susceptible face aux critiques des analystes financiers (facteur de risque pour Enron et Qwest) peuvent tous être des indicateurs additionnels de manipulation des bénéfices et/ou de fraude.

2.2.2. - Gouvernance

Beasley (1996) est l'un des chercheurs qui s'est le plus intéressé au lien existant entre les mécanismes de gouvernance et la fraude contenue dans les états financiers. Dans cette étude, il examine la relation existant entre certaines caractéristiques du conseil d'administration et la probabilité de fraude comptable. Son échantillon est composé de 75 entreprises dont les états financiers contiennent une fraude, obtenues à partir des AAER et du *Wall Street Journal*, de 1982 à 1991. De leur côté, les 75 entreprises constituant l'échantillon de contrôle ont été sélectionnées en fonction de la taille, de l'industrie, du marché boursier et de la période de temps. Sa variable indépendante d'intérêt est le pourcentage d'administrateurs externes sur le conseil d'administration. Toutes les autres variables (pourcentage de variation des actifs, nombre de pertes nettes dans la période précédant la fraude, nombre d'années depuis que la firme est publique, nombre d'actions détenues par les membres de la haute direction faisant partie du conseil d'administration, durée de la présence du chef de la direction sur le conseil d'administration, le chef de la direction est aussi le président du conseil et présence de détenteurs de blocs d'actions indépendants de la direction) servent uniquement de variables de contrôle. L'auteur observe que le nombre moyen (médian) d'administrateurs externes sur le conseil d'administration des entreprises dont les états financiers sont manipulés est de 50,2 % (50,0 %), alors qu'il est de 64,7 % (64,3 %) pour les entreprises de contrôle. En effectuant une régression logistique, il obtient un

coefficient négatif et statistiquement significatif pour la variable pourcentage d'administrateurs externes sur le conseil d'administration, alors que tous les coefficients des variables de contrôle sont non significatifs. Il arrive à des résultats identiques en séparant les administrateurs externes en administrateurs indépendants et administrateurs liés à l'entreprise (*gray directors*); en ajoutant la variable présence d'un comité de vérification (coefficient non significatif) et un terme d'interaction entre les variables présence d'un comité de vérification et pourcentage d'administrateurs externes sur le conseil d'administration (coefficient non significatif); en ajoutant des variables portant sur le nombre d'actions détenues par les administrateurs externes (coefficient négatif et statistiquement significatif), sur la durée de leur mandat sur le conseil d'administration (coefficient négatif et statistiquement significatif), sur le nombre de postes d'administrateurs de différentes entreprises occupés par ceux-ci (coefficient positif et statistiquement significatif) et sur la taille du conseil d'administration (coefficient positif et statistiquement significatif).

Beasley *et al.* (2000) comparent eux aussi les mécanismes de régie interne d'entreprises reconnues coupables de fraude comptable à ceux d'entreprises de contrôle. Leur étude est particulière, car ils effectuent la comparaison par rapport à l'ensemble des firmes d'une industrie donnée. Leur échantillon, obtenu à partir de l'étude de Beasley *et al.* (1999), contient 66 entreprises ayant commis une fraude à l'intérieur de leurs états financiers (25 dans l'industrie technologique, 19 dans celle des soins de santé et 22 dans celle des services financiers), alors que leur échantillon de contrôle, tout comme les variables de gouvernance, d'ailleurs, provient du *1999-2000 Public Company Governance Survey*, publié par la *National Association of Corporate Directors*. Les critères de sélection des entreprises de contrôle sont la taille et l'industrie. Les variables explicatives portent sur les caractéristiques du comité de vérification, sur la présence d'une fonction de vérification interne et sur les caractéristiques du conseil d'administration. Dans les trois industries, les auteurs observent que la taille médiane des entreprises ayant commis une fraude est relativement petite en comparaison avec celle des entreprises du *Fortune 1000*, qu'elles ont de faibles profits et que la plupart d'entre elles ne sont pas cotées au NYSE ou au *American Stock Exchange* (AMEX). Par ailleurs, ils notent que les entreprises ayant commis une fraude dans les industries

technologique (valeur de p inférieure à 0,10) et des services financiers (valeur de p inférieure à 0,05) sont significativement moins susceptibles d'avoir un comité de vérification que les entreprises de leur industrie respective. Dans chacune des trois industries, le pourcentage de firmes ayant un comité de vérification entièrement composé d'administrateurs externes est plus faible pour les entreprises ayant commis une fraude. Cette différence est particulièrement marquée dans l'industrie des services financiers où 94 % des firmes de contrôle ont un comité de vérification entièrement composé d'administrateurs externes, alors que seulement 17 % des entreprises ayant commis une fraude en ont un. Dans les industries technologiques et des soins de santé, les membres du comité de vérification des entreprises ayant manipulé frauduleusement leurs états financiers se rencontrent significativement moins souvent (une fois par année), à un niveau de confiance de 95 %, que ceux des entreprises de contrôle (deux ou trois fois par année). De plus, dans chaque industrie, la présence d'une fonction de vérification interne est, de manière significative (valeur de p inférieure à 0,05), plus faible dans les entreprises ayant commis une fraude que dans les entreprises de contrôle. Enfin, en ce qui a trait aux caractéristiques du conseil d'administration, une seule différence est statistiquement significative, à un niveau de confiance de 95 %, entre les deux groupes d'entreprises : dans les trois industries, la proportion de conseils d'administration composés d'une majorité d'administrateurs externes est plus faible pour les entreprises ayant commis une fraude que pour les firmes de contrôle.

L'étude de Dechow *et al.* (1996) s'intéresse, quant à elle, aux causes et aux conséquences de la gestion des bénéfices. Plus particulièrement, les auteurs se penchent sur les entreprises qui ont commis des violations des PCGR, sans qu'elles aient nécessairement été reconnues coupables de fraude par la SEC³. Ils cherchent à déterminer à quel point les manipulations alléguées peuvent être expliquées par des hypothèses de gestion des bénéfices et s'il existe une relation entre la gestion des bénéfices et les mécanismes de gouvernance. L'échantillon est composé de 92 firmes, sélectionnées à partir des AAER publiés entre 1982 et 1992, et de 92 firmes de contrôle choisies selon deux critères : la taille et l'industrie. Les variables auxquelles les auteurs ont recours ont trait à la gouvernance, mais aussi aux motivations pour manipuler les

³ En fait, 69 des 92 firmes de l'échantillon ont été reconnues coupables d'avoir violé les clauses reliées à la fraude du *Securities Exchange Act* de 1934.

bénéfices. Ils effectuent une analyse univariée. En ce qui concerne les variables reliées aux motivations, leurs résultats indiquent que 39 % des entreprises ayant manipulé leurs bénéfices ont besoin de financement externe au cours des deux années suivant la manipulation, alors que seulement 16 % des firmes de contrôle en requièrent (la différence est statistiquement significative à un niveau de confiance de 95 %). De plus, 36 % des firmes ayant manipulé leurs bénéfices émettent des titres financiers, alors que seulement 20 % des entreprises de contrôle le font (*idem*). Les fonds amassés lors des émissions par les entreprises ayant manipulé leurs bénéfices sont aussi plus importants que ceux des firmes de contrôle (différence de moyenne non significative, mais de médiane oui; valeur de *p* inférieure à 0,03). Selon les auteurs, ces résultats confirment la thèse voulant que les gestionnaires des firmes ayant manipulé leurs bénéfices le fassent pour diminuer leur coût de capital externe. Par ailleurs, les gestionnaires et les administrateurs des firmes ayant manipulé leurs bénéfices ne vendent pas une proportion significativement plus grande d'actions de leur firme que ne le font les administrateurs des entreprises de contrôle. Même si 27 chefs de la direction des entreprises ayant manipulé leurs bénéfices vendent des actions durant la période de la manipulation, la valeur relative de leurs ventes ne diffère pas de celle des 17 chefs de la direction des firmes de contrôle qui en vendent. De plus, la présence d'un plan de rémunération lié aux bénéfices (*earnings-based bonus plan*) ne diffère pas significativement entre les entreprises ayant manipulé leurs bénéfices et celles de contrôle. Dans les deux groupes, environ 40 % des firmes ont un tel plan de rémunération. Enfin, les entreprises ayant manipulé leurs bénéfices ont un levier financier médian (26 %) significativement plus élevé que les firmes de contrôle (16 %). Dix-huit firmes ayant manipulé leurs bénéfices (19,6 %) violent les clauses de leur convention de prêt, alors que seulement 9,8 % des entreprises de contrôle le font (la différence est statistiquement significative à 6 %). En ce qui a trait à la gouvernance, selon Dechow *et al.* (1996), les résultats supportent l'hypothèse voulant que les entreprises ayant manipulé leurs bénéfices ont de faibles mécanismes de régie interne. Même si les deux groupes d'entreprises ont, en moyenne, un conseil d'administration de même taille (neuf membres), les firmes ayant manipulé leurs bénéfices ont une proportion significativement plus grande d'initiés sur leur conseil d'administration (53 %) par rapport aux entreprises de contrôle (40 %). En plus, les initiés des entreprises ayant manipulé leurs bénéfices possèdent un pourcentage des

actions totales détenues par tous les membres du conseil (90 %) significativement plus grand que ceux des firmes de contrôle (77 %). Les entreprises ayant violé les PCGR sont aussi moins susceptibles d'avoir un comité de vérification (58 % versus 76 %, respectivement) et des détenteurs de bloc d'actions (42 % versus 57 %, respectivement) que les firmes de contrôle. De plus, 54 % (34 %) des entreprises ayant manipulé leurs bénéfices (entreprises de contrôle) ont un conseil d'administration dominé par les initiés. Par ailleurs, le chef de la direction semble avoir plus de pouvoir sur le conseil d'administration des entreprises ayant manipulé leurs bénéfices, car il y est aussi le président dans 86 % des cas, comparativement à 74 % pour les entreprises de contrôle. Il est aussi le fondateur de l'entreprise dans 49 % des entreprises ayant manipulé leurs bénéfices, alors qu'il l'est dans seulement 30 % des firmes de contrôle. Enfin, les entreprises ayant manipulé leurs bénéfices et les firmes de contrôle n'ont pas plus souvent recours l'une que l'autre à une grande firme de vérification comptable.

2.2.3. - Initiés

Dunn (2004) est parmi les rares auteurs qui s'intéressent aux initiés. Il étudie, d'une part, la manière dont les initiés exercent leur contrôle sur l'équipe de direction et sur le conseil d'administration et, d'autre part, comment cette concentration du pouvoir entre leurs mains contribue à la décision de publier délibérément de l'information financière mensongère. Son échantillon inclut 103 entreprises ayant commis une fraude comptable, obtenues par le biais des AAER de 1992 à 1996 et de quotidiens, et 103 firmes de contrôle dont les critères de sélection sont la taille et l'industrie. Il utilise les variables explicatives suivantes : (1) la proportion des postes à caractère financier qui sont détenus par les initiés (qui mesure leur pouvoir hiérarchique (*structural power*)), (2) la proportion d'initiés sur le conseil d'administration, (3) le nombre d'actions détenues par les initiés en pourcentage du nombre total d'actions détenues par le conseil (qui mesure le pouvoir lié à la propriété (*ownership power*)), en plus de variables de contrôle reliées aux caractéristiques de l'équipe de direction (durée du mandat, diversité et taille), aux mécanismes de gouvernance (durée du mandat des administrateurs et taille du conseil d'administration) et aux motifs économiques (difficultés financières et émissions d'actions secondaires). Pour le développement de ses trois modèles, il a recours à des

régressions logistiques en coupe croisée et à une procédure d'estimation de la probabilité maximale. Les résultats du premier modèle indiquent que la fraude est reliée à un pourcentage élevé d'initiés sur le conseil et à une jeune équipe de gestionnaires et d'administrateurs. De plus, les initiés détiennent un plus grand nombre d'actions, en pourcentage du nombre total d'actions détenues par les administrateurs de l'entreprise, que ceux-ci. De son côté, le deuxième modèle révèle que contrôler pour les principaux postes de direction n'a pas d'impact statistiquement significatif. Néanmoins, l'auteur soupçonne que le pouvoir hiérarchique des initiés peut être dû à leur contrôle de l'équipe de direction et du conseil d'administration. Le deuxième modèle considère donc le pouvoir hiérarchique comme étant une combinaison de la proportion de titres détenus par les initiés et le pourcentage d'initiés sur le conseil d'administration. Ce terme d'interaction est statistiquement significatif à un niveau de confiance de 99 %, tandis que les coefficients des autres variables sont similaires à ceux du premier modèle. Selon l'auteur, ce résultat suggère que le pouvoir des initiés provient de leur occupation des postes-clés de direction et des sièges du conseil d'administration. Dans cet échantillon, les initiés qui sont dans une telle position ont près de 3,5 fois plus de chances de s'engager dans une fraude que les autres. Enfin, dans le troisième modèle, auquel l'auteur ajoute trois variables (présence d'un comité de vérification, nombre de rencontres des membres du comité durant l'année de la fraude et pourcentage d'administrateurs externes indépendants sur le comité), aucune nouvelle variable n'est statistiquement significative, même si le modèle reste sensiblement le même, à une exception près : lorsque la variable pourcentage d'administrateurs externes indépendants sur le comité a été ajoutée, la variable durée du mandat des administrateurs a cessé d'être statistiquement significative. Par conséquent, Dunn (2004) affirme que la présence d'un comité de vérification ne permet pas, dans cet échantillon, du moins, de prévenir la perpétration d'une fraude comptable par l'équipe de direction étant donné le pouvoir considérable des initiés.

2.3. - Les modèles

Les auteurs développant des modèles de détection de la fraude comptable ont souvent recours à des techniques de régression ou de réseaux de neurones. En effet, au cours des dernières années, les développements en intelligence artificielle ont rendu les réseaux de

neurones plus attrayants et plus faciles à utiliser. Ils se sont donc offerts naturellement aux chercheurs comme solution de rechange aux techniques de régression qui requièrent, par exemple, des hypothèses de normalité et aux systèmes experts, qui peuvent être ardues à implanter. Par ailleurs, ces auteurs utilisent une variété de variables quantitatives et qualitatives, financières et non financières, reliées à un ou plusieurs groupes différents : ratios financiers, gouvernance, transactions d'initiés, *etc.* Les variables financières, dont font partie les ratios, représentent la classe de variables prédictives la plus populaire, car elles possèdent la caractéristique d'être calculables à partir de données publiques faciles à obtenir.

2.3.1. - Régression

Persons (1995) développe deux modèles de détection de la fraude contenue dans les états financiers, un pour l'exercice financier dans lequel la fraude a débuté et un autre pour l'exercice précédent. Il a construit un échantillon de 103 entreprises reconnues coupables de fraude pour l'année dans laquelle la fraude a commencé et de 100 entreprises pour l'année précédente, toutes obtenues à partir des *Accounting Series Releases*, publiés eux aussi par la SEC, de 1974 à 1981 et des AAER de 1982 à 1991. Son échantillon de contrôle, qui est composé du même nombre d'observations pour chaque exercice financier, a été formé, en plus de la période de temps, sur la base de l'industrie. Il ne contrôle donc pas pour la taille des entreprises, ce qui peut miner la validité de ses résultats. Il a recours à dix ratios, calculés à partir de données comptables publiques, mesurant sept aspects d'une entreprise : le levier financier, la rentabilité, la composition des actifs, la liquidité, le taux de rotation du capital, la taille et la santé financière. Ses deux modèles sont développés à partir de la méthode de régression logistique. Il calcule les coûts espérés de mauvaise classification pour choisir le meilleur seuil de classification. De plus, les calculs sont faits avec des coûts relatifs de mauvaise classification variant entre 1:1 et 30:1. L'auteur estime la performance des modèles en comparant leur coût espéré de mauvaise classification à celui d'une stratégie naïve supposant que les états financiers de toutes les firmes sont exempts de fraude. Une analyse univariée suggère que les entreprises ayant manipulé leurs états financiers diffèrent des autres entreprises selon quatre aspects (ces variables prédictives sont

incluses dans les deux modèles) : elles ont un levier financier plus élevé, un taux de rotation du capital plus faible, une plus grande proportion d'inventaires et de comptes à recevoir et sont de plus petite taille. Le coût espéré de mauvaise classification des modèles est plus faible que celui de la stratégie naïve pour tout coût relatif de mauvaise classification. Le pourcentage d'erreurs de type I indique que plus le coût relatif augmente, plus les modèles classent correctement les entreprises ayant commis une fraude. Par exemple, le taux d'erreurs de type I se situe à 97 % pour un coût relatif de 1:1, comparativement à 36 % pour un coût relatif de 30:1. Bien que le taux d'erreurs de type II augmente quand le coût relatif augmente, le pourcentage est relativement faible (maximum de 21 %). De plus, quand le coût relatif augmente, il y a une plus grande réduction en pourcentage du coût espéré de mauvaise classification du modèle par rapport à la stratégie naïve. Par ailleurs, il n'y a aucune différence significative entre les deux modèles quand les coûts relatifs sont faibles (1:1 et 5:1). La différence entre les deux modèles devient apparente quand les coûts relatifs sont d'au moins 10:1, un échelon plus réaliste selon l'auteur. Ces différences sont les suivantes : comparativement à la stratégie naïve, le coût espéré de mauvaise classification du modèle développé pour détecter la fraude l'année précédant son commencement est plus faible que celui de l'autre modèle. Ce dernier donne aussi lieu à un taux d'erreurs de type I plus élevé pour les coûts relatifs de mauvaise classification 10:1 (12 % de plus) et 30:1 (17 %). D'après Persons (1995), il serait donc plus facile de détecter les firmes qui ont un risque élevé de commettre une fraude que de détecter les firmes qui ont commis une fraude.

De leur côté, Bell et Carcello (2000) cherchent à construire un modèle d'estimation de la probabilité que les clients d'une firme de vérification comptable américaine ait commis une fraude. Ils utilisent des données concernant 77 entreprises ayant commis une fraude entre 1960 et 1980 et 305 entreprises de contrôle en 1990. Les auteurs ne contrôlent donc pas pour le temps, ce qui constitue une limite de leur étude. Leurs variables prédictives sont constituées de 46 facteurs de risque qualitatifs présentés sous la forme de questions binaires aux vérificateurs externes. Ils développent et testent des centaines de modèles de régression logistique avec les 46 facteurs en question, en incluant ou non ceux qui ne sont pas statistiquement significatifs sur une base univariée. Individuellement, seuls les facteurs suivants sont statistiquement significatifs : la

direction a menti au vérificateur externe ou répondait de manière trop évasive à ses demandes; contrôle interne insuffisant; attitude de la direction agressive sans raison; la direction place trop d'importance sur l'atteinte des cibles de bénéfices; transactions ou comptes dont l'importance est significative et qui sont difficiles à vérifier; et l'expérience du vérificateur lui indique que la direction fait preuve de malhonnêteté. Le meilleur modèle développé par les auteurs contient les variables contrôle interne insuffisant, entreprise à croissance rapide, rentabilité relative inadéquate ou inconsistante, la direction place trop d'importance sur l'atteinte des cibles de bénéfices, la direction a menti au vérificateur externe ou répondait de manière trop évasive aux demandes du vérificateur, le type de propriété de l'entreprise et un terme d'interaction entre contrôle interne insuffisant et la direction place trop d'importance sur l'atteinte des cibles de bénéfices. Ils ont évalué par la suite la performance du modèle à l'aide de plusieurs seuils de classification ou, en d'autres mots, de probabilités de fraude, variant entre 0,01 et 0,99. Par exemple, pour un seuil égal à 0,10, le taux de bonne classification du modèle est de 95 % pour les entreprises ayant commis une fraude et de 71 % pour les entreprises de contrôle dans l'échantillon d'estimation et de 90 % et de 67 %, respectivement, sur l'échantillon de validation. De manière générale, les catégories de risque élevé et très élevé (probabilité de fraude supérieure ou égale à 0,25) comprennent 80 % des cas de fraude et 11 % des cas sans fraude, tandis que les catégories de risque faible et très faible (probabilité de fraude inférieure ou égale à 0,10) incluent 69 % des cas sans fraude et 8 % des cas de fraude. Le modèle classe donc correctement une majorité des observations des deux groupes. Pour les cas de fraude, le modèle surpasse la performance des prédictions, faites sans assistance, des vérificateurs externes : il classe 80 % des cas dans les catégories de risque élevé ou très élevé, alors que les vérificateurs le font dans 35 % des cas; 12 % dans les catégories de risque modéré, alors que les vérificateurs le font dans 36 % des cas; et 8 % dans les catégories de risque faible et très faible, alors que les vérificateurs le font dans 9 % des cas. Cependant, en ce qui concerne les entreprises de contrôle, les prédictions du modèle et des vérificateurs externes sont similaires.

Contrairement aux auteurs précédents, Beneish (1997) s'intéresse à la gestion des bénéfices. Dans un premier article, il présente un modèle de détection pour les firmes

qui subissent une performance financière extrême. Son échantillon est composé de 64 entreprises, dont 47 ont été poursuivies en cour pour fraude, sélectionnées à partir des AAER et de quotidiens, et couvre la période allant de 1987 à 1993. Il utilise un échantillon de contrôle composé de 2 658 firmes-années et de 2 118 firmes ayant de grandes réserves discrétionnaires (*large positive discretionary accruals*), s'étalant de 1983 à 1992, qu'il sépare en deux sous-échantillons : d'un côté, les utilisateurs agressifs des réserves et, de l'autre, les utilisateurs agressifs des réserves dont les ventes sont en hausse. Il a recours à des variables qui ont un impact sur les incitations à violer les PCGR, sur l'habileté à les violer et sur la probabilité de détecter la violation. Il utilise un modèle de régression probabilistique. Le modèle utilisant l'échantillon de contrôle composé d'utilisateurs agressifs des réserves a un pouvoir de prédiction significatif. Cinq variables y sont statistiquement significatives : l'indice d'adéquation entre les comptes à recevoir et les ventes (signe positif), le ratio réserves totales sur actif total (négatif), les rendements anormaux passés (négatif) et les variables réserves positives dans les années précédant la violation (positif) et ventes en baisse (négatif). Le modèle ayant recours à l'autre échantillon de contrôle diffère sur deux points : la variable ventes en baisse est non significative et le levier financier (positif) est maintenant statistiquement significatif. L'auteur procède à une analyse de sensibilité exhaustive, ce qui constitue une des principales forces de son étude. Tout d'abord, il enlève du modèle une ou plusieurs variables à la fois. Il obtient des résultats similaires pour les autres variables. Ensuite, il estime de nouveau le modèle à l'aide de 100 échantillons aléatoires. Les résultats sont une fois de plus semblables. Par ailleurs, il mesure la performance du modèle dans un échantillon de validation et calcule la probabilité de violation des PCGR. Le modèle estime des probabilités de violation plus élevées pour les entreprises ayant violé les PCGR que pour les utilisateurs agressifs des réserves dans les échantillons d'estimation (moyenne (médiane) de 0,106 (0,072) par rapport à 0,021 (0,008), respectivement) et de validation (0,123 (0,058) par rapport à 0,026 (0,009), respectivement). Toutes les différences sont statistiquement significatives. En moyenne, les entreprises ayant violé les PCGR sont quatre à cinq fois plus susceptibles de contrevenir aux PCGR que les utilisateurs agressifs des réserves. Les résultats sont similaires en utilisant l'échantillon d'utilisateurs agressifs des réserves dont les ventes sont en hausse. Par la suite, l'auteur compare le modèle au modèle basé sur les réserves

de Jones modifié. Or, celui-ci n'identifie qu'entre 11 et 19 entreprises ayant violé les PCGR en fonction de l'année et du niveau de confiance utilisés, ce qui représente un faible taux de détection. Il compare aussi la performance du modèle à celle de six stratégies, basées sur le modèle de Jones, en fonction des coûts espérés de mauvaise classification. Il trouve que les coûts espérés du modèle sont systématiquement plus faibles que ceux de toutes les stratégies et que le modèle identifie les entreprises ayant violé les PCGR seulement quand le coût d'une erreur de type I est plus grand que celui d'une erreur de type II. Plus particulièrement, dans l'échantillon d'estimation, les résultats pour les utilisateurs agressifs des réserves sont les suivants : le modèle commet moins d'erreurs de type I et II sous toutes les hypothèses de coûts relatifs de mauvaise classification, sauf celle d'égalité; pour les coûts relatifs 10:1 et 20:1, le modèle identifie 28,1 % et 56,8 % des 43 entreprises ayant violé les PCGR, alors qu'avec la meilleure stratégie, le modèle de Jones en identifie seulement 20,9 %. Les résultats sont similaires dans l'échantillon de validation et pour les utilisateurs agressifs des réserves dont les ventes sont en hausse.

Dans un second article, Beneish (1999) développe le modèle de détection de la manipulation des bénéfices dont il a été question dans Grove et Cook (2004). Cette fois-ci, il a recours à un échantillon composé de 74 firmes ayant manipulé leurs bénéfices, obtenus à partir des AAER et de recherches dans les médias et couvrant la période allant de 1982 à 1992, et de 2 332 firmes de contrôle, sélectionnées sur la base de l'année de la violation et de l'industrie. Il utilise des variables prédictives construites à partir de données comptables, notamment des indices, pour la plupart de la forme « ratio de l'année t sur ratio de l'année t-1 », liées à l'adéquation entre les comptes à recevoir et les ventes (DSRI), à la marge brute (GMI), à la qualité de l'actif (AQI), à la croissance des ventes (SGI), à l'amortissement (DEPI), aux dépenses générales, administratives et liées aux ventes, (SGAI), au levier financier (LVGI), en plus du ratio réserves totales sur actifs totaux (TATA). Il développe deux modèles à l'aide de techniques de régression probabilistique. Les deux modèles sont statistiquement significatifs et ont un pouvoir descriptif. Dans le deuxième modèle, les variables suivantes sont statistiquement significatives et leur coefficient adopte le signe attendu : DSRI (positif), GMI (positif), AQI (positif), SGI (positif) et TATA (positif). Les résultats du premier modèle sont

similaires. Par la suite, l'auteur estime les probabilités de manipulation des firmes. Dans l'échantillon d'estimation le premier modèle prédit une probabilité moyenne (médiane) plus élevée pour les manipulateurs (0,107 (0,024)) que pour les autres (0,006 (0,003)). Dans l'échantillon de validation, ces probabilités sont égales à 0,097 (0,009) et à 0,007 (0,002), respectivement. Toutes les différences sont statistiquement significatives. Les résultats du deuxième modèle sont similaires. Les manipulateurs sont donc dix fois plus susceptibles de trafiquer leurs bénéfiques que les non-manipulateurs. Ensuite, comme dans l'étude précédente, il procède à une analyse de sensibilité complète, ce qui constitue encore un point fort de son travail. De manière générale, les résultats sont robustes à différentes estimations des probabilités *a priori* de manipulation des bénéfiques, à plusieurs spécifications du modèle, à de nombreuses définitions des variables prédictives et aux choix des échantillons d'estimation et de validation. Enfin, il mesure l'utilité du modèle en tant qu'outil de classification. Les résultats des deux modèles sont similaires, encore une fois. Par exemple, pour le second, dans l'échantillon d'estimation, à des coûts relatifs de mauvaise classification de 20:1 ou de 30:1, ce dernier classe correctement 74,0 % des manipulateurs et 86,2 % des non-manipulateurs. Dans l'échantillon de validation, à des coûts relatifs de 20:1 ou de 30:1, il classe correctement 50,0 % des manipulateurs et 92,8 % des non-manipulateurs. De l'aveu même de l'auteur, ces résultats sont décevants. Ainsi, il se demande si une stratégie naïve classant toutes les entreprises comme manipulatrices entraîne un coût espéré de mauvaise classification plus faible que le modèle. Pour les échantillons d'estimation et de validation, le modèle a des coûts espérés de mauvaise classification plus faibles que la stratégie naïve quand le coût de l'erreur de type I est supérieur à celui de l'erreur de type II. Par exemple, dans l'échantillon d'estimation, les coûts espérés de mauvaise classification du modèle relatif à la stratégie naïve sont 0,496 et 0,417 pour les coûts relatifs de mauvaise classification de 20:1 et 30:1, respectivement. Dans l'échantillon de validation, ces coûts sont de 0,623 et 0,582, respectivement.

Contrairement aux autres auteurs qui ont recours à des variables financières, Lee, Ingram et Howard (1999) estiment dans quelle mesure la relation entre les bénéfiques et les flux monétaires peut être utilisée pour signaler la présence d'une fraude dans les états financiers. Ils émettent l'hypothèse que les bénéfiques des firmes qui les ont manipulés

seront substantiellement plus élevés que leurs flux monétaires liés aux opérations pendant la période dans laquelle la fraude s'est déroulée. Ils utilisent un échantillon composé de 56 cas de fraude obtenus à partir des AAER et du *Wall Street Journal Index* entre 1978 et 1991. Ils ont recours à deux échantillons de contrôle, sélectionnés en fonction de l'année de la fraude et de l'industrie : le premier inclut des firmes qui ont fait faillite, ont été liquidées, *etc.*, qui sont plus jeunes, qui ont une piètre performance financière et sont donc plus difficiles à séparer des entreprises de l'échantillon de fraude (« échantillon de firmes non cotées »), alors que le second est constitué de firmes cotées au NYSE, AMEX ou au comptoir, qui sont plus grandes et mieux établies (« échantillon de firmes cotées »). Ils effectuent aussi leurs comparaisons pour toutes les années précédant celle de la fraude (150 firme-années; « années pré-découverte ») et pour l'année où la variable EC (voir plus bas) est à son maximum pour les entreprises de l'échantillon de fraude (56 firmes; « valeurs maximales »). Dans les deux cas, l'échantillon de contrôle contient plus de 18 000 firmes-années. La différence entre les bénéfices et les flux monétaires liés aux opérations (EC) constitue leur variable prédictive principale. Toutes les autres (au total 12, pour la plupart des variables financières associées à un niveau de risque de fraude élevé et/ou à la variable prédictive principale) servent de variables de contrôle. Les auteurs utilisent des modèles de régression logistique. Ils trouvent que le coefficient de la variable EC est positif et statistiquement significatif dans toutes les versions du modèle. Le coefficient de la variable rendement de l'actif est positif et statistiquement significatif dans l'échantillon de firmes non cotées pour les années pré-découverte et pour les valeurs maximales, alors qu'il est négatif et statistiquement significatif dans l'échantillon de firmes cotées pour les années pré-découverte et pour les valeurs maximales, ce qui fait dire aux auteurs que ce ne sont pas les bénéfices en tant que tels qui signalent un niveau de risque de fraude élevé, mais l'excédant des bénéfices sur les flux monétaires liés aux opérations. Les autres variables statistiquement significatives sont le levier financier, les bénéfices non répartis, la valeur au marché, l'émission de titres financiers, la cotation au NYSE et le code SIC (3000-3999) pour l'échantillon de firmes non cotées pour les années pré-découverte. Les coefficients sont tous positifs, sauf celui de la cotation au NYSE. Seules les variables levier financier et valeur au marché sont statistiquement significatives dans l'échantillon de firmes non cotées pour les valeurs maximales. En plus de la variable

EC, le levier financier, la cotation (NYSE ou AMEX), l'âge (nombre d'années listée sur COMPUSTAT) et le code SIC sont significatifs dans l'échantillon de firmes cotées pour les années pré-découverte et pour les valeurs maximales. Les auteurs développent par la suite 36 modèles, soit un pour chaque code SIC à quatre chiffres représenté dans l'échantillon de fraude. Le modèle de prédiction de chaque échantillon de validation (industrie) est développé en utilisant toutes les firmes de l'échantillon de fraude dans les 35 autres industries et toutes les firmes de contrôle qui leur sont associées dans COMPUSTAT. Ils utilisent les données de l'année précédant celle de la fraude pour développer les modèles. Les échantillons de fraude et de contrôle contiennent 56 et 564 observations, respectivement. Enfin, ils comparent la performance du modèle avec et sans la variable EC. Leurs résultats indiquent que les coefficients ne varient pas beaucoup à travers les 36 équations et sont similaires à ceux présentés précédemment. En utilisant la variable EC et en considérant qu'une entreprise a commis une fraude si sa probabilité de fraude est supérieure ou égale à 10 %, le taux de bonne classification pour l'ensemble des 36 échantillons de validation est de 73,2 % pour ces firmes et de 90,1 % pour les firmes de contrôle. Plus la probabilité de fraude augmente, moins le modèle classe correctement les firmes ayant commis une fraude et plus il classe correctement les entreprises de contrôle. Sans la variable EC, le taux de bonne classification des entreprises ayant eu recours à la fraude chute à 50,0 % et celui des entreprises de contrôle, à 81,2 %.

Comme Dunn (2004), Summers et Sweeney (1998) s'intéressent aux initiés. Cependant, ils ne s'intéressent pas au pouvoir détenu par ceux-ci, mais examinent plutôt si les transactions d'initiés peuvent servir d'indicateur aux vérificateurs externes pour estimer la probabilité qu'une fraude comptable ait été commise. Ils sont les seuls auteurs à considérer les transactions d'initiés comme une variable prédictive potentielle. Des recherches dans le *Wall Street Journal* de 1980 à 1987 leur ont permis de trouver 51 cas de fraude. Ils ont sélectionné leur échantillon de contrôle, comprenant aussi 51 observations, sur la base de l'industrie, de la taille et de l'exercice financier avant que la fraude ne débute. Ils utilisent les variables prédictives liées aux transactions d'initiés suivantes : montant en dollars, nombre d'actions et nombre de transactions pour les achats et les ventes, montant net (ventes moins achats) en dollars et actions et nombre

total de transactions. Des variables comptables (score Z d'Altman, rendement de l'actif, croissance moyenne des ventes au cours des trois dernières années précédant celle de fraude, croissance des ventes de l'année précédant la fraude, indices d'adéquation entre les comptes à recevoir (l'inventaire) et les ventes et statut du client vis-à-vis sa firme de vérification comptable) leur servent de variables de contrôle. Ils estiment trois modèles de régression logistique. Le premier classe les firmes dans les catégories fraude et sans fraude à l'aide des variables comptables et le second, à l'aide des variables liées aux transactions d'initiés. Ces deux modèles produisent chacun un indice variant entre 0 à 1 mesurant le risque de fraude. Ces deux indices sont alors utilisés en tant que variables prédictives dans le troisième modèle. Les auteurs mesurent la performance à l'aide d'une mesure de concordance, qui indique le nombre de fois que les entreprises reconnues coupables de fraude sont classées comme étant plus risquées que les entreprises de contrôle, et du taux de bonne classification, en utilisant un seuil de classification égal à 0,5. Toutes les variables sont incluses dans le premier modèle, les variables indice d'adéquation entre l'inventaire et les ventes et rendement de l'actif étant très significatives. Sa mesure de concordance est de 67,8 % et son taux de bonne classification, de 59,8 %. Dans le deuxième modèle, seules les variables montant en dollars, nombre d'actions et nombre de transactions pour les achats et les ventes sont incluses. La mesure de concordance de ce modèle est 62,7 % et son taux de bonne classification, de 57,8 %. Enfin, les deux indices sont statistiquement significatifs dans le troisième modèle. Plus de poids est accordé aux variables comptables (coefficient égal à 4,1615) qu'à celles liées aux transactions d'initiés (3,6542). Les résultats indiquent aussi que les données comptables de l'année précédant la fraude ont un pouvoir prédictif important, car la mesure de concordance du modèle est de 72,2 % (4,4 points de pourcentage de plus que le premier modèle) et le taux de bonne classification, de 66,7 % (6,9 points de pourcentage de plus).

D'une manière un peu différente des autres études, Stice (1991) développe un modèle qui tente de classer les entreprises en fonction du risque de poursuite qu'elles représentent pour leur firme de vérification comptable. En d'autres mots, il tente d'établir des liens entre les caractéristiques des clients et des firmes de vérification qui sont liées à un échec du processus annuel de vérification et/ou à la présence d'erreurs

dans les états financiers. Les sources auxquelles il a eu recours pour trouver des cas dans lesquels une firme de vérification a été impliquée dans une poursuite sont le *Wall Street Journal Index* et les ASR de 1960 à 1985. Il exclut les cas impliquant des entreprises de services financiers et de services publics. Son échantillon final comporte 49 observations. Il utilise deux échantillons de contrôle : le premier a pour critère de sélection la période de temps et le second, sélectionné indépendamment du premier, la période de temps et l'industrie. Ses variables prédictives sont liées aux caractéristiques des clients (comptes à recevoir sur actif total, inventaire sur actif total, pourcentage de changement des ventes, score Z d'Altman, variabilité des rendements anormaux et capitalisation boursière), de la firme de vérification (taille, durée de la relation avec le client et taille relative des ventes à un client qui mesure l'indépendance). Il utilise un modèle de régression probabilistique. La performance du modèle, telle que mesurée par son coût espéré de mauvaise classification, est comparée à celle d'une stratégie naïve qui prédit que tous les clients d'une firme de vérification ne seront pas à l'origine d'une poursuite pour celle-ci. Pour l'échantillon de contrôle basé sur la période de temps, le pourcentage de changement des ventes (signe positif), la condition financière (négatif), la durée de la relation avec le client (négatif), l'indépendance (négatif), la variance des rendements anormaux (positif) et la capitalisation boursière (positif) sont significatifs à 5 % et leur coefficient adopte le signe prévu. Pour l'échantillon de contrôle basé sur la période de temps et l'industrie, le ratio inventaire sur actif total (positif), la condition financière (négatif) et la capitalisation boursière (positif) sont significatifs à 5 % et leur coefficient a le signe prédit en théorie, tandis que le ratio comptes à recevoir sur actif total (positif) et la variance des rendements anormaux (positif) sont significatifs à 10 % et leur coefficient prend aussi le signe prévu. Selon l'auteur, ces résultats démontrent les effets de l'inclusion dans une industrie, laquelle influencerait le coefficient des variables. Par ailleurs, plus la probabilité d'une poursuite augmente, moins les entreprises qui en sont à l'origine sont mal classées. De plus, plus le coût relatif de mauvaise classification augmente, plus le modèle classe correctement les entreprises qui sont source d'une poursuite pour leur vérificateur externe. Avec un coût relatif d'au moins 20:1 et une probabilité *a priori* de poursuite d'au moins 3 %, le modèle fait mieux que la stratégie naïve. Si la probabilité *a priori* de poursuite est de 3 %, le modèle a une meilleure performance que la stratégie naïve quand les coûts relatifs sont d'au moins 25:1.

2.3.2. - Réseaux de neurones

Kwon et Feroz (1996) ont été parmi les premiers auteurs à utiliser les réseaux de neurones pour développer un modèle de détection de la fraude comptable. Ainsi, à l'aide de réseaux de neurones, ils déterminent l'efficacité de facteurs de risque pour prédire quelles entreprises seront les cibles d'enquête (pour avoir commis une fraude dans leurs états financiers) par la SEC. Ils utilisent un échantillon formé, d'un côté, de 35 cibles d'enquête, sélectionnées à partir des AAER No. 1 à 244, et, de l'autre, de 35 firmes de contrôle dont les critères de sélection étaient l'industrie et la taille. Ils ont recours à six échantillons d'estimation contenant chacun 55 entreprises et autant de validation comprenant chacun, pour leur part, 15 firmes. Tous ces échantillons sont construits aléatoirement. Leurs variables correspondent à sept facteurs de risque qui sont sous la forme de changements en pourcentage sur une période de cinq années : quatre financiers reliés à la rentabilité, à la sensibilité aux taux d'intérêt, au niveau de difficulté de la vérification (*difficulty to audit*) et à la détresse financière, et trois non financiers, mesurant les taux de rotation du chef de la direction, du chef de la direction financière (*chief financial officer*) et du vérificateur externe. Ils comparent la performance de leurs réseaux de neurones à celle d'un modèle de régression logistique. Dans les échantillons d'estimation et de validation combinés, ils obtiennent un taux de bonne classification moyen des firmes cibles de 87,8 % (47,1 %) pour les réseaux de neurones (régression logistique) en utilisant les deux groupes de variables, de 73,3 % (52,9 %) en utilisant seulement les variables financières et de 80,0 % (52,9 %) en utilisant seulement les variables non financières. Malheureusement, les auteurs ne présentent pas séparément leurs résultats pour les échantillons d'estimation et de validation. De plus, ils ne font pas mention des résultats portant sur les firmes de contrôle. Par ailleurs, contrairement à bon nombre d'auteurs, ils n'incluent pas de coûts de mauvaise classification dans leurs modèles. Ces trois points constituent donc des faiblesses de leur étude.

Green et Choi (1997) développent quant à eux trois réseaux de neurones pour estimer le risque qu'une fraude soit contenue dans les états financiers d'entreprises manufacturières et de commerce au détail. L'étude se concentre sur l'étape préliminaire du processus annuel de vérification dans laquelle les ressources sont alloués aux

différents champs de vérification sur la base d'indicateurs du risque d'erreurs et d'irrégularités. Ils utilisent un échantillon qui comprend 86 entreprises, obtenues à partir des AAER parus entre 1982 et 1990, dont la fraude a trait à l'un des comptes du cycle des revenus et 86 entreprises de contrôle sélectionnées en fonction de l'année, de la taille et de l'industrie. Les données brutes des deux groupes d'entreprises, s'étendant jusqu'à quatre années avant le début de la fraude, sont transformées en calculant la différence en pourcentage qui existe entre la valeur d'un compte rapportée dans les états financiers et la valeur attendue de celui-ci lors de l'année sous enquête. Trois types de transformations sont utilisés. Cinq ratios (provisions pour créances douteuses sur ventes nettes, provisions pour créances douteuses sur comptes à recevoir, ventes nettes sur comptes à recevoir, marge brute sur ventes nettes et comptes à recevoir sur actif total) et trois comptes (ventes nettes, comptes à recevoir et provisions pour créances douteuses) servent de variables explicatives. Les résultats des trois réseaux utilisant à la fois les ratios et des mesures de tendance indiquent que leurs erreurs de type I et de type II sont significativement inférieures à 50,00 % dans l'échantillon d'estimation, dans celui de validation et dans les deux échantillons combinés. Par exemple, le réseau PSYDNN, celui qui a procuré aux auteurs les meilleurs résultats dans les deux échantillons combinés, a un taux d'erreur de type I (type II) nulle (15,38 %) dans l'échantillon d'estimation, de 26,67 % (33,33 %) dans celui de validation et de 15,09 % (21,95 %) dans les deux échantillons combinés. Les deux premières hypothèses des auteurs stipulant que les réseaux de neurones sont performants se voient donc confirmées. De plus, leurs résultats indiquent que le taux d'erreur global des réseaux est significativement inférieur à 100,00 % dans les deux échantillons combinés. En effet, il est de 48,67 % pour le réseau utilisant la méthode de transformation des données la moins sophistiquée (SPCNN), de 37,04 % pour celui utilisant la deuxième méthode la plus sophistiquée (PSYDNN) et de 68,64 % pour celui utilisant la méthode la plus sophistiquée (ISYDNN). La troisième hypothèse formulée par les auteurs voulant que les réseaux de neurones sont un outil de classification efficace est donc elle aussi confirmée. Par ailleurs, les auteurs ont comparé les taux d'erreur de type I et II d'un réseau entraîné avec seulement un des deux groupes de variables à la fois. Les ratios, et non les tendances comme ils s'y attendaient, ont permis d'obtenir les meilleurs résultats. Les taux d'erreur de type I du réseau utilisant les ratios (tendances) est de 9,09 % (72,73

%) dans l'échantillon d'estimation, de 14,81 % (66,67 %) dans celui de validation et de 12,24 % (69,39 %) dans les deux échantillons combinés. Pour leur part, les taux d'erreur de type II sont de 3,70 % (25,93 %), 10,53 % (26,32 %) et 6,52 % (26,09 %), respectivement.

Fanning et Cogger (1998) développent eux aussi un modèle de détection de la fraude dans les états financiers en utilisant les réseaux de neurones et des données publiques. Toutefois, cette fois-ci, ils en comparent la performance à trois autres modèles développés à partir des méthode de régression logistique (RL), d'analyse discriminante linéaire (ADL) et d'analyse discriminante quadratique (ADQ). Ils ont rassemblé un total de 102 cas de fraude à partir des ASR, des AAER et des *Litigation Releases*, eux aussi publiés par la SEC. Par ailleurs, les 102 firmes de l'échantillon de contrôle ont été choisies sur la base de l'industrie, de la fin de l'année fiscale et de la taille. Les variables prédictives utilisées par les auteurs, qui constituent une force de leur étude tant elles sont variées, se rapportent à la gouvernance, à la firme de vérification, aux problèmes d'agence, aux filiales, à la structure de capital, aux résultats opérationnels, au personnel, aux litiges, aux choix comptables, aux comptes et ratios des états financiers et à l'analyse de tendances. Pour développer leurs modèles, les auteurs utilisent les 21 variables significatives sur une base univariée, à l'exception du ratio comptes à recevoir sur actif total. Les variables sélectionnées par le réseau sont la proportion d'administrateurs externes sur le conseil d'administration (1), une variable binaire égale à 1 si la firme de vérification ne fait pas partie des six plus grandes (2), le taux de croissance géométrique des ventes au cours des trois dernières années (3), les ratios comptes à recevoir sur ventes (4), propriété, usine et équipement sur actifs totaux (5), dette sur avoir des actionnaires (6) et les tendances des comptes à recevoir (7) et de la marge brute (8). Les modèles de régression logistique et d'analyse discriminante contiennent cinq des huit variables du réseau, les variables 3, 4, 5 étant remplacées par les variables changement du chef de la direction financière au cours des trois dernières années, utilisation de la méthode dernier entré premier sorti pour la comptabilisation de l'inventaire et le ratio ventes sur actifs totaux. Les taux de bonne classification des quatre modèles sont similaires dans l'échantillon d'estimation. Cependant, seul le réseau de neurones a maintenu son niveau de performance dans l'échantillon de validation :

même si tous les modèles prédisent correctement une plus grande proportion des cas de fraude (ADL : 67 %; ADQ : 78 %; RL : 67 %) que le réseau de neurones (66 %), celui-ci (59 %) est le seul à prédire plus de 37 % des cas exempts de fraude correctement (ADL : 37 %; ADQ : 22 %; RL : 33 %). Par conséquent, il prédit correctement, en moyenne, 63 % des observations, alors que les autres modèles ont de la difficulté à faire mieux que 50 %. Il aurait été pertinent de comparer la performance du réseau de neurones à celle des trois autres modèles à l'aide de divers coûts de mauvaise classification et probabilités *a priori* pour déterminer avec certitude si sa performance est effectivement supérieure.

Tout comme les auteurs précédents, Feroz *et al.* (2000) vérifient l'habileté de modèles, dont un développé à partir des réseaux de neurones, à prédire quelles firmes ont manipulé leurs états financiers et seront poursuivies par la SEC. Les 42 cibles de leur échantillon ont été obtenues par le biais des AAER, tandis que les 90 entreprises de contrôle ont été sélectionnées sur la base de l'industrie et de la taille. Pour tester la sensibilité des modèles, les auteurs utilisent différentes combinaisons de firmes cibles et de contrôle dans leurs échantillons (10 % et 90 %, 20 % et 80 %, *etc.*) pour mesurer les effets de différentes hypothèses d'échantillonnage. Cette caractéristique constitue sans contredit une force de leur étude, car elle permet de se rapprocher des probabilités *a priori* qui existent dans la population corporative américaine. Ils utilisent des facteurs de risque financiers (rentabilité, sensibilité aux taux d'intérêt, transactions difficiles à vérifier et indicateurs de santé financière), liées au personnel (taux de rotation du chef de la direction et taux de rotation du chef de la direction financière) et à la vérification (taux de rotation de la firme de vérification) provenant tous de SAS N° 53. Leurs données s'étendent sur une période allant jusqu'à quatre ans avant l'année dans laquelle débute la fraude. Ils comparent la performance de leur réseau de neurones à celle d'un modèle de régression logistique. Leurs résultats dépendent grandement de l'hypothèse d'échantillonnage utilisée. En effet, le taux de bonne classification des cibles pour le réseau de neurones varie entre 63 % et 94 %, pour une précision moyenne de 81 % pour l'ensemble des 16 hypothèses. De son côté, le taux de bonne classification des cibles pour la régression logistique varie entre 52 % et 88 %, pour un taux moyen de 70 %. Ils notent qu'en général plus la proportion de cibles est faible dans les échantillons d'estimation et de validation, plus la précision des méthodes est élevée. Ils ont aussi

recours à un autre indicateur de performance : le taux d'erreurs global qui correspond à la somme des taux d'erreurs de type I et de type II. Le taux d'erreurs global du réseau varie entre 0,006 et 0,522 pour un taux d'erreur moyen de 0,15, tandis que celui de la régression logistique varie entre 0,03 et 0,42 pour un taux d'erreur moyen de 0,13. Enfin, les auteurs comparent les coûts espérés de mauvaise classification des deux méthodes en supposant des coûts relatifs de mauvaise classification allant de 1:1 à 50:1. Ils arrivent à la conclusion qu'aucune des deux méthodes ne domine strictement l'autre en terme de coûts espérés. Le réseau de neurones a un coût espéré un peu plus faible lorsqu'un même poids est accordé aux erreurs de types I et II. Cependant, lorsque des poids différents sont accordés aux deux types d'erreur, la régression logistique semble avoir un coût espéré plus faible.

2.3.3. - Systèmes experts

Ragothaman *et al.* (1995) sont parmi les rares auteurs ayant développé un système expert pour détecter la présence d'erreurs et d'irrégularités dans les états financiers. Leur échantillon est constitué de 34 entreprises dont les états financiers contiennent une fraude et de 58 firmes de contrôle choisies aléatoirement sur COMPUSTAT. Ce dernier point représente une faiblesse de leur étude, car les auteurs ne contrôlent pour aucune caractéristique des firmes. Les huit variables prédictives auxquelles ils ont recours, calculées à partir de données financières publiques, sont les ratios flux monétaires sur dette long terme, dépenses de capital sur actifs totaux, flux monétaire sur ventes, dépenses de recherche et développement sur ventes et dépenses de publicité sur ventes, la racine carré de la valeur marchande des actions ordinaires, le rendement de l'actif et la racine carré des ventes. Le système expert est construit en utilisant 34 règles induites par un logiciel, IXL, dont le fonctionnement est inspiré de la théorie des *fuzzy topologies* développée par Zadeh (1975, cité dans Ragothaman *et al.*, 1995) et Postin (1974, cité dans Ragothaman *et al.*, 1995). Les auteurs comparent la performance du système expert à celle d'un modèle d'analyse discriminante multiple. Dans l'échantillon d'estimation, 86,4 % des cas de fraude et 100,0 % des cas sans fraude sont classés correctement. Dans l'échantillon de validation, ces pourcentages sont de 83,3 % et 92,0 %, respectivement. En comparaison, dans l'échantillon d'estimation, le modèle d'analyse discriminante

multiple classe correctement 77,3 % des cas de fraude et 90,9 % des cas sans fraude. Dans l'échantillon de validation, ces pourcentages sont de 83,3 % et 80 %, respectivement. La performance du système expert surpasse donc celle de l'analyse discriminante multiple. Malheureusement, les auteurs n'effectuent aucune analyse de sensibilité. Cette conclusion ne peut donc être définitive.

Le dernier texte que nous présentons est d'un tout autre genre que les articles précédents. En effet, l'objectif de Kaminski et Wetzel (2004) est de déterminer, d'une part, si les ratios financiers sont d'une quelconque utilité pour prévoir la présence d'une fraude dans les états financiers et, d'autre part, si la prévision devrait être faite à partir d'un modèle linéaire ou non linéaire. Pour l'atteindre, ils adoptent une approche unique, car ils étudient, à l'aide de la théorie du chaos, la dynamique du système comptable et le comportement de ratios calculés à partir d'éléments des états financiers, à la recherche de preuves de non linéarité. Ils utilisent un échantillon composé de 30 paires d'entreprises, chacune comprenant une entreprise ayant commis une fraude et une entreprise de contrôle. Les firmes ayant commis une fraude ont été sélectionnées à partir des AAER N° 1 à 1148, couvrant la période allant de 1982 à 1999. Les critères de sélection des firmes de contrôle sont la taille, la période et l'industrie. Pour qu'une entreprise soit incluse dans l'échantillon, un minimum de sept années de données doivent être disponibles. Ils ont recours à dix ratios financiers calculés à partir d'éléments de bilans et d'états des résultats trimestriels appartenant à sept familles : rendement de l'investissement (R1 et R2); rotation du capital (R3 et R4); rotation de l'inventaire (R5 et R6); levier financier (R7); rotation des comptes à recevoir (R8 et R9); et liquidité à court terme (R10). Ils procèdent à une analyse longitudinale des ratios. Ils utilisent quelques-uns des outils reliés à la théorie du chaos (exposant de Hurst, exposant de Lyapunov, statistique BDS, *etc.*) pour exécuter des tests pour déterminer le comportement (i.e. aléatoire, périodique ou chaotique) des séries de données (*time-series*). Ces mesures ont été calculées pour chaque ratio de chaque entreprise. Pour chaque mesure, sa moyenne et l'erreur de celle-ci ont été calculées pour chaque groupe d'entreprises et pour des sous-groupes basés sur la taille de l'échantillon (petite versus grande) et sur la proportion de données frauduleuses (faible versus élevée). De manière générale, les auteurs trouvent que les ratios immobilisations sur actifs totaux (R4),

passifs totaux sur actifs totaux (R7) et actif à court terme sur passif à court terme (R10) sont de forts indicateurs du chaos. Le ratio comptes à recevoir sur inventaire (R9) proviendrait lui aussi d'une série de données chaotique, mais de façon moins consistante. Ces résultats indiquent que les ratios calculés à partir d'éléments du bilan sont le résultat d'un système dynamique chaotique non linéaire. Aucun ratio se semble avoir un comportement périodique. Ces résultats sont similaires pour les deux groupes d'entreprises. Les auteurs affirment que ces ratios ne peuvent donc pas être utilisés pour différencier un groupe d'entreprises de l'autre. L'utilisation de modèles linéaires utilisant de tels ratios est donc inapproprié, car ils ne captent pas la dynamique du système, résultant ainsi dans un faible pouvoir explicatif.

Comme nous pouvons le constater, la littérature portant directement sur la fraude comptable et, en particulier, sur le développement de modèle de détection, est quelque peu limitée. Néanmoins, plusieurs éléments sont à retenir des recherches précédentes. Ainsi, il appert que la fraude comptable est reliée, au moins d'un point de vue statistique, à diverses caractéristiques d'une entreprise : sa situation financière, son équipe de direction, *etc.* En effet, des variables mesurant des aspects tels que la composition de l'actif (comptes à recevoir sur actifs totaux, indice de qualité des actifs), la croissance (croissance des ventes), la productivité (ventes sur actifs totaux, indice d'adéquation entre les comptes à recevoir et les ventes), la rentabilité (différence entre les bénéfices et les flux monétaires opérationnels sur actifs totaux, indice de marge brute), les mécanismes de contrôle (présence d'un comité de vérification), le financement (besoin de financement externe) et le respect des clauses de convention de prêt (levier financier) expliquent, parmi tant d'autres, le recours à la fraude par les gestionnaires d'une entreprise.

Qui plus est, lorsque les relations entre la variable dépendante et les variables indépendantes sont correctement exploitées dans le cadre d'un modèle de classification, il est possible de différencier des entreprises ayant commis une fraude dans leurs états financiers d'entreprises de contrôle. Toutefois, la performance des modèles et, de surcroît, des méthodes à partir desquelles les modèles sont développés, est variable. Tout de même, l'analyse discriminante (Ragothaman *et al.*, 1995), la régression (Bell et

Carcello, 2000), les réseaux de neurones (Green et Choi, 1997) et les systèmes experts (Ragothaman et al., 1995) permettent tous dans au moins une étude d'atteindre des taux de bonne classification élevés pour les entreprises ayant commis une fraude comptable et les entreprises de contrôle dans les échantillons d'estimation et de validation. La fraude comptable est donc un phénomène qu'il est possible d'expliquer, mais aussi de prédire à partir de données publiques généralement contenues dans le rapport annuel d'une entreprise.

Les études ci-haut ne sont toutefois pas sans reproche. Ainsi, quelques-unes d'entre elles (DeFond et Jiambalvo, 1991; Feroz *et al.*, 2000; Grove et Cook, 2004; Kwon et Feroz, 1996; Lee *et al.*, 1999; Ragothaman *et al.*, 1995; Stice, 1991; Summers et Sweeney, 1998) ont recours à un ensemble d'entreprises reconnues coupables de fraude comprenant seulement une cinquantaine d'observations. Pour notre part, notre échantillon est composé de 190 entreprises dont 95 ont commis une fraude comptable. Nous serons donc en mesure de procéder à une validation de nos résultats hors-échantillon, contrairement à certaines recherches qui n'en font pas. Plus particulièrement, nous aurons recours à la validation croisée cinq fois. À notre connaissance, ce nombre de cas de fraude est parmi les plus élevés utilisés dans ce genre d'études. Seuls Dunn (2004), Fanning et Cogger (1998) et Persons (1995) ont eu recours à un échantillon d'entreprises ayant manipulé frauduleusement leurs états financiers d'une taille supérieure au nôtre. Les cas de fraude utilisés dans notre étude sont aussi plus récents que tous ceux utilisés précédemment. Ils sont obtenus à partir des AAER, publiés par la SEC, aux États-Unis, entre octobre 1999 et décembre 2004. Les AAER les plus récents utilisés dans la littérature datent de 1997 (Beasley, Carcello, Hermanson et Lapedes, 2000; Dunn, 2004).

Par ailleurs, l'ensemble de variables prédictives que nous utilisons dans le développement des modèles de détection est varié et, par le fait même, exclusif à notre étude. Ainsi, contrairement à certains auteurs, nous ne portons pas seulement notre attention sur un type de variables. Nous aurons effectivement recours à des variables financières, reliées à la gouvernance et aux motivations pour commettre une fraude. Parmi celles-ci, plusieurs n'ont jamais été combinées dans un même modèle de détection

de la fraude, alors que d'autres n'ont été utilisées qu'une fois pour développer un modèle.

Finalement, nous aurons recours à une méthode de classification qui n'a jamais été utilisée dans ce domaine : il s'agit du partitionnement récursif. La performance de cette méthode sera comparée à celle des techniques d'analyse discriminante linéaire, de régression logistique et de réseaux de neurones. Nous utiliserons deux mesures de performance : en plus des taux de bonne classification, nous calculerons aussi les coûts espérés de mauvaise classification de chaque modèle. Contrairement aux études précédentes qui ne procèdent pas toujours à une analyse de sensibilité, nous utiliserons une série de probabilités *a priori* de fraude, de coûts relatifs de mauvaise classification et de seuils de classification pour développer les modèles, lorsqu'il sera possible de le faire, et/ou calculer les mesures de performance.

CHAPITRE 3. - PRÉSENTATION DES DONNÉES

La présentation des données est divisée en quatre parties principales. Tout d'abord, nous décrirons le processus qui a mené à la construction de l'échantillon. Ensuite, nous traiterons des variables prédictives auxquelles nous aurons recours dans les modèles de classification. Par la suite, nous présenterons les statistiques descriptives des variables. Par le fait même, nous analyserons les résultats des tests d'égalité des moyennes, porterons un diagnostic sur la normalité des variables et discuterons des valeurs extrêmes. Enfin, nous procéderons à une analyse de la corrélation des variables.

3.1. - Méthode de construction de l'échantillon

À notre connaissance, il n'existe pas, à l'heure actuelle, de base de données portant sur la fraude comptable. Par conséquent, la première étape du développement des modèles de détection consiste à procéder à une collecte de données. Ainsi, dans cette section, il sera question des sources et de la méthode qui ont été utilisées pour sélectionner les entreprises qui ont commis une fraude dans leurs états financiers, les entreprises de contrôle et les données pour chacune d'entre elles. Une attention particulière sera portée sur la sélection des entreprises ayant commis une fraude comptable.

3.1.1. - Entreprises ayant commis une fraude comptable

La première étape de la cueillette des données consiste à trouver, évidemment, des entreprises ayant commis une fraude comptable. Malheureusement, un tel ensemble d'entreprises n'est disponible sur aucune base de données. Néanmoins, comme nous l'avons mentionné précédemment, il existe une source de cas de fraude couramment utilisée dans la littérature : cette source, ce sont les AAER. Nous y avons donc eu recours pour construire une liste d'entreprises ayant publié des états financiers mensongers. Il est à noter que l'utilisation des AAER restreint presque exclusivement les cas de fraude à ceux commis par des entreprises publiques américaines. Ce phénomène tend à être accentué par la disponibilité des données, beaucoup plus restreinte pour les entreprises étrangères, sauf, peut-être, pour les entreprises canadiennes.

Contrairement aux études précédentes ayant eu recours à cette source, nous utilisons des AAER publiés plus récemment. Par conséquent, les périodes sur lesquelles les fraudes ont eu lieu devraient elles aussi être plus récentes. Ces AAER, jamais utilisés, à notre avis, par le passé, correspondent à ceux publiés entre octobre 1999 et décembre 2004, inclusivement. Pour qu'une entreprise soit incluse dans notre échantillon, il doit en être question dans un de ces AAER ou dans un AAER relié à un de ceux-ci, que ce dernier ait été publié ou non durant cette période. Ce AAER peut faire référence, directement ou indirectement, dans ce dernier cas, par le biais d'un de ses employés, de son vérificateur externe ou de sa firme de vérification comptable, à une entreprise. L'entreprise doit être présumée avoir enfreint les lois des valeurs mobilières. Assumer la culpabilité des entreprises peut être problématique. En effet, nous avons constaté - Beasley *et al.* (1999) en font aussi mention - que les entreprises accusées de fraude n'admettent que rarement leur culpabilité. Par ailleurs, il se peut aussi que plaider coupable soit, pour une raison ou une autre, la stratégie la moins coûteuse. Fanning et Cogger (1998) affirment, toutefois, suite à l'analyse des AAER et des procédés de mise en accusation de la SEC, qu'il est raisonnable de supposer qu'une entreprise se retrouvant dans les AAER ait commis une fraude dans ses états financiers. Le type d'infractions particulier qui nous intéresse correspond à des violations de la section 10(b) et de la règle 10(b)-5 du *Securities Exchange Act* de 1934 et/ou de la section 17(a) du *Securities Act* de 1933. Beasley *et al.* (1999) expliquent que « [b]ecause these securities provisions generally require the intent to deceive, manipulate or defraud, they more specifically indicate alleged instances of financial statement fraud than do other provisions of the securities laws » (p. 11). Pour qu'une entreprise soit retenue, ces violations doivent affecter ses états financiers (bilan, états des résultats, *etc.*) annuels. Si les objections soulevées en ce qui concerne la représentativité des AAER sont réelles (voir la section trois), alors l'utilisation de cette source de cas de fraude constitue une limite de la présente étude.

Parmi les 972 AAER que nous avons consultés, en excluant ceux manquants, nous en avons éliminé 716 qui faisaient référence à d'autres types de violations, dont celles des principes de vérification généralement reconnus, étaient disponibles en deux copies, manquants ou encore incomplets. Ainsi, nous avons identifié, directement ou indirectement, environ 250 entreprises. Pour chacune d'entre elles, nous avons recueilli

les informations suivantes : le type de AAER (mise en accusation, entente avec la SEC, jugement de la cour, *etc.*), le nom de l'entreprise, la partie impliquée (entreprise, employé(s), *etc.*), les états financiers affectés par la fraude ou, le cas échéant, la période sur laquelle elle s'est déroulée, le type de violations et toute autre information susceptible d'être pertinente (par exemple, les informations concernant une première émission d'actions publique, les numéros des autres AAER reliés au cas de fraude, *etc.*). Soixante et onze entreprises ont dû être rejetées principalement parce que la fraude n'affectait que des données divulguées dans des états financiers trimestriels, un communiqué de presse et une conférence téléphonique; le premier exercice financier affecté est d'une durée inférieure à 12 mois; l'entreprise a modifié la fin de son année fiscale au cours des trois années précédant le début de la fraude; l'entreprise est un organisme sans but lucratif; l'entreprise a procédé à une première émission d'actions publique⁴. Étant donné que leurs états financiers ne sont pas directement comparables à ceux des autres entreprises, les entreprises de services financiers ont été exclues de l'analyse. Neuf entreprises ont été visées par cette mesure. Dans 75 cas, le manque ou l'absence de données a forcé la suppression des entreprises. Enfin, il a été impossible d'associer une entreprise de contrôle – les critères utilisés pour les sélectionner seront expliqués en détails dans le paragraphe suivant – à six entreprises qui ont donc été écartées. Ainsi, la partie de l'échantillon correspondant aux cas de fraude comprend 95 observations.

3.1.2. - Entreprises de contrôle

Une entreprise de contrôle a été associée à chacune des entreprises ayant commis une fraude comptable. Les entreprises de contrôle ont été sélectionnées sur la base de l'appartenance à l'industrie, de la taille et de la date de la fin de l'exercice financier. Plus précisément, pour chaque entreprise accusée de fraude, toutes les firmes ayant, au minimum, un même code SIC à deux chiffres à la fin de l'année fiscale dans laquelle la fraude a commencé ont été identifiées sur COMPUSTAT⁵. Pour le code SIC à quatre

⁴ Une raison souvent invoquée pour l'exclusion des entreprises qui ont procédé à une première émission d'actions publique est l'insuffisance des données disponibles. Voir, à ce sujet, Dechow *et al.* (1996).

⁵ L'entreprise de contrôle de sept firmes (AAER N° 1441, 1502, 1542, 1572, 1726, 1776 et 1781) a été trouvée à partir de Mergent Online. Le reste du processus de sélection est identique.

chiffres, l'entreprise qui permettait de minimiser la différence de taille, telle que mesurée par les actifs à la fin de l'exercice financier dans lequel la violation des normes de publication de l'information financière a débuté, a été retenue. La différence de taille maximale considérée est de 40,0 %. Si deux entreprises de contrôle identiques existaient, la période commune de l'année fiscale, mesurée en mois, a été maximisée. À une exception près, aucune période commune n'est inférieure à six mois⁶. Lorsque ce processus s'avère infructueux, il est refait, mais cette fois-ci pour le code SIC à trois chiffres et, lorsque nécessaire, pour le code SIC à deux chiffres. Si aucune entreprise n'est disponible, alors l'entreprise ayant commis une fraude est exclue de l'échantillon. (Comme il a été mentionné dans la section précédente, six cas de fraude ont dû être rejetés en raison de l'absence d'une entreprise de contrôle respectant ces critères). Pour qu'une entreprise de contrôle soit retenue, les mêmes données que pour les firmes de l'autre groupe doivent, évidemment, être disponibles. Nous discuterons des sources de données dans la prochaine section. Ainsi, l'échantillon final comprend un total de 190 entreprises : 95 entreprises ayant commis une fraude comptable (groupe 1) et 95 entreprises de contrôle (groupe 2). Le tableau 1 présente quelques statistiques descriptives sur chacun des groupes d'entreprises.

Tableau 1 : Statistiques descriptives sur les entreprises du groupe 1 (n=95) et du groupe 2 (n=95)

	Moyenne	Médiane	Écart type	Égalité des moyennes*
Actifs totaux				
Groupe 1	3 290,6	175,9	13 163,1	0,18
Groupe 2	2 960,9	174,8	11 905,4	(0,86)
Ventes nettes				
Groupe 1	2 182,0	152,5	6 755,5	0,08
Groupe 2	2 105,6	179,5	6 460,6	(0,94)
Bénéfice net				
Groupe 1	117,7	4,9	697,7	-0,82
Groupe 2	217,9	8,2	968,5	(0,41)

Légende : *Résultats des tests d'égalité des moyennes à deux queues effectués en utilisant un seuil de signification de 5 %. La statistique t et la valeur de p, entre parenthèses, sont présentées.

⁶ L'exercice financier d'une entreprise ayant commis une fraude comptable ne partage que cinq mois avec celui de l'entreprise de contrôle.

Au tableau précédent, nous constatons qu'il n'existe pas de différences statistiquement significatives entre les valeurs moyennes des actifs totaux, des ventes nettes et du bénéfice net entre les entreprises qui ont manipulé frauduleusement leurs résultats financiers et celles de contrôle. De son côté, le tableau 2 contient des caractéristiques supplémentaires sur les deux groupes d'entreprises et sur le processus de contrôle.

Tableau 2 : Autres caractéristiques sur les entreprises du groupe 1 (n=95) et du groupe 2 (n=95) et sur le processus de contrôle

Marché boursier						
	AMEX	NASDAQ	NYSE	Comptoir	Autre	Aucun
Groupe 1	4	45	24	20	0	2
Groupe 2	13	43	27	11	1	0
Répartition industrielle des entreprises du groupe 1 - Code SIC à deux chiffres						
1300	1		3400	3	5100	2
2000	2		3500	10	5600	2
2300	3		3600	11	5900	2
2600	1		3700	1	6700	2
2800	5		3800	9	7300	22
3100	1		4800	4	7900	1
3200	1		4900	4	8700	3
3300	1		5000	4		
Contrôle de l'industrie - Code SIC à N chiffres						
N=2	28					
N=3	19					
N=4	48					
Répartition annuelle des entreprises du groupe 1						
1994	3		1997	14	2000	23
1995	2		1998	23	2001	7
1996	13		1999	10		
Contrôle pour la période de temps - N mois communs						
N=5	1		N=8	6	N=11	10
N=6	4		N=9	19	N=12	38
N=7	6		N=10	11		

Nous remarquons qu'un peu moins d'entreprises faisant partie du groupe 1 sont cotées sur un marché boursier national (American Stock Exchange, NASDAQ National Stock Market (NASDAQ) et NYSE). Fait à noter, deux entreprises ayant commis une fraude ne sont cotées sur aucune place boursière. Par ailleurs, nous remarquons que près de la moitié des entreprises du groupe 1 font partie des industries dont le code SIC commence

par 35 (machinerie industrielle et commerciale et matériel informatique), 36 (électronique et autres équipement et composants électriques, excluant le matériel informatique) et 73 (services aux entreprises).

3.1.3. - Données

Pour chaque entreprise, un ensemble de données de gouvernance, de marché et comptables, ces dernières s'échelonnant sur une période de trois ans dont la fin correspond à celle du premier exercice financier dans lequel la fraude a débuté, qui n'ont pas été l'objet de corrections doit être disponible sur COMPUSTAT et/ou EDGAR. Une partie des données comptables a été obtenue par le biais de COMPUSTAT, l'autre étant collectée manuellement sur EDGAR à l'aide des états financiers annuels (rapport 10-K). Les données de marché, qui correspondent, en fait, au prix des actions ordinaires à la fin de l'exercice financier dans lequel la fraude a débuté, ont été recueillies en utilisant COMPUSTAT et Datastream. Enfin, les données de gouvernance ont été obtenues en presque totalité à partir de la lettre de convocation envoyée aux actionnaires dans le cadre de l'assemblée annuelle (*proxy statement*; rapport DEF 14A)⁷. Lorsqu'il s'avère impossible de calculer la valeur d'une variable prédictive en raison d'un manque de données, nous lui imputons la valeur médiane prise par cette variable dans un groupe donné. Nous avons imputé la médiane à un maximum de sept variables prédictives (25 %) pour chaque entreprise. Le tableau 3 contient plus d'informations à ce sujet.

Tableau 3 : Nombre de valeurs médianes imputées et nombre d'entreprises affectées dans le groupe 1 (n=95) et le groupe 2 (n=95)

	0	1	2	3	4	5	6	7
Groupe 1	75	6	0	1	1	7	4	1
Groupe 2	87	3	0	0	0	5	0	0

Dans la prochaine partie, nous décrivons en détails les variables qui serviront à développer les modèles de classification, ainsi que les raisons qui en motivent l'utilisation.

⁷ Pour certaines entreprises, généralement, les plus petites, ces informations étaient contenues dans le rapport annuel.

3.2. - Variables prédictives

Les variables prédictives auxquelles nous aurons recours pour développer les modèles de détection de la fraude comptable sont des variables financières, reliées à la gouvernance et aux motivations pour commettre une fraude. Pour chacune d'entre elles, nous allons en justifier l'utilisation et en déterminer la relation attendue avec la fraude⁸. Les définitions exactes des variables utilisées se trouvent en annexe (voir annexe 1).

Avant d'aborder les variables prédictives, mentionnons que la variable prédite que nous utilisons (FRAUD) est une variable binaire égale à un si l'entreprise a commis une fraude comptable. Autrement, elle est égale à zéro.

3.2.1. - Variables financières

Les variables financières constituent la principale classe de variables que nous utiliserons. Elles sont principalement composées de ratios et de mesures de tendance reliés à la composition de l'actif, à la croissance, à la liquidité, à la productivité, aux opportunités de croissance, à la qualité des bénéfices et à la rentabilité des entreprises.

3.2.1.1. - Composition de l'actif

La composition de l'actif est mesurée à l'aide des ratios comptes à recevoir sur actifs totaux (REC) et inventaires sur actifs totaux (INV) et de l'indice de qualité des actifs (QUAL).

De nombreux arguments motivent l'utilisation des ratios comptes à recevoir sur actifs totaux et inventaires sur actifs totaux. Tout d'abord, selon l'AICPA (1984, cité dans Stice, 1991), les éléments du bilan dont l'évaluation est en partie subjective présentent un risque d'erreur plus élevé dans leur estimation. De plus, les comptes qui représentent une grande partie des actifs totaux sont de manière générale plus exposés au risque de

⁸ Toutefois, il est à noter que les prévisions des signes attendus des coefficients des variables prédictives ne seront utiles que pour les modèles d'analyse discriminante linéaire et ceux de régression logistique. En effet, seules ces deux méthodes fournissent une quelconque information sur des coefficients.

fraude, car une faible erreur en pourcentage peut se révéler significative en termes absolus. Or, ces deux critères s'appliquent aux comptes à recevoir et aux inventaires, car ils constituent généralement une part significative des actifs à court terme des entreprises et, en plus, les créances irrécouvrables et les inventaires obsolètes sont l'objet d'estimation par les vérificateurs externes. Ensuite, Feroz *et al.* (1991) signalent que les sur-évaluations des comptes à recevoir et des inventaires sont responsables d'une portion importante des mesures réglementaires prises par la SEC, tandis que St. Pierre et Anderson (1984) mentionnent qu'il en est question dans un grand nombre de poursuites contre les vérificateurs externes. Enfin, de nombreux auteurs suggèrent que les gestionnaires peuvent manipuler les comptes à recevoir en enregistrant les ventes avant qu'elles ne soient complétées et les inventaires en ne faisant pas correspondre les ventes aux marchandises vendues, en les comptabilisant au plus faible du coût historique ou de la valeur au marché ou encore en sous-estimant le montant d'inventaires obsolètes (Fanning et Cogger, 1998; Feroz *et al.*, 1991; Persons, 1995; Stice, 1991). Un total de 22 % et de 14 %, respectivement, des fraudes commises par les entreprises incluses dans l'échantillon de Loebbecke, Eining et Willingham (1989, cité dans Summers et Sweeney, 1998) impliquaient les comptes à recevoir et les inventaires. Ainsi, plus les comptes à recevoir et les inventaires d'une entreprise sont importants en termes relatifs, plus la probabilité de fraude est élevée. Par conséquent, nous nous attendons à ce que les coefficients des variables REC et INV soient positifs.

Pour sa part, l'indice de qualité des actifs évalue la variation d'actifs totaux pour lesquels les bénéfices futurs attendus sont potentiellement moins certains. C'est une mesure agrégée du changement du risque de réalisation des actifs (*asset realization risk*) suggéré par Siegel (1991, cité dans Beneish, 1997). Une augmentation du risque de réalisation des actifs, reflété par un indice supérieur à un, indique qu'une entreprise a davantage tendance à capitaliser et, ainsi, à reporter ses coûts. Ainsi, plus l'indice de qualité des actifs est élevé, plus la probabilité de fraude est élevée. Par conséquent, nous nous attendons à ce que le coefficient de QUAL soit positif.

3.2.1.2. - Croissance

La croissance des ventes au cours de l'exercice financier dans lequel la fraude a débuté (CROIS1) et celle au cours de cet exercice financier et du précédent (CROIS2) sont utilisées pour mesurer l'expansion des activités des entreprises.

L'utilisation d'une variable mesurant la croissance des entreprises peut être expliquée de diverses façons. Une croissance des ventes élevée n'implique pas nécessairement que les gestionnaires de l'entreprise ont commis une fraude pour l'atteindre. Néanmoins, les gestionnaires qui font face à un ralentissement des activités de leur entreprise peuvent avoir des incitations pour commettre une fraude afin d'éviter une baisse du prix de l'action qui, éventuellement, pourrait leur causer une diminution de salaire, miner leur réputation et peut-être même leur coûter leur emploi. À cet égard, Fridson (1991, cité dans Beneish, 1997) mentionne que « *almost invariably, companies try to dispel the impression that their growth is decelerating, since that perception can be so costly to them* » (p. 7-8). Ceci est tout particulièrement vrai pour les entreprises à forte croissance qui ont, entre autres, d'importants besoins de capital qui poussent leurs gestionnaires à atteindre les cibles de rentabilité fixées par le marché (NCFFR, 1987; ACFE, 1993, cité dans Beneish, 1999). De plus, les mécanismes de contrôle interne et de publication de l'information auraient tendance à évoluer moins rapidement que les activités des entreprises en période de forte croissance, les rendant ainsi inadéquats (NCFFR, 1987). Or, l'efficacité de ces mécanismes affecte la probabilité que des erreurs significatives soient contenues dans les états financiers (AICPA, 1984, cité dans Stice, 1991). Hall et Renner (1988, cité dans Stice, 1991) ont aussi noté que les firmes de vérification comptable des entreprises à forte croissance sont souvent impliquées dans une poursuite lorsque les mécanismes de surveillance de leurs clients ne sont pas conçus de façon à supporter une telle croissance. Loebbecke *et al.* (1989, cité dans Summers et Sweeney, 1998) ont trouvé que près du tiers des entreprises ayant perpétré une fraude dans leur échantillon étaient des entreprises à forte croissance. Ainsi, plus la croissance des ventes est élevée, plus la probabilité de fraude est élevée. Par conséquent, nous nous attendons à ce que les coefficients des variables CROIS1 et CROIS2 soient positifs.

3.2.1.3. - Liquidité

Le ratio de liquidité générale (LIQ) et le fonds de roulement (ROUL) évaluent la capacité des entreprises à poursuivre sans difficulté leurs activités à court terme.

Une faible liquidité pourrait inciter les gestionnaires à commettre une fraude pour masquer les difficultés auxquelles fait face l'entreprise. D'ailleurs, les résultats obtenus par Kreutzfeldt et Wallace (1986, cité dans Persons, 1995) supportent cet argument, car les états financiers des entreprises ayant des problèmes de liquidité dans leur échantillon contenaient significativement plus d'erreurs que ceux des autres entreprises. Ainsi, moins une entreprise a de fonds disponibles sous la main, plus la probabilité de fraude est élevée. Par conséquent, nous nous attendons à ce que les coefficients de LIQ et de ROUL soient négatifs.

3.2.1.4. - Opportunités de croissance

Les opportunités de croissance d'une entreprise sont mesurées à l'aide d'indice de marge brute (BRUT) et des ratios d'évaluation cours-bénéfice (CB), de la valeur au marché (VAL), cours sur ventes (*price to sale ratio*) (PV) et cours sur flux monétaires (*price to cash flow ratio*) (PFM).

Lev et Thiagarajan (1993, cité dans Beneish, 1997, 1999) affirment que la marge brute est reliée aux opportunités de croissance d'une entreprise⁹. Une détérioration de celle-ci, reflétée par un indice supérieur à un, signale une dégradation de la situation financière. Par conséquent, à l'aide d'un raisonnement analogue à celui de Beneish (1999) voulant que les entreprises qui voient leur horizon s'assombrir aient une plus forte probabilité de s'engager dans une fraude, nous nous attendons à ce que le coefficient de BRUT soit positif.

⁹ Lev et Thiagarajan (1993, cité dans Beneish, 1997, 1999) mentionnent aussi que l'indice de marge brute, qui est une mesure de tendance, est un des nombreux indicateurs utilisés par les analystes financiers pour estimer la qualité des bénéfices. Nous aurions donc pu inclure cette variable avec celles mesurant la qualité des bénéfices.

Nous aurons aussi recours à quatre ratios d'évaluation qui permettront d'intégrer l'opinion des participants aux marchés financiers sur la situation financière des entreprises et, plus particulièrement, sur leurs opportunités de croissance. Comme pour la marge brute, une diminution d'un ratio d'évaluation indique que les perspectives d'avenir d'une entreprise sont moins reluisantes. Par conséquent, nous nous attendons à ce que les coefficients des ratios CB, VAL, PV et PFM soient négatifs.

3.2.1.5. - Productivité

La productivité est mesurée à l'aide de la rotation du capital (ROT) et de l'indice d'adéquation entre les comptes à recevoir et les ventes (ADEQ).

La rotation du capital représente à la fois la capacité des actifs et l'habileté des gestionnaires d'une entreprise à générer des ventes. Persons (1995) stipule que les gestionnaires moins doués ont plus de difficultés, surtout lorsque le marché est compétitif, à utiliser efficacement les actifs de leur entreprise et ont de plus grandes motivations pour recourir à la fraude. Ainsi, moins une entreprise est productive, plus la probabilité de fraude est élevée. Par conséquent, nous nous attendons à ce que le coefficient de la variable ROT soit négatif.

Pour sa part, l'indice d'adéquation entre les comptes à recevoir et les ventes cherche à estimer le degré auquel les comptes à recevoir et les ventes évoluent parallèlement d'une année à l'autre (Beneish, 1997, 1999). Une plus forte augmentation des comptes à recevoir par rapport aux ventes, reflété par un indice supérieur à un, accroît la probabilité que les comptes à recevoir, les ventes et les bénéfices soient sur-évalués, bien qu'une telle sur-évaluation ait pu être causée par une politique de crédit laxiste visant à stimuler les ventes. Par ailleurs, les arguments utilisés pour justifier l'utilisation du ratio comptes à recevoir sur actifs totaux s'applique ici aussi. Ainsi, plus l'indice d'adéquation entre les comptes à recevoir et les ventes est élevé, plus la probabilité de fraude est élevée. Par conséquent, nous nous attendons à ce que le coefficient de ADEQ soit positif.

3.2.1.6. - *Qualité des bénéfices*

Deux variables sont utilisées pour mesurer la qualité des bénéfices d'une entreprise : les ratios différence entre les bénéfices et les flux monétaires liés aux opérations sur actifs totaux (DIFF) et réserves totales sur actifs totaux (RES). Comme il est possible de le voir en annexe, DIFF et RES sont de construction similaire.

Utilisé par Lee, Ingram et Howard (1999), le ratio différence entre les bénéfices et les flux monétaires liés aux opérations sur actifs totaux mesure, d'une façon comparable à celle des indices d'adéquation précédents, la concordance entre les bénéfices et les flux monétaires liés aux opérations. Ils expliquent que lorsqu'une fraude est découverte et que ses effets initiaux sont inversés, il y a réduction des bénéfices, sans toutefois que les flux monétaires liés aux opérations soient diminués. Ainsi, les bénéfices des entreprises ayant commis une fraude devraient être supérieurs à leurs flux monétaires liés aux opérations. Dans le cas des entreprises de contrôle, il devrait exister une différence entre ces deux éléments, bien que celle-ci ne soit pas toujours positive. Ainsi, les auteurs font remarquer que cette variable n'indique pas de manière non équivoque la présence de fraude, tout en estimant, que pour les entreprises ayant commis une fraude, les différences entre les bénéfices et les flux monétaires liés aux opérations seront substantiellement plus grandes et positives que celles des entreprises de contrôle, étant donné que les effets d'une fraude systématique sont permanents aussi longtemps qu'elle dure. Ainsi, plus la différence entre les bénéfices et les flux monétaires liés aux opérations est élevée en termes relatifs, plus la probabilité de fraude est élevée. Par conséquent, nous nous attendons à ce que le coefficient de DIFF soit positif.

Le ratio réserves totales sur actifs totaux permet lui aussi d'estimer la proportion des bénéfices qui est tangible (*cash based*) et l'importance des choix de comptabilisation discrétionnaires effectués par les gestionnaires des entreprises (Beneish, 1997, 1999). Plus le ratio est élevé, moins les bénéfices réels sont importants et plus la probabilité de fraude est élevée. Par conséquent, nous nous attendons à ce que le coefficient du ratio RES soit positif.

3.2.1.7. - Rentabilité

Le rendement de l'actif (RA), le rendement des fonds propres (RFP) et le rendement comptable de l'action (RCA) nous permettront d'évaluer le niveau de rentabilité des entreprises.

Deux arguments, qui sont complémentaires, militent en faveur de l'utilisation de ratios de rentabilité dans le développement des modèles de détection. D'une part, la stabilité d'emploi des gestionnaires, qui est maximisée lorsque sont générés des bénéfices supérieurs ou égaux d'une année à l'autre, leur permet, entre autres moyens, de maximiser leur utilité, objectif pouvant être en contradiction avec celui de rentabilité des entreprises (Gordon, 1964, cité dans Summers et Sweeney, 1998). Ainsi, les gestionnaires incapables d'améliorer ou, au minimum, de maintenir les niveaux de rentabilité passés auraient des incitations pour commettre une fraude. D'autre part, une piètre rentabilité, en valeur absolue, au même titre qu'une faible liquidité, pourrait inciter les gestionnaires à manipuler les bénéfices pour redorer la situation financière de leur entreprise. À ce chapitre, Kreutzfeldt et Wallace (1986, cité dans Persons, 1995) ont obtenu, comme pour la liquidité, des résultats concluants. En effet, on retrouve significativement plus d'erreurs dans les états financiers des entreprises éprouvant des problèmes de rentabilité que dans ceux des autres entreprises. Par ailleurs, 35 % des entreprises ayant commis une fraude dans l'échantillon de Loebbecke et al. (1989, cité dans Summers et Sweeney, 1998) avaient, selon eux, une rentabilité inconciliable avec celle des autres membres de leur industrie. Ainsi, moins une entreprise est rentable, plus la probabilité de fraude est élevée. Par conséquent, nous nous attendons à ce que les coefficients des variables RA, RFP et RCA soient négatifs.

3.2.2. - Gouvernance

Les variables liées à la gouvernance corporative mesurent divers aspects de l'équipe de direction, du conseil d'administration, du comité de vérification et de la firme de vérification des entreprises.

3.2.2.1. - Équipe de direction

Nous nous intéressons à la caractéristique suivante de l'équipe de direction : le président et/ou le chef de la direction de l'entreprise est-il aussi son ou l'un de ses fondateurs? FOND est une variable binaire égale à un si le président et/ou le chef de la direction de l'entreprise est, à la clôture de l'exercice financier dans lequel la fraude a débuté, son ou l'un de ses fondateurs. Autrement, elle est égale à zéro.

L'utilisation de cette variable est motivée par Jensen (1993, cité dans Dechow *et al.*, 1996), lequel soutient que le président d'une entreprise, lorsqu'il est le ou l'un de ses fondateurs, exerce généralement un plus grand contrôle sur ses activités quotidiennes. De plus, il aurait tendance à rendre moins de comptes au conseil d'administration. Ainsi, sa mainmise sur les opérations de l'entreprise, jumelée à une plus grande liberté d'action, pourraient faciliter le recours à la manipulation des états financiers lorsque, par exemple, la situation financière de « son » entreprise se dégrade. Ainsi, lorsque le président d'une entreprise est son ou l'un de ses fondateurs, la probabilité de fraude est plus élevée. Par conséquent, nous nous attendons à ce que le coefficient de FOND soit positif.

3.2.2.2. - Conseil d'administration

Les variables liées au conseil d'administration sont au nombre de deux : elles mesurent la taille du conseil d'administration (CA) et le cumul des postes de président et/ou de chef de la direction et de président du conseil par la même personne (PRES). PRES est une variable binaire égale à un si le président et/ou le chef de la direction de l'entreprise occupe aussi le poste de président du conseil. Autrement, elle est égale à zéro. Ces deux variables sont évaluées à la fin de l'année fiscale dans laquelle la fraude a débuté.

Il n'y a pas de consensus dans la littérature sur le lien qui existe entre la taille du conseil d'administration et son efficacité. Chaganti, Mahajan et Sharma (1985, cité dans Beasley, 1996) croient que les conseils d'administration de grande taille sont plus utiles que ceux de petite taille, car leurs membres, de par la diversité de leur formation, de leur

expérience professionnelle, *etc.*, sont plus à même de fournir des services mieux adaptés à la situation de l'entreprise. Ils ont confirmé cette intuition en établissant que les entreprises composant leur échantillon qui se sont mises sous la protection de la loi de la faillite avaient moins d'administrateurs siégeant sur leur conseil d'administration que les autres entreprises. Jensen (1993, cité dans Beasley, 1996) pense plutôt qu'il est plus aisé au président de l'entreprise de contrôler un conseil d'administration de grande taille, alors qu'un conseil d'administration de petite taille peut, lui, plus facilement exercer une surveillance accrue. Bacon (1993, cité dans Dunn, 2004) supporte ce point de vue, car il pense qu'il peut être trop difficile de gérer un conseil d'administration de grande taille pour en amener les membres à prendre des décisions appropriées. Les résultats des études de Beasley (1996) et Dechow *et al.* (1996) supportent ces opinions, car ils révèlent que les entreprises ayant commis une fraude ont tendance à avoir un conseil d'administration de grande taille. Gautschi et Jones (1987, cité dans Fanning et Cogger, 1998) ont quant à eux trouvé une relation positive entre les comportement corporatifs illégaux et la taille du conseil d'administration. Enfin, contrairement aux auteurs précédents, Vance (1983, cité dans Fanning et Cogger, 1998) n'a pu établir de lien statistique entre la taille du conseil d'administration et la performance économique. Bien que les avis soient partagés, nous nous attendons à ce que le coefficient de CA soit positif.

Par ailleurs, les tâches qui incombent au président du conseil sont nombreuses : il veille au bon déroulement des rencontres du conseil, se charge des processus d'embauche, de renvoie et d'évaluation du président, détermine les assignations aux différents comités, *etc.* (Beasley, 1996; Fanning et Cogger, 1998). Ainsi, en remplissant les fonctions de président du conseil, le président pourrait avoir de la difficulté à ne pas considérer ses propres intérêts. En d'autres mots, lorsqu'il occupe aussi le poste de président du conseil, le président se retrouve potentiellement en conflit d'intérêts. L'existence d'une telle « dualité » ferait en sorte que le conseil d'administration remplit moins bien ses fonction de surveillance auprès des gestionnaires (Beasley, 1996; Fanning et Cogger, 1998). Dans de telles circonstances, il pourrait donc être plus facile de commettre une fraude. Par conséquent, nous nous attendons à ce que le coefficient de PRES soit positif.

3.2.2.3. - *Comité de vérification*

Nous construisons une variable binaire égale à un si une entreprise possède, à la date où se termine son exercice financier, un comité de vérification (COM). Autrement, elle est égale à zéro.

Les différents comités du conseil d'administration jouent un rôle crucial pour assurer la bonne marche de l'entreprise. Parmi ceux-ci, le plus important est le comité de vérification pour prévenir la fraude comptable (Beasley, 1996; NCFR, 1987). D'ailleurs, par le passé, une relation entre le comité de vérification, les mécanismes de gouvernance et la fraude a été établie par de nombreux auteurs (Beasley, 1996; Dechow *et al.*, 1996). DeFond et Jiambalvo (1991) affirment que les mécanismes de contrôle, dont le comité de vérification est l'un des plus importants, en améliorant les probabilités de détection, permettent de réduire l'éventualité que des erreurs, intentionnelles ou non, soient incorporées aux états financiers. Plus particulièrement, ils mentionnent que :

The increased probability of detection increases the expected costs of misrepresentation since detected intentional errors reduce a manager's value in the market for managerial labor. Thus, controls reduce the tendency to deliberately overstate earnings. (p. 646).

En accord avec ce raisonnement, ils ont trouvé que les entreprises dont les états financiers contiennent des erreurs sont moins susceptibles d'avoir mis sur pied un comité de vérification. McMullen (1996, cité dans Fanning et Cogger, 1998) est arrivé à une conclusion similaire. Par ailleurs, Beasley (1996) a trouvé qu'à peine 41 % des entreprises ayant commis une fraude dans son échantillon avaient un comité de vérification. Par conséquent, nous nous attendons à ce que le coefficient de la variable binaire COM soit négatif.

3.2.2.4. - *Firme de vérification*

L'aspect des firmes de vérification auquel nous nous intéressons est leur taille qui pourrait, semble-t-il, influencer la probabilité qu'une fraude soit menée à terme. VERIF est une variable binaire égale à un si la firme de vérification qui a examiné les états

financiers dans lesquels la fraude a débuté est de grande taille (*Big Four Auditor*¹⁰). Autrement, elle est égale à zéro.

Le processus annuel de vérification est un mécanisme de contrôle fondamental : il permet d'attester l'exactitude des états financiers d'une entreprise. Ainsi, les vérificateurs ont la possibilité de détecter une manipulation des bénéfices avant que les états financiers soient disséminés au public. Deux caractéristiques d'une firme de vérification comptable influenceraient cette possibilité : son indépendance et la qualité du service qu'elle offre (Dechow *et al.*, 1996; Stice, 1991). Selon DeAngelo 1981, cité dans Dechow *et al.*, 1996), l'indépendance d'une firme de vérification est positivement corrélée à sa taille. De plus, les grandes firmes de vérification effectueraient des vérifications de meilleure qualité (Palmrose, 1988, cité dans Dechow *et al.*, 1996). Plusieurs raisons l'expliquent : un intérêt économique accru (DeFond et Jiambalvo, 1991); de plus grandes ressources humaines, techniques, *etc.* (Stice, 1991); un important investissement dans leur réputation, qui constitue l'un de leurs principaux actifs (Beatty, 1989, cité dans Fanning et Cogger, 1998) et sur laquelle les clients se basent pour déterminer la qualité de la vérification effectuée (Simunic et Stein, 1986, cité dans Stice, 1991); enfin, une plus grande expertise industrielle (Benston, 1980, cité dans Fanning et Cogger, 1998). Ainsi, si une entreprise fait affaire avec un grand cabinet comptable, la probabilité de fraude est plus faible. Par conséquent, nous nous attendons à ce que le coefficient de VERIF soit négatif.

3.2.3. - Motivations pour commettre une fraude

Les variables liées aux motivations pour commettre une fraude que nous utilisons ont trait au besoin de financement externe et au respect des clauses de convention de prêt.

¹⁰ Les grands cabinets comptables incluent aujourd'hui Deloitte & Touche, Ernst & Young, KPMG et PricewaterhouseCoopers. Nous avons considéré ces quatre firmes de vérification, leurs prédécesseurs et toute autre firme ayant déjà fait partie d'un tel classement (par exemple, Arthur Andersen), qui n'a pas toujours comporté quatre représentants, comme un grand cabinet comptable.

3.2.3.1. - Besoin de financement externe

Nous avons recours à deux variables pour estimer le besoin de financement externe d'une entreprise (FIN1 et FIN2). En fait, ces variables, qui mesurent directement la quantité de fonds internes disponibles à une entreprise, ne sont différenciées que par la mesure des dépenses de capital qui est utilisée. Ce sont deux variables binaires égales à un si une entreprise a besoin de financement au cours des deux prochaines années. Autrement, elles sont égales à zéro.

La logique derrière l'utilisation de ces variables est la suivante : une entreprise qui aura besoin de nouveaux fonds au cours des deux prochaines années commencera dès aujourd'hui à prendre les moyens requis pour s'assurer leur obtention (Dechow *et al.*, 1996). Cet argument suppose implicitement que la situation financière actuelle de l'entreprise ne lui permettra pas, dans deux ans, d'obtenir un prêt bancaire ou de vendre des titres sur les marchés financiers. Ainsi, plus une entreprise a besoin de capitaux supplémentaires, plus la probabilité de fraude est élevée. Par conséquent, nous nous attendons à ce que les coefficients des variables FIN1 et FIN2 soient positifs.

3.2.3.2. - Respect des clauses de convention de prêt

Sans accès direct aux conventions de prêt auxquelles les entreprises sont soumises, il est difficile de déterminer si elles en violent les clauses. Néanmoins, une variable est fréquemment utilisée dans la littérature pour estimer la proximité de la violation des clauses de convention de prêt : cette variable, c'est le levier financier (LEV) (Dechow *et al.*, 1996).

Plus son ratio de levier financier est élevé, plus une entreprise est susceptible de ne pas respecter les termes de son contrat d'emprunt. DeFond et Jambalvo (1991) motivent l'utilisation de cette variable en affirmant, d'une part, que lorsqu'une entreprise viole les clauses de ses conventions de prêt, il s'ensuit habituellement une coûteuse renégociation et, d'autre part, qu'une entreprise qui n'est pas présentement financée par prêt, mais qui compte l'être dans le futur a intérêt à maintenir une situation financière saine. Ainsi, les

gestionnaires d'une entreprise qui se retrouve dans l'une de ces deux situations a de plus fortes incitations pour recourir à la fraude. À cet effet, Bowen, Noreen et Lacey (1981, cité dans DeFond et Jiambalvo, 1991) et Christie (1990, cité dans Persons, 1995) ont établi qu'il existait une relation positive entre le levier financier et l'utilisation de méthodes de comptabilisation agressives (*income-increasing accounting methods*). Il est à noter que le levier financier n'est pas une mesure parfaite de la proximité de la violation des clauses de conventions de prêts : c'en est plutôt une mesure approximative, car le ratio de levier financier optimal est fonction, de manière générale, des caractéristiques de l'entreprise (Smith et Watts, 1992; cité dans Dechow *et al.*, 1996). De plus, un levier financier élevé est relié à une plus forte demande de financement par actions (Opler et Titman, 1994, cité dans Dechow *et al.*, 1996). Le levier financier peut donc mesurer le besoin de financement externe et expliquer le recours à la fraude même lorsque les termes du contrat d'emprunt ne sont pas stricts (Dechow *et al.*, 1996). D'ailleurs, les résultats trouvés par Persons (1995) indiquent qu'un niveau d'endettement élevé n'est pas nécessairement associé à la fraude. Par conséquent, nous nous attendons à ce que le coefficient de LEV soit positif.

3.2.4. - Autre

Nous utilisons une dernière variable reliée au marché boursier sur lequel une entreprise est cotée (BOUR). Il s'agit d'une variable binaire égale à un si l'entreprise est cotée, à la clôture de son année fiscale, sur le NASDAQ. Autrement, elle est égale à zéro. Nous avons choisi le NASDAQ, car il représente le marché boursier le plus fréquent dans chaque groupe. Le fait de ne pas avoir considéré le NYSE, en plus du NASDAQ, implique que 24 entreprises ayant commis une fraude comptable et 27 entreprises de contrôle se sont vues attribuer une valeur égale à zéro pour la variable BOUR.

Les résultats empiriques indiquent que les entreprises ayant commis une fraude comptable sont moins souvent cotées sur un marché boursier national (Beasley *et al.*, 1999, 2000). Ainsi, en raison des nombreux contrôles et exigences de gouvernance, de capital, *etc.*, les entreprises cotées sur le NASDAQ ou, à cet effet, tout autre marché

boursier national sont moins susceptibles de commettre une fraude. Par conséquent, nous nous attendons à ce que le coefficient de la variable BOUR soit négatif.

3.3. - Statistiques descriptives

L'annexe 2 contient des statistiques descriptives pour chacune des variables des deux groupes. L'indice de normalité est égal à un lorsque la distribution d'une variable est normale. Pour que la distribution d'une variable soit qualifiée de normale, sa kurtose doit être comprise dans l'intervalle $[-1, 1]$ et son coefficient d'asymétrie, dans l'intervalle $[-0,5, 0,5]$. Autrement, l'indice de normalité est égal à zéro. Par ailleurs, la colonne Valeurs extrêmes fait référence, comme son nom l'indique, au nombre de valeurs extrêmes contenues dans les données pour chaque variable pour chacun des deux groupes d'entreprises. Nous expliquerons plus bas le traitement que nous avons réservé à ces données. Toutefois, mentionnons avant d'aller plus loin que les mesures de la moyenne, de l'écart type, *etc.* présentées à l'annexe 2 correspondent aux mesures calculées après contrôle des valeurs extrêmes. Enfin, la statistique t fait référence aux résultats des tests d'égalité des moyennes à deux queues que nous avons effectués. Pour réaliser les tests, nous avons utilisé un seuil de signification de 5 %. La probabilité que la statistique t soit inférieure à la valeur critique de t est indiquée entre parenthèses.

Parmi les trois variables financières reliées à la composition de l'actif, nous constatons que la moyenne d'aucune d'entre elles n'est statistiquement différente, à un niveau de confiance de 95 %, d'un groupe à l'autre. La moyenne de la variable QUAL l'est, toutefois, à un niveau de confiance de 90 %. L'indice de qualité des actifs moyen des entreprises ayant commis une fraude comptable (4,29) est plus élevé que celui des entreprises de contrôle (1,34). Contrairement à l'indice de qualité des actifs moyen, l'indice médian est similaire entre les deux groupes. Ainsi, en utilisant plutôt ce dernier, bien qu'il soit supérieur à un pour les deux groupes, les entreprises du groupe 1 ne semble pas avoir davantage tendance à capitaliser et, ainsi, à reporter leurs coûts que celles du groupe 2. Par ailleurs, nous remarquons que la variable REC de chacun des groupes suit une distribution normale. En fait, le ratio comptes à recevoir sur actifs totaux, en plus du ratio fonds de roulement sur actifs totaux (ROUL) des entreprises

ayant commis une fraude financière, sont les deux seules variables à être distribuées normalement selon les critères que nous avons utilisés.

La croissance des ventes moyenne des entreprises ayant eu recours à une comptabilité mensongère est quant à elle significativement plus grande que celle des entreprises de contrôle, peu importe la période pour laquelle elle est calculée. La moyenne de la variable CROIS1 pour les entreprises du groupe 1 se situe à 101 % (1,01), alors que pour les entreprises du groupe 2 elle ne s'élève qu'à 8 % (0,08). Pour la variable CROIS2, les moyennes correspondent à 74 % (0,74) et 11 % (0,11), respectivement. Les deux mesures de la croissance des ventes médiane sont aussi substantiellement plus élevées pour les entreprises du groupe 1 que pour celles du groupe 2. Ces résultats supportent l'affirmation voulant que plus la croissance des ventes d'une entreprise est élevée, plus la probabilité qu'elle commette une fraude est élevée.

La moyenne des ratios de liquidité LIQ et ROUL n'est pas statistiquement différente d'un groupe à l'autre. Il en est de même pour les ratios mesurant le productivité des firmes et leurs opportunités de croissance. Cependant, parmi ces derniers, deux ont une moyenne statistiquement différente d'un groupe à l'autre à un niveau de confiance de 90 %. Il s'agit des ratios VAL et PFM : dans les deux cas, le ratio moyen des entreprises qui ont perpétré une fraude comptable est supérieur à celui des entreprises de contrôle. Nous arrivons à la même conclusion en utilisant la valeur médiane de ces deux ratios. Ces résultats sont donc opposés à ceux que nous attendions.

Par ailleurs, les variables DIFF et RES ont toutes deux une moyenne différente, d'un point de vue statistique, entre les deux groupes. Cependant, contrairement à ce que nous attendions, la moyenne de DIFF est négative pour les deux groupes : elle est égale à $-0,61$ pour les entreprises ayant commis une fraude dans leurs états financiers et à $-0,07$ pour les entreprises de contrôle. La médiane de DIFF elle est aussi négative pour les deux groupes, quoique moins que la moyenne ($-0,19$ et $-0,04$, respectivement). De son côté, RES est plus élevée pour les entreprises ayant commis une fraude (0,01) que pour les autres ($-0,09$) (la différence est statistiquement significative à un niveau de confiance de 95 %). Comme prévu, la moyenne et la médiane de ce ratio pour les entreprises du

groupe 1 sont supérieures à celles du ratio pour les entreprises du groupe 2, signifiant, entre autres choses, que les bénéfices des entreprises ayant commis une fraude comptable ont tendance à être moins tangibles que ceux des entreprises de contrôle. Ainsi, même si la variable DIFF n'indique pas que les bénéfices des entreprises du groupe 1 ne concordent pas à leurs flux monétaires liés aux opérations, la variable RES, de son côté, laisse entendre le contraire. Étant moins tangibles, chaque dollar de bénéfices est donc associé à des flux monétaires plus faibles pour les entreprises ayant commis une fraude comptable.

De toutes les variables de gouvernance, la variable binaire reliée au fondateur de l'entreprise (FOND) est la seule qui a une moyenne statistiquement différente d'un groupe à un autre. Comme nous pouvions nous y attendre, un plus grand nombre de présidents et/ou de chefs de la direction sont aussi le ou l'un des fondateurs de l'entreprise pour laquelle ils travaillent dans le groupe 1 (0,35) que dans le groupe 2 (0,21). Toutefois, ce raisonnement n'est valable qu'en utilisant la valeur moyenne de la variable, sa valeur médiane étant nulle pour les deux catégories d'entreprises.

Les deux variables mesurant les besoins de financement externes des entreprises sont, en moyenne, statistiquement différentes entre les deux groupes d'entreprises. Dans les deux cas, comme nous nous y attendions, la valeur de la variable des entreprises ayant publié des états financiers erronés est supérieure à celle des entreprises de contrôle. Par exemple, la valeur moyenne de FIN1, variable dans laquelle nous avons recours aux dépenses de capital ayant eu lieu au cours de l'exercice financier dans lequel la fraude a eu lieu, est égale à 0,17 pour les entreprises ayant publié des états financiers trompeurs, alors qu'elle est égale à 0,06 pour les entreprises de l'autre groupe.

Il ne semble pas non plus qu'un plus faible nombre d'entreprises ayant commis une fraude dans leurs états financiers soit coté sur le NASDAQ. Au contraire, la valeur moyenne de cette variable pour les entreprises du groupe 1 (0,47) est supérieure à celle des entreprises du groupe 2 (0,45). Cependant, la différence n'est pas statistiquement significative aux niveaux de confiance habituels.

Enfin, dans la dernière colonne du tableau à l'annexe 2, nous remarquons que le nombre de valeurs extrêmes est relativement faible. Seulement six variables contenaient un nombre de données extrêmes supérieur ou égal à trois. Il s'agit, pour les entreprises ayant commis une fraude comptable, des variables CROIS2, BRUT, PFM et ROT et, pour les entreprises de contrôle, des variables LIQ et RCA. Toute valeur extrême a été ramenée à une borne se situant à plus ou moins trois écarts types de la moyenne, selon le cas.

3.4. - Analyse de corrélation

La présente section porte sur l'étude de la corrélation entre les diverses variables prédictives dans les groupes 1 et 2. Les matrices de corrélation associées à chacun de ces deux groupes se trouvent à l'annexe 3. Nous y avons aussi inclus, à titre informatif, la matrice de corrélation conjointe des deux catégories d'entreprises. Nous n'allons présenter et analyser, ici, que quelques exemples. Nous nous attarderons particulièrement aux corrélations pour lesquelles le coefficient est supérieur ou égal, en valeur absolue, à 0,50. Dans le groupe des entreprises ayant commis une fraude comptable, nous en dénombrons un total de cinq. Dans le groupe des entreprises de contrôle, ce nombre s'élève à quatorze. Les entreprises ayant commis une fraude comptable et celles de contrôle ne partagent que deux corrélations supérieures ou égales à 0,50, en valeur absolue.

Dans la matrice de corrélation des entreprises du premier groupe, nous remarquons que la corrélation entre les variables CROIS1 et DIFF est très négative (-0,64). Il semble donc qu'une forte croissance de ces entreprises ne soit pas associée à un accroissement de la qualité de leurs bénéfices. Au contraire, plus leur croissance est importante, moins leurs bénéfices seraient tangibles. Cependant, ce constat s'applique aux deux catégories d'entreprises. En effet, le coefficient de corrélation entre ces deux variables est aussi très négatif inférieur (-0,41 pour être exact) dans le deuxième groupe.

De son côté, quel que soit le groupe, le coefficient de corrélation entre LIQ et ROUL est fortement positif. Plus précisément, dans le groupe 1, il est égal à 0,78 et dans le groupe

2, à 0,64. Ce résultat n'a rien de surprenant, car le ratio de liquidité général et le fonds de roulement sont des mesures substitués du niveau de liquidité des entreprises.

Par ailleurs, nous constatons que les ratios d'évaluation VAL et PV sont très corrélés positivement dans la matrice de corrélation du groupe 1 (0,79), beaucoup plus, en fait, que dans celle du groupe 2 (0,47). Les ratios de la valeur au marché et cours sur ventes mesurent tous deux les perspectives de croissance de l'entreprises au cours des prochaines années, ce qui explique, sans doute, l'importance de la corrélation entre les deux.

De plus, parmi les entreprises ayant commis une fraude, la corrélation entre les ratios RA et RFP est elle aussi substantiellement plus élevée que 0,50. En fait, son coefficient s'élève à 0,93. Encore une fois, ce résultat était prévisible, le rendement de l'actif et le rendement des fonds propres étant tous deux reliés à la rentabilité. Le coefficient de corrélation entre ces deux variables des firmes du groupes 2 est plus de deux fois inférieur à celui des entreprises du groupe 1. Toutefois, deux mesures de la rentabilité sont aussi très fortement corrélées dans la catégorie des entreprises de contrôle. Il s'agit des variables RA et RCA, la corrélation entre les deux s'établissant à 0,75. Inversement, parmi les entreprises qui ont publié des états financiers mensongers, le niveau de corrélation entre ces deux variables est beaucoup plus faible (0,40).

Finalement, la seule différence entre les variables binaires FIN1 et FIN2, reliées aux besoins de financement externe, ne consistant qu'en la mesure des dépenses de capital utilisée dans le calcul des flux monétaires libres, nous nous attendions donc à ce que le coefficient de corrélation entre celles-ci soit très élevé. D'ailleurs, c'est le résultat que nous observons. Dans le groupe 1, le coefficient est égal à 0,92, alors que dans le groupe 2, il est égal à 1,00. Ainsi, parmi les entreprises ayant commis une fraude comptable, nous retrouvons les coefficients de corrélation les plus élevés, à une exception près (CROIS1 et DIFF), entre des mesures substitués de la liquidité, des opportunités de croissances, de la rentabilité et du besoin de financement externe.

Par ailleurs, dans la matrice de corrélation des entreprises de contrôle, nous notons que les deux mesures de la croissance (CROIS1 et CROIS2) sont positivement corrélées (0,63). Ces deux variables sont aussi corrélées de manière positive dans le groupe 1, bien que plus faiblement (0,47).

Nous remarquons également que les variables ROUL et RES sont davantage corrélées dans le groupe 2 (0,50) que dans le groupe 1 (0,42). Ainsi, il semblerait qu'un accroissement du fonds de roulement s'effectue au détriment d'une diminution de la qualité des bénéfices. ROUL est aussi corrélé négativement avec les deux mesures des besoins de financement externe. Dans les deux cas, le coefficient de corrélation se situe à -0,50. Ainsi, une diminution des fonds disponibles pour poursuivre les activités d'une entreprise à court terme entraîne, comme nous pouvions nous y attendre, une augmentation de la demande de fonds externes. Toutefois, ce raisonnement n'est valide que pour les entreprises du groupe 2, la corrélation entre FIN1 et FIN2 et ROUL n'étant que faiblement négative dans le groupe 1.

De plus, nous remarquons que le coefficient de corrélation entre FIN1 et FIN2 et le rendement de l'actif est négatif parmi les entreprises ayant commis une fraude comptable (-0,46 dans les deux cas), mais moins que parmi les entreprises de contrôle (-0,64, encore une fois, dans les deux cas). Donc, similairement à une diminution de la liquidité, une baisse de la rentabilité entraîne une hausse des besoins de financement externe dans les deux groupes. FIN1 et FIN2 sont aussi corrélées positivement à PV (0,51, une fois de plus, dans les deux cas). Dans le groupe 1, les coefficients de corrélation correspondants sont pratiquement nuls, s'établissant, tous deux, à 0,01.

Le rendement de l'actif est aussi très corrélé avec deux autres variables : les ratios PV (-0,67) et RES (0,66). Dans les deux cas, le coefficient de corrélation est grandement supérieur à celui retrouvé dans la matrice de corrélation des entreprises du premier groupe.

Enfin, nous constatons que RCA, une autre mesure de la rentabilité des entreprises, est elle aussi corrélée positivement avec RES et, qu'une fois de plus, le coefficient de

corrélation entre ces deux variables est substantiellement plus élevée dans le groupe 2 que dans le groupe 1. Ainsi, il semble qu'une détérioration de la qualité des bénéficiaires soit associée à une amélioration de la rentabilité parmi les entreprises de contrôle.

L'objectif principal de cette étude n'est pas de déterminer la nature exacte des relations entre la fraude perpétrée dans les états financiers et diverses variables explicatives. Ainsi, dans le cadre du développement des modèles de classification, nous avons donc eu recours à toutes les variables dont il a été question ci-haut. Dans la prochaine section, il sera important de garder cette information en tête lors de l'interprétation des coefficients des variables dans les modèles d'analyse discriminante linéaire et de régression logistique, car ils risquent d'être influencés, le cas échéant, par les niveaux de corrélation élevés entre certaines variables.

CHAPITRE 4. - DESCRIPTION DES MODÈLES

Dans cette section, nous ferons une présentation générale des différentes méthodes auxquelles nous avons recours pour développer les modèles de détection. Nous aborderons, entre autres sujets, leur fonctionnement général, les hypothèses sous-jacentes à leur utilisation et leurs forces et faiblesses. Par la suite, nous décrirons les modèles eux-mêmes.

Les modèles de détection développés sont, en fait, des modèles de classification. Ils ont été élaborés à partir de quatre méthodes : deux statistiques et deux d'intelligence artificielle. Les deux méthodes statistiques, dites paramétriques, sont l'analyse discriminante linéaire et la régression logistique. Pour leur part, les méthodes d'intelligence artificielle, dites non paramétriques, sont le partitionnement récursif, aussi connu sous le vocable arbre de classification en raison de la forme que prennent les modèles, et les réseaux de neurones. Comme nous l'avons mentionné en introduction, le partitionnement récursif n'a jamais été utilisé, selon toute vraisemblance, dans ce champ de la recherche.

Pour chacun des modèles, nous avons eu recours à la validation croisée cinq fois. Pour ce faire, un nombre aléatoire différent a été généré pour chaque paire d'entreprises accusée de fraude et de contrôle. Les firmes ont ensuite été classées en ordre croissant en fonction de ce nombre aléatoire. Enfin, l'échantillon a été séparé en cinq parts de taille égale. Ainsi, chaque part est utilisée à quatre reprises pour estimer un modèle et à une reprise pour le valider.

Par ailleurs, lorsqu'il était possible de le faire, nous avons incorporé dans les modèles différentes probabilités *a priori* et coûts relatifs de mauvaise classification. Cependant, les trois logiciels utilisés (le même logiciel a été utilisé pour développer les modèles à partir de l'analyse discriminante linéaire et de la régression logistique) ne partageant pas tous les mêmes caractéristiques, ces hypothèses n'ont pas pu toujours être insérées dans le calcul des taux de bonne classification et/ou des coûts de mauvaise classification, les deux mesures auxquelles nous aurons recours dans la section suivante pour comparer la

performance des modèles. Nous y reviendrons plus en détails dans les sections suivantes. Nous allons maintenant procéder à la description des méthodes et des modèles.

4.1. - Analyse discriminante linéaire

4.1.1. - Présentation générale

La discussion suivante est basée sur l'article de Altman, Avery, Eisenbeis et Sinkey (1981). Pour plus d'informations, prière de vous référer au texte original.

L'analyse discriminante est une méthode de classification. Elle permet de classer une observation en fonction de ses caractéristiques dans un de plusieurs groupes préalablement définis. Elle a été utilisée pour la première fois par Fischer, en 1936, dans le domaine de la biologie. Depuis, plusieurs chercheurs y ont eu recours avec succès, d'ailleurs, pour solutionner des problèmes financiers. Le travail de Altman (1968), portant sur la prédiction de la faillite, en est un bon exemple.

L'analyse discriminante est une méthode statistique. Plus précisément, il s'agit d'une technique d'analyse multivariée de la variance. Les techniques d'analyse de la variance se concentrent, en général, sur la distribution d'une ou de plusieurs variables, qu'elles comparent entre différents groupes. Il est supposé par la méthode que ces derniers sont connus, identifiables et mutuellement exclusifs.

Les variables indépendantes sont supposées suivre une distribution normale multivariée dans chaque groupe. De plus, leur distribution est présumée liée à celle de la variable dépendante. Cependant, contrairement à la méthode de régression logistique, le flux d'informations (*casual flow*) trouve son origine du côté de cette dernière. En fonction de l'appartenance à un groupe, la distribution spécifique des variables indépendantes est estimée.

Après avoir formulé des hypothèses sur la distribution des variables indépendantes, l'analyse discriminante permet de vérifier la présence de différences entre les vecteurs de moyennes et/ou les matrices de variances-covariances entre les différents groupes. Par ailleurs, elle peut servir à formuler des équations (*schemes*) pour prédire l'appartenance à un groupe, sous la forme d'une probabilité, d'observations qui n'ont pas servi à estimer les paramètres de l'équation – ce sont donc de « nouvelles » observations – qui sont caractérisées par un ensemble de variables indépendantes, mais dont le groupe réel est inconnu. Les équations assignent des probabilités à une observation en fonction du groupe avec lequel elle partage le plus de similitudes, telles que mesurées par les variables indépendantes. Pour chaque observation, la probabilité *a posteriori* d'appartenance à un groupe est estimée à partir de la fonction de probabilité (*likelihood function*) de ce groupe.

Les probabilités d'appartenance aux groupes et les règles de classification sont obtenus en comparant les fonctions de probabilité des deux groupes. Les règles de classification peuvent aussi permettre de classer directement une observation dans un groupe ou l'autre en fonction de ses caractéristiques. En ajustant les règles de classification, l'analyse discriminante offre même la possibilité de considérer les coûts de mauvaise classification. Pour chaque observation, la règle de classification suivante est utilisée dans la présente étude :

$$F(1) / F(2) \geq [C(1|2) * P(NF)] / [C(2|1) * P(F)]$$

où

F(1) = score de la fonction de classification du groupe 1 pour l'observation;

F(2) = score de la fonction de classification du groupe 2 pour l'observation;

C(1|2) = coût d'une erreur de type II (classer dans le groupe 1 une observation du groupe 2);

C(2|1) = coût d'une erreur de type I (classer dans le groupe 2 une observation du groupe 1);

P(F) = probabilité *a priori* qu'une fraude soit contenue dans les états financiers ;

$P(NF)$ = probabilité *a priori* qu'une fraude ne soit pas contenue dans les états financiers.

Le fonctionnement de l'analyse discriminante linéaire repose sur deux hypothèses simplificatrices : comme il a été dit précédemment, les variables indépendantes sont supposées suivre une distribution normale et, en plus, il est présumé qu'il y a égalité entre les matrices de variances-covariances des différents groupes.

L'analyse discriminante a l'avantage de considérer un ensemble de caractéristiques communes aux observations et l'interaction entre celle-ci et de réduire le nombre de dimensions de l'analyse. Par contre, la performance de la version linéaire risque d'être diminuée, si ce n'est tout simplement faible, en raison de la violation probable des hypothèses à son origine.

Pour développer les modèles d'analyse discriminante linéaire, nous avons eu recours à XLStat. Les spécifications de base du logiciel ont été utilisées.

4.1.2. - Description des modèles

Afin de ne pas alourdir inutilement le texte, nous ne traiterons que des variables pour lesquelles les coefficients sont différents de nos attentes. Le tableau 4 (p. 74) présente un résumé des coefficients dans les cinq modèles d'analyse discriminante linéaire. À l'annexe 4, nous présentons les résultats complets des modèles.

Au tableau 4, l'indicateur de positivité correspond, pour une variable prédictive donnée, au nombre de fois où, autrement dit, à la fréquence à laquelle le coefficient de cette variable adopte une valeur supérieure à zéro dans les modèles d'analyse discriminante linéaire qui, rappelons-le, sont au nombre de cinq. Nous y observons que le coefficient de la troisième variable reliée à la composition de l'actif que nous avons utilisée, l'indice de qualité des actifs (QUAL), est, en moyenne, nul. En fait, même lorsqu'il est positif, il ne l'est que faiblement. Ainsi, contrairement à ce que nous avons prévu, cette variable ne semble pas avoir un impact positif, du moins, significatif, sur la probabilité de fraude.

Le coefficient de BRUT est lui aussi nul et ce, dans tous les modèles, alors que nous nous attendions à ce qu'il soit positif. Par conséquent, une diminution de la marge brute, signifiant que les opportunités de croissance d'une entreprise s'amenuisent, n'entraînerait pas une hausse de la probabilité de fraude. De plus, contrairement aux trois autres ratios d'évaluation, nous remarquons également que le coefficient moyen de VAL est positif.

Tableau 4 : Coefficients des modèles d'analyse discriminante linéaire

Variable	Signe attendu	Moyenne	Écart type	Indicateur de positivité
Constante	-	1,16	0,68	5
REC	(+)	3,61	0,76	5
INV	(+)	2,37	0,40	5
QUAL	(+)	0,00	0,02	3
CROIS1	(+)	0,14	0,26	3
CROIS2	(+)	0,54	0,24	5
LIQ	(-)	-0,12	0,07	0
ROUL	(-)	-1,21	0,34	0
BRUT	(+)	0,00	0,00	0
CB	(-)	-0,59	1,97	2
VAL	(-)	0,24	0,39	4
PV	(-)	-1,29	0,78	0
PFM	(-)	-0,13	0,31	1
ROT	(-)	-0,67	0,15	0
ADEQ	(+)	-0,75	0,32	0
DIFF	(+)	-0,02	0,04	1
RES	(+)	4,46	0,73	5
RA	(-)	-0,19	0,32	1
RFP	(-)	0,00	0,00	0
RCA	(-)	0,08	0,04	5
FOND	(+)	0,58	0,10	5
CA	(+)	-0,02	0,01	0
PRES	(+)	0,48	0,09	5
COM	(-)	0,12	0,56	3
VERIF	(-)	-0,12	0,19	2
FIN1	(+)	1,25	1,27	4
FIN2	(+)	-1,15	1,07	1
LEV	(+)	-0,20	0,06	0
BOUR	(-)	-0,34	0,18	0

Par ailleurs, nous remarquons que le coefficient moyen de la variable ADEQ est négatif. De plus, son coefficient est négatif dans chacun des cinq modèles. Ainsi, il existerait une

relation négative, et non positive, tel que nous l'avions anticipée, entre l'indice d'adéquation entre les comptes à recevoir et les ventes et la probabilité de fraude.

De plus, contrairement à ce que nous avons prévu, le coefficient de DIFF est faiblement négatif. Ainsi, une dégradation de la qualité des bénéfices, représenté par un accroissement de la différence entre les bénéfices et les flux monétaires liés aux opérations, n'aurait pas un effet positif sur la probabilité de fraude. Toutefois, le coefficient moyen de DIFF n'est probablement pas significativement différent de zéro. Par contre, tel que prévu, celui de RES est très positif.

Parmi les variables mesurant la rentabilité, seul le rendement de l'actif a un coefficient moyen négatif. En effet, celui du rendement comptable de l'action est positif, alors que celui du rendement des fonds propres est nul. Toutefois, ce résultat dernier doit être analysé avec prudence, car la corrélation entre les variables RA et RFP est très élevée, surtout dans le premier groupe.

Précédemment, nous avons avancé que la taille du conseil d'administration aurait un impact positif sur la probabilité de fraude. Or, il semblerait que ce ne soit pas le cas. En fait, le coefficient moyen de la variable CA est presque nul (-0,02) et n'est jamais positif. Cette variable ne semble donc pas affecter significativement la probabilité de fraude.

Par ailleurs, le coefficient moyen de la variable COM est positif. Ce résultat est lui aussi contraire à notre prédiction et même contre-intuitif, car il implique que la présence d'un comité de vérification accroît la probabilité qu'une fraude ait été commise. Or, toutes les informations disponibles à cet égard laissent croire l'inverse.

Contrairement à FIN1, FIN2 a un coefficient négatif. Il n'est positif que dans un des modèles. Ce résultat est inattendu et doit lui aussi être analysé avec prudence, car la corrélation entre ces deux variables est extrêmement élevée dans les deux groupes. Enfin, une augmentation du levier financier (LEV), signifiant qu'une entreprise a plus de chances de violer les clauses de ses conventions de prêt, est associée négativement,

plutôt que positivement, à la probabilité de fraude. En effet, le coefficient moyen de cette variable est négatif. Ainsi, comme ceux de Persons (1995), nos résultats indiquent que niveau d'endettement élevé et fraude ne vont pas nécessairement de pair.

4.2. - Régression logistique

4.2.1. - Présentation générale

Nous allons maintenant décrire la régression logistique. Le lecteur intéressé à avoir plus d'information sur son fonctionnement, ses variantes, *etc.* est invité à consulter les références AI Access (2005), Pezzullo (2005) et San Francisco State University (2002), à partir desquels la présentation suivante est effectuée, qui se trouvent dans la bibliographie.

La régression logistique est une méthode statistique. Elle fait partie de la classe des modèles linéaires généralisés. En ce sens, elle est une variante de la régression linéaire. La régression logistique est utilisée soit pour prédire l'appartenance à un groupe, soit pour établir des relations et, par le fait même, déterminer leur ampleur entre les variables.

Elle vise, en général, à construire les modèles les plus parcimonieux possibles. Ainsi, toute variable indépendante qui permet d'accroître la bonne classification des observations est incluse dans le modèle. La procédure pas à pas (*stepwise*) est souvent utilisée pour construire les modèles.

La régression logistique est adaptée aux problèmes dans lesquels la variable dépendante Y ne peut prendre que deux valeurs auxquelles une probabilité est associée : la valeur 1 a une probabilité de succès de θ et 0 une probabilité d'échec de $1-\theta$. Les variables indépendantes peuvent prendre une ou l'autre des formes suivantes : continue, discrète et binaire. Contrairement à l'analyse discriminante linéaire, aucune hypothèse n'est formulée en ce qui concerne leur distribution. La relation entre la variable dépendante et les variables indépendantes est exprimée par :

$$\theta = \exp(\alpha + \beta_i X_i) / [1 + \exp(\alpha + \beta_i X_i)]$$

où :

α = la constante ;

β_i = le coefficient de la variable indépendante i ;

X_i = la valeur de la variable indépendante i .

En fonction des variables indépendantes, l'équation précédente estime donc la probabilité d'occurrence *a posteriori* d'un événement donné. Contrairement à l'analyse discriminante, la probabilité est estimée directement, c'est-à-dire sans que soient estimées, au préalable, les densités des classes. Ceci représente un avantage de la régression logistique sur l'analyse discriminante. Cependant, cette méthode n'est pas en tous points supérieure à l'analyse discriminante. Par exemple, le fait qu'elle ne requiert pas que les variables indépendantes suivent une distribution particulière implique que des échantillons de plus grande taille sont nécessaires pour obtenir une performance stable hors-échantillon.

Comme les modèles d'analyse discriminante linéaire, ceux de régression logistique ont aussi été estimés à partir de XLStat en utilisant, encore une fois, les valeurs de base des paramètres du logiciel.

4.2.2. - Description des modèles

Nous allons procéder à une analyse des coefficients des modèles de régression logistique similaire à celle des coefficients des modèles d'analyse discriminante linéaire. Nous remarquons que les coefficients sont rarement significatifs à un niveau de confiance de 90 %. Ainsi, nous porterons une attention particulière aux coefficients qui sont significatifs. Un résumé des coefficients de chacun des modèles de régression logistique se trouve au tableau 5 (p. 78). Comme pour les modèles d'analyse discriminante linéaire, les résultats complets des modèles sont présentés en annexe (voir annexe 5).

Au tableau 5, l'indicateur de significativité est égal à un lorsque le coefficient d'une variable est significatif dans un modèle à un niveau de confiance de 90 % ou plus, à deux lorsqu'il l'est dans deux modèles et ainsi de suite. La définition de l'indicateur de positivité est inchangée, à l'exception près qu'elle s'applique, cette fois-ci, aux cinq modèles de régression logistique.

Tableau 5 : Coefficients des modèles de régression logistique

Variable	Signe attendu	Moyenne	Écart type	Indicateur de significativité	Indicateur de positivité
Constante	N/A	-0,68	2,45	1	3
REC	(+)	5,65	2,93	3	5
INV	(+)	4,56	1,25	4	5
QUAL	(+)	0,05	0,07	0	4
CROIS1	(+)	0,68	1,43	0	4
CROIS2	(+)	5,70	0,98	5	5
LIQ	(-)	-0,29	0,11	0	0
ROUL	(-)	-0,56	1,13	0	2
BRUT	(+)	-0,40	1,11	1	1
CB	(-)	0,00	0,00	0	0
VAL	(-)	0,11	0,08	0	5
PV	(-)	-0,12	0,14	1	0
PFM	(-)	0,00	0,00	1	0
ROT	(-)	-0,98	0,44	3	0
ADEQ	(+)	0,19	0,85	0	3
DIFF	(+)	-0,30	1,73	0	2
RES	(+)	6,69	2,32	4	5
RA	(-)	-0,95	3,24	1	2
RFP	(-)	-0,04	0,46	0	2
RCA	(-)	-3,26	2,69	1	0
FOND	(+)	0,92	0,22	1	5
CA	(+)	-0,01	0,07	0	2
PRES	(+)	0,94	0,45	3	5
COM	(-)	0,36	0,77	0	3
VERIF	(-)	-0,36	0,42	0	1
FIN1	(+)	31,39	3,24	0	5
FIN2	(+)	-31,56	3,32	0	0
LEV	(+)	-0,35	0,24	2	0
BOUR	(-)	-1,30	0,55	3	0

Légende : Indicateur de significativité=n lorsque le coefficient d'une variable est significatif dans n modèles à un niveau de confiance de 90 % ou plus (n=1, 2, 3, 4, 5).

Tel qu'indiqué dans le tableau ci-haut, les coefficients moyens des variables REC et INV sont positifs. De plus, ils sont significatifs dans trois et quatre modèles, respectivement. Ces deux variables semblent donc avoir un effet prédictif important

dans le contexte de la fraude comptable, une faible augmentation d'un de ces deux ratios entraînant une hausse marquée de la probabilité de fraude.

De plus, tel que prévu, le coefficient de CROIS2 est positif et significatif dans chacun des modèles. Le coefficient de CROIS1 est positif quatre fois sur cinq, mais n'est jamais significatif. Tout comme pour les ratios comptes à recevoir sur actifs totaux et inventaires sur actifs totaux, il semble donc exister une forte relation positive entre la croissance des ventes et la fraude dans les états financiers.

Par ailleurs, la valeur moyenne des coefficients de LIQ et de ROUL est négative. Cependant, leur coefficient n'est significatif dans aucun des modèles. Ce résultat indique que les entreprises rencontrant des problèmes de liquidité n'ont pas nécessairement plus d'incitations à commettre une fraude que les autres firmes.

Nous constatons aussi que le coefficient de la rotation du capital (ROT) est négatif dans tous les modèles et qu'il est significatif dans trois d'entre eux. Ainsi, ce résultat confirme qu'une détérioration de la productivité peut effectivement servir d'incitations aux dirigeants d'une entreprise pour commettre une fraude.

Le coefficient moyen de RES est quant à lui fortement positif. D'ailleurs, il est positif et significatif dans tous les modèles. Par conséquent, une diminution de la qualité ou, encore, de la tangibilité des bénéfices, reflétée par une hausse du ratio réserves totales sur actifs totaux, a un effet positif important sur la probabilité de fraude.

Toutes les variables de gouvernance ne sont que peu ou pas significatives, à l'exception de PRES qui l'est dans trois modèles. Son coefficient est toujours positif, indiquant que lorsque les postes de président et/ou chef de la direction et de président du conseil sont occupés par la même personne, la probabilité qu'une fraude soit commise est plus élevée. Il serait donc important qu'il y ait une séparation entre ces postes.

Finalement, le coefficient de la variable BOUR est négatif dans cinq modèles et significatif dans trois. Ainsi, une entreprise cotée sur le NASDAQ a une plus faible

probabilité, tel qu'anticipé, d'avoir commis une fraude. Ce résultat peut s'expliquer, entre autres, par les règles de gouvernance que les firmes cotées sur ce marché boursier doivent respecter qui sont, en général, nombreuses et strictes.

4.3. - Partitionnement récursif

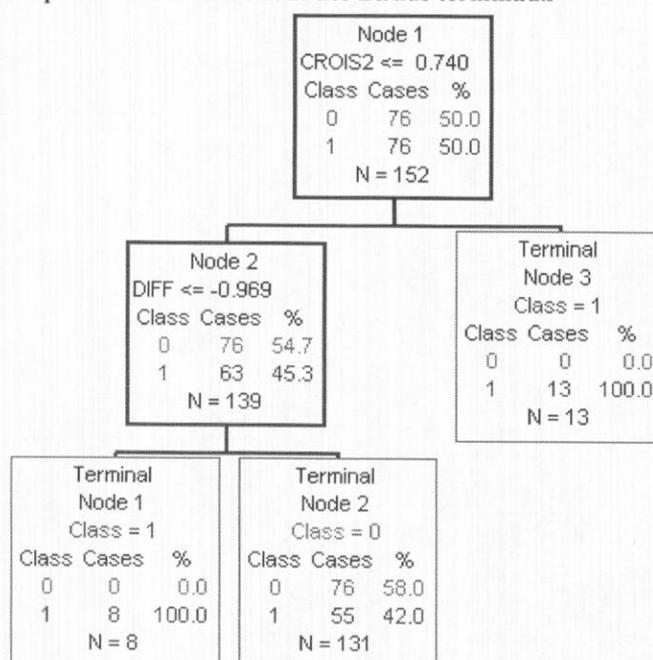
4.3.1. - Présentation générale

Dans cette section, nous ne présenterons la méthode du partitionnement récursif que brièvement. Le lecteur intéressé à en savoir davantage est invité à consulter le texte de Breiman, Friedman, Olshen et Stone (1984) qui a servi de base à la discussion suivante.

Un arbre de classification est construit en séparant un nœud initial en deux nouveaux nœuds, en séparant, si nécessaire, un ou ces deux nœuds à leur tour en deux nouveaux nœuds chacun, et ainsi de suite. Les nœuds qui ne sont pas séparés sont appelés nœuds terminaux. Un groupe est associé à chaque nœud terminal. Plus d'un nœud terminal peut se voir attribuer la même classe. Une observation se voit assigner le même groupe que celui qui est associé au nœud terminal dans lequel elle se retrouve. Le taux de bonne classification d'un groupe est obtenu en combinant les résultats individuels des nœuds qui lui sont associés. La figure 1 (p. 81) illustre un arbre de classification comprenant cinq nœuds dont trois sont des nœuds terminaux.

La séparation d'un nœud est effectuée à partir d'une question binaire portant sur l'une ou l'autre des variables indépendantes. La question binaire est déterminée en fonction de la réduction de l'impureté du modèle qu'elle entraîne. L'impureté d'un nœud donné est maximale lorsqu'un même nombre d'observations de chaque groupe y est contenu et, au contraire, minimale lorsqu'il ne contient des observations que d'une seule classe. La question binaire optimale est, évidemment, celle qui permet la plus importante diminution de l'hétérogénéité. À chaque nœud, un algorithme détermine quelle question est optimale pour chaque variable indépendante. Par la suite, parmi cet ensemble de questions binaires, il choisit la meilleure. Lorsqu'il n'est plus possible d'abaisser l'impureté d'un nœud de manière significative, alors il devient un nœud terminal.

Figure 1 : Exemple d'arbre de classification comprenant cinq nœuds dont trois sont des nœuds terminaux



Ainsi, en résumé, quatre éléments sont nécessaires pour construire un modèle de partitionnement récursif : un univers de questions binaires, un critère de performance des questions, une règle d'arrêt de la séparation et une règle d'affectation d'un nœud terminal à un des groupes.

Le partitionnement récursif présente un grand nombre d'avantages. En voici quelques-uns : le partitionnement récursif peut être utilisé pour traiter n'importe quel type de données; le modèle final est généralement simple, compact et efficace hors-échantillon; la méthode utilise l'information conditionnelle; elle procède automatiquement à une sélection des variables et à une réduction de la complexité du modèle; le modèle fournit la classification finale et la probabilité d'erreur de chaque observation; le partitionnement récursif est insensible aux transformations linéaires des variables ordonnées; il est robuste aux valeurs extrêmes et aux mauvaises classifications; il est tolérant aux données manquantes; enfin, ses résultats sont intuitifs.

Par contre, les arbres de classification sont affublés de quelques faiblesses concernant le choix de la taille optimale du modèle; le choix du critère de performance des questions binaires; la simplicité des questions binaires qui ne comprennent qu'une variable

indépendante; la simplicité de la structure de l'arbre final qui peut être trompeuse; la structure du modèle, potentiellement instable; les questions binaires qui tendent à favoriser, toutes choses étant égales par ailleurs, la séparation d'un nœud en un nœud de petite taille et un autre de grande taille plutôt qu'en deux nœuds de taille similaire (*end cuts*); la sélection des questions binaires qui est biaisée en faveur de celles qui prennent le plus grand nombre de valeurs différentes et, ainsi, qui offrent la plus grande variété de questions potentielles; et la procédure de construction des modèles qui n'est optimale que localement ou, en d'autres mots, que pour un nœud.

Les modèles de partitionnement récursif sont conçus à partir de CART. Les probabilités *a priori* et les coûts de mauvaise classification sont intégrés directement dans le logiciel. Autrement, nous avons eu recours à la configuration de base du logiciel.

4.3.2. - Description des modèles

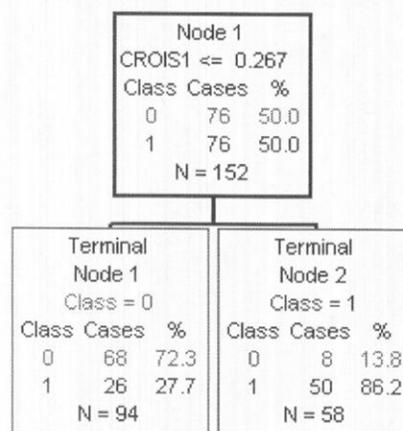
Étant donné le nombre important de modèles de partitionnement récursif qui ont été développés (90), nous n'en analyserons que cinq. Il s'agit des cinq arbres de classification qui ont été conçus dans ce qui sera considéré plus loin comme le scénario de base de cette méthode (voir le Chapitre 5. – Description des résultats). Après avoir présenté ces arbres, nous poursuivrons en discutant des variables prédictives qui, en général, ont été incluses dans l'ensemble des modèles. Plus particulièrement, nous traiterons de l'importance des variables, telle que rapportée par CART.

La figure 2 (p. 83) présente l'arbre de classification qui a été développé dans le scénario de base à partir du premier échantillon de validation croisée. Les cinq arbres conçus dans le cadre de ce scénario sont présentés à l'annexe 4.

Nous remarquons que l'arbre de classification précédent adopte une forme simple. En fait, comme il est possible de le constater en annexe, quatre des cinq arbres construits dans le scénario de base ne comportent que trois nœuds dont deux sont des nœuds terminaux. Contrairement aux autres, le troisième arbre de classification est beaucoup

plus complexe. En effet, il comprend un total de dix-neuf nœuds dont dix sont des nœuds terminaux.

Figure 2 : Arbre de classification développé dans le scénario de base à partir du premier échantillon de validation croisée



La question binaire initiale dans chacun de ces arbres de classification a trait à la variable CROIS1. Dans les deuxième, troisième et quatrième arbres, le seuil utilisé est égal à 0,266 (non rapporté), alors que dans le premier arbre il est égal à 0,267 (non rapporté) et dans le troisième, à 0,260 (non rapporté). Ces résultats indiquent qu'il est possible de distinguer les entreprises ayant commis une fraude comptable des autres firmes à partir de leur croissance. En particulier, dans notre échantillon, si la croissance des ventes d'une entreprise au cours du dernier exercice financier est supérieure à plus ou moins 26,0 % (0,260), elle est classée parmi les firmes ayant manipulé frauduleusement leurs états financiers.

Les autres questions binaires incluses dans le troisième arbre de classification sont reliées à la croissance (CROIS1 et CROIS2), aux opportunités de croissance (BRUT et PFM à deux reprises), à la rentabilité (RA), à la qualité des bénéfices (RES) et à la composition de l'actif (INV). À première vue, la croissance est donc particulièrement utile pour identifier les entreprises coupables d'avoir commis une fraude.

Ces résultats suggèrent que le partitionnement récursif est une méthode à la fois relativement stable et parcimonieuse. En effet, quatre fois sur cinq, la taille de l'arbre de

classification développé dans le cadre du scénario de base est identique. De plus, dans tous les arbres, la question binaire initiale est similaire. Nous allons maintenant traiter de l'importance des variables dans l'ensemble des modèles de partitionnement récursif développés dans le cadre de cette étude. Un ensemble de statistiques descriptives pour chaque variable est contenu dans le tableau 6.

Tableau 6 : Importance des variables dans les modèles de partitionnement récursif

Variable	Moyenne	Médiane	Écart type	Minimum	Maximum
REC	2,57	0,00	5,46	0,00	24,57
INV	3,45	0,00	8,00	0,00	34,37
QUAL	9,83	2,21	14,73	0,00	60,22
CROIS1	96,80	100,00	7,42	64,66	100,00
CROIS2	68,14	70,24	28,07	0,00	100,00
LIQ	1,38	0,00	4,37	0,00	24,51
ROUL	1,96	0,00	5,85	0,00	28,89
BRUT	5,44	2,58	9,29	0,00	50,12
CB	4,81	0,00	9,24	0,00	31,43
VAL	3,07	0,00	8,23	0,00	38,50
PV	3,11	0,00	8,57	0,00	47,58
PFM	11,85	0,00	20,80	0,00	84,19
ROT	2,23	0,00	5,91	0,00	37,53
ADEQ	5,15	0,00	8,61	0,00	37,38
DIFF	44,30	47,15	18,55	0,00	87,65
RES	25,43	18,92	18,25	0,00	75,21
RA	5,80	0,54	9,59	0,00	42,44
RFP	5,70	0,00	9,53	0,00	38,74
RCA	7,21	0,00	12,55	0,00	45,99
FOND	0,00	0,00	0,00	0,00	0,00
CA	2,05	0,00	8,53	0,00	57,46
PRES	0,00	0,00	0,00	0,00	0,00
COM	0,33	0,00	1,79	0,00	10,14
VERIF	0,00	0,00	0,00	0,00	0,00
FIN1	0,02	0,00	0,11	0,00	0,65
FIN2	0,00	0,00	0,00	0,00	0,00
LEV	1,77	0,00	5,79	0,00	35,68
BOUR	0,00	0,00	0,00	0,00	0,00

Nous remarquons que les deux variables dont l'importance moyenne est la plus élevée sont les mesures de la croissance des ventes. En effet, CROIS1 a une importance moyenne de 96,80 et CROIS2, de 68,14. En utilisant l'importance médiane plutôt que l'importance moyenne, nous arrivons à la même conclusion. Par ailleurs, nous relevons que la valeur minimale de l'importance de CROIS1 est la seule qui n'est pas nulle. En

fait, en se situant à 64,66, elle est même très élevée. Ce résultat indique, d'une part, que la croissance des ventes à un an permet de départager les entreprises des deux groupes et, d'autre part, que son rôle dans la séparation des observations est substantiel.

Par ailleurs, les variables différence entre les bénéfices et les flux monétaires liés aux opérations sur actifs totaux (DIFF) et réserves totales sur actifs totaux (RES) ont elles aussi une importance considérable dans les arbres de classification. L'importance moyenne (médiane) de DIFF s'élève à 44,30 (47,15). Dans le cas de RES, elle s'établit à 25,43 (18,92). Ainsi, la qualité des bénéfices, telle que mesurée par les deux variables précédentes, permettrait de différencier les entreprises ayant commis une fraude comptable des autres.

PFM est la cinquième variable dont l'importance moyenne est supérieure à 10,00. Cependant, comme sa médiane est nulle, elle est donc présente dans moins de la moitié des modèles, ce qui signifie que son importance, en fait, est somme toute limitée. L'indice de qualité des actifs (QUAL) a une importance moyenne de 9,83. Son importance médiane, sans être nulle, est très faible (2,21). Ces deux variables permettent donc de classer les entreprises dans leur groupe respectif, mais dans une mesure substantiellement moindre que les variables CROIS1 ou CROIS2, par exemple.

Toutes les autres variables ont une importance moyenne et médiane faible, sinon nulle. Leur valeur maximale indique qu'elles peuvent jouer un rôle important (par exemple, l'importance maximale de CA, la variable mesurant la taille du conseil d'administration, se situe à 57,46) dans au moins un modèle. Toutefois, le nombre de modèles en question devrait être faible, impliquant que ces variables ont un effet marginal sur la répartition des entreprises à un groupe ou l'autre.

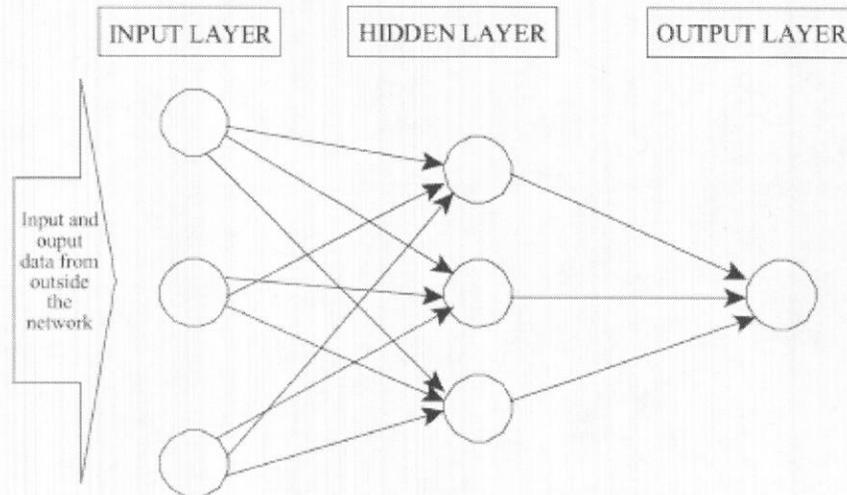
4.4. - Réseaux de neurones

4.4.1. - Présentation générale

Comme pour les méthodes précédentes, nous allons effectuer un bref survol de la méthode des réseaux de neurones. Quelques références sur le sujet se trouvent dans la bibliographie. Parmi celles-ci, mentionnons le texte de Calderon et Cheh (2002) qui aborde le développement des réseaux de neurones dans le domaine de la vérification. La présentation suivante est quant à elle basé sur Medsker, Turban et Trippi (1993).

Les réseaux de neurones font eux aussi partie des méthodes d'intelligence artificielle. Leur conception est inspirée d'études sur le cerveau et le système nerveux. Les réseaux de neurones sont des modèles qui reproduisent le traitement de l'information effectué par les réseaux de neurones biologiques. Comme son nom l'indique, un réseau de neurones est un ensemble de neurones regroupés sous la forme de couches. Généralement, un réseau est constitué de trois couches comme celui sur la figure 3.

Figure 3 : Architecture d'un réseau neurones



Source : Calderon et Cheh (2002)

La première couche, à gauche, est appelée couche d'entrée (*input layer*); la seconde, au milieu, couche intermédiaire ou couche cachée (*hidden layer*); enfin, la troisième, à droite, couche de sortie (*output layer*). Chaque neurone composant la couche d'entrée

est associé à un intrant, ou, en d'autres mots, à une variable prédictive différente. Le nombre de neurones composant la ou les couches intermédiaires – il peut effectivement y en avoir plus d'une – est quant à lui variable. Enfin, le nombre de neurones composant la couche de sortie est fonction du nombre d'extrants ou de solutions au problème. Les neurones des différentes couches peuvent être reliés les uns aux autres de différentes façons. Ainsi, les réseaux de neurones peuvent prendre différentes formes. En ce sens, leur architecture est souple.

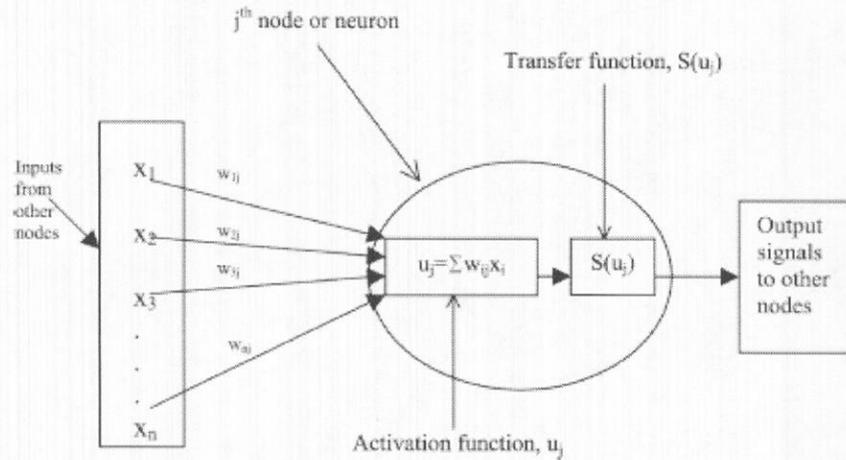
Les neurones représentent les éléments du réseau qui traitent l'information. Ainsi, un neurone reçoit un intrant, le traite et produit un extrant. L'intrant peut être une nouvelle information ou l'extrant d'un autre neurone qui peut lui-même être l'extrant final produit par le réseau ou l'intrant d'un autre neurone. Plusieurs neurones peuvent traiter de l'information simultanément.

Les poids sont des éléments-clés des réseaux de neurones. Ce sont effectivement eux qui permettent l'apprentissage d'un réseau, apprentissage qui s'effectue en les ajustant continuellement. En fait, avant d'arriver à l'ajustement des poids, un réseau calcule les extrants. Ensuite, il les compare à leur valeur réelle. Si nécessaire, il ajustera les poids pour minimiser ou éliminer la différence entre les extrants calculés et leur valeur réelle. Les valeurs des poids initiales sont déterminées aléatoirement.

Un réseau de neurones est aussi composé d'une fonction de sommation ou fonction d'activation qui multiplie la valeur de l'intrant de chaque neurone de la couche d'entrée par le poids qui lui est associé et effectue ensuite la sommation pour l'ensemble de neurones. Le résultat de la sommation est comparé à un niveau d'activation qui, lorsqu'il est franchi, fait en sorte que le neurone produit un extrant. La relation entre le niveau d'activation du neurone et son extrant est exprimée par une fonction de transformation qui peut être linéaire ou non-linéaire. Un exemple de fonction de transformation non-linéaire est la fonction sigmoïdale. La fonction de transformation a pour objectif de transformer l'extrant pour qu'il prenne une valeur « acceptable », souvent entre 0 et 1. L'extrant de chaque neurone peut être transformé ou encore seulement celui du neurone

de la couche de sortie. Tous ces éléments sont représentés sur la figure 4 pour un neurone.

Figure 4 : Éléments de base d'un neurone



Source : Calderon et Cheh (2002)

Les réseaux de neurones présentent plusieurs avantages par rapport aux méthodes statistiques traditionnelles. Tout d'abord, ils ont la capacité de tenir compte de relations non-linéaires entre la variable dépendante et les variables indépendantes. Ensuite, ils sont, en général, fiables et tolérants aux erreurs de données. Enfin, ils permettent habituellement d'effectuer de bonnes prévisions hors-échantillon. Cependant, comme les arbres de classification, les réseaux de neurones tendent à être complexes. En particulier, le nombre de paramètres à déterminer est important. Comme le choix des paramètres, l'architecture optimale du réseau est elle aussi obtenue en procédant par essai et erreur. De plus, les poids n'ont pas, à première vue, d'interprétation économique. Pour cette raison, les réseaux de neurones sont souvent considérés comme une boîte noire et ne peuvent donc pas servir à valider des théories.

Les réseaux de neurones de la présente étude ont été conçus à partir de NeuroShell2. Comme pour les trois autres méthodes, les spécifications initiales du logiciel ont été utilisées pour développer les modèles.

4.4.2. - Description des modèles

Comme nous l'avons mentionné dans la section précédente, les poids des réseaux de neurones n'ont pas d'interprétation évidente. Nous n'essaierons donc pas de les interpréter. Par contre, d'une manière similaire au partitionnement récursif, nous allons discuter brièvement de la contribution des variables dans les réseaux de neurones. Le tableau 7 présente quelques statistiques descriptives sur la contribution de chaque variable prédictive.

Tableau 7 : Contribution des variables prédictives dans les réseaux de neurones

Variable	Moyenne	Médiane	Écart type	Minimum	Maximum
REC	0,049	0,048	0,013	0,034	0,068
INV	0,039	0,039	0,005	0,033	0,044
QUAL	0,027	0,026	0,006	0,020	0,035
CROIS1	0,030	0,030	0,006	0,021	0,038
CROIS2	0,039	0,039	0,004	0,033	0,044
LIQ	0,046	0,048	0,006	0,038	0,052
ROUL	0,036	0,036	0,004	0,032	0,041
BRUT	0,031	0,032	0,004	0,025	0,034
CB	0,026	0,026	0,002	0,024	0,030
VAL	0,036	0,036	0,006	0,028	0,042
PV	0,029	0,031	0,005	0,021	0,033
PFM	0,032	0,032	0,003	0,030	0,036
ROT	0,045	0,041	0,011	0,035	0,064
ADEQ	0,026	0,027	0,004	0,019	0,030
DIFF	0,032	0,032	0,008	0,020	0,040
RES	0,053	0,053	0,004	0,047	0,058
RA	0,026	0,026	0,003	0,021	0,029
RFP	0,023	0,023	0,004	0,017	0,029
RCA	0,028	0,029	0,006	0,018	0,033
FOND	0,046	0,044	0,006	0,041	0,056
CA	0,045	0,041	0,008	0,040	0,059
PRES	0,033	0,033	0,004	0,027	0,038
COM	0,034	0,035	0,006	0,026	0,039
VERIF	0,042	0,045	0,008	0,030	0,051
FIN1	0,036	0,037	0,007	0,024	0,040
FIN2	0,034	0,035	0,006	0,023	0,039
LEV	0,035	0,035	0,004	0,030	0,041
BOUR	0,043	0,046	0,005	0,035	0,048

Étant donné le nombre important de variables prédictives utilisées, nous remarquons que la contribution moyenne de chaque variable est relativement faible. La contribution moyenne varie entre 0,023 et 0,053. La contribution médiane varie aussi entre ces deux

bornes. Par ailleurs, la contribution minimale s'établit à 0,017 et la contribution maximale, à 0,068, ce qui indique que certaines variables prédictives contribuent davantage que d'autres à la performance des réseaux de neurones.

Ainsi, nous constatons que seule la variable RES à une contribution moyenne supérieure à 0,050. Sa contribution médiane est elle aussi plus élevée que 0,050. La contribution minimale de RES (0,047), qui est la plus élevée parmi les 28 variables prédictives utilisées, laisse entrevoir que la qualité des bénéfices, telle que mesurée par cette variable, permet de départager davantage que les autres variables les entreprises des deux groupes.

La contribution moyenne des variables REC, LIQ, ROT, FOND, CA, VERIF et BOURSE se situe quant à elle entre 0,040 et 0,049. Les variables reliées à l'équipe de direction (FOND) et au conseil d'administration (CA) ont toutes deux une contribution minimale supérieure à 0,040. Leur contribution dans les réseaux de neurones serait donc quelque peu plus élevée, en général, que celle des autres variables prédictives. De plus, le ratio comptes à recevoir sur actifs totaux (REC), le ratio de liquidité générale (LIQ), la rotation du capital et la variable binaire reliée à la firme de vérification (VERIF) ont tous une contribution maximale supérieure à 0,050. Dans au moins un réseau de neurones, ces variables contribuent donc plus que les autres à la séparation des entreprises ayant commis une fraude comptable des autres.

Par ailleurs, les variables QUAL, CB, PV, ADEQ, RA, RFP et RCA ont toutes une contribution moyenne inférieure à 0,020. Ainsi, l'apport de la rentabilité, telle que mesurée dans la présente étude par le rendement de l'actif (RA), le rendement des fonds propres (RFP) et le rendement comptable de l'action (RCA), serait somme toute limité dans les réseaux de neurones. Cette caractéristique permettrait donc moins de différencier les entreprises de chacun des deux groupes que les autres variables prédictives.

Nous concluons cette section en abordant l'importance des variables prédictives dans les quatre méthodes. Le tableau 8 (p. 92) contient quelques informations à ce sujet. Dans les

colonnes deux à cinq, les chiffres 0, 1 et 2 y signifient qu'une variable prédictive est peu importante, importante et très importante, respectivement. Pour qu'une variable se voit attribuer ces chiffres dans l'analyse discriminante linéaire, son coefficient standardisé moyen, en valeur absolue, doit se situer entre 0,00 et 0,19, entre 0,20 et 0,39 et à plus de 0,40, respectivement; dans la régression logistique, son indicateur de significativité doit être égal à 0 ou 1, à 2 ou 3 et à 4 ou 5, respectivement; dans le partitionnement récursif, son importance moyenne doit s'établir entre 0,00 et 19,99, entre 20,00 et 39,99 et à plus de 40,00, respectivement; enfin, dans les réseaux de neurones, sa contribution moyenne doit valoir entre 0,000 et 0,019, entre 0,020 et 0,039 et plus de 0,040, respectivement. Pour sa part, dans la sixième colonne, l'importance totale correspond à la somme de l'importance d'une variable dans chacune des quatre méthodes, telle que nous venons de la décrire. Enfin, dans la colonne « Variable très importante », le chiffre associé à une variable est égal à un lorsque cette variable est considérée très importante, selon la classification précédente, dans au moins une des quatre méthodes; autrement, ce chiffre est égal à zéro.

Nous remarquons que le partitionnement récursif est la méthode la plus parcimonieuse. En effet, seulement quatre variables prédictives y sont importantes ou très importantes. Qui plus est, ces variables n'appartiennent qu'à deux classes distinctes : la croissance (CROIS1 et CROIS2) et la qualité des bénéfiques (DIFF et RES).

Quoiqu'un peu moins parcimonieux que les arbres de classification, les modèles de régression logistique peuvent aussi être décrits comme tels. Un nombre relativement restreint de variables prédictives y sont effectivement importantes ou très importantes. Parmi celles-ci, nous retrouvons des mesures de la croissance (CROIS2), de la qualité des bénéfiques (RES), de la composition de l'actif (REC et INV) et de la productivité (ROT).

Contrairement aux deux autres méthodes, l'analyse discriminante linéaire et les réseaux de neurones considèrent une majorité de variables comme étant importantes ou très importantes. En fait, en ce qui concerne les réseaux de neurones, toutes les variables y ont un de ces deux statuts. Parmi ces variables, nous retrouvons encore une fois des

mesures de la croissance (CROIS2), de la qualité des bénéfices (DIFF et RES), de la composition des actifs (REC et INV) et de la productivité (ROT).

Tableau 8 : Importance des variables prédictives dans les méthodes d'analyse discriminante linéaire (ADL), de régression logistique (RL), de partitionnement récursif (PR) et de réseaux de neurones (RN)

Variable	ADL	RL	PR	RN	Importance totale	Variable très importante
REC	2	1	0	2	5	1
INV	1	2	0	1	4	1
QUAL	0	0	0	1	1	0
CROIS1	0	0	2	1	3	1
CROIS2	2	2	2	1	7	1
LIQ	1	0	0	2	3	1
ROUL	1	0	0	1	2	0
BRUT	0	0	0	1	1	0
CB	0	0	0	1	1	0
VAL	1	0	0	1	2	0
PV	0	0	0	1	1	0
PFM	1	0	0	1	2	0
ROT	2	1	0	2	5	1
ADEQ	1	0	0	1	2	0
DIFF	1	0	2	1	4	1
RES	2	2	1	2	7	1
RA	0	0	0	1	1	0
RFP	1	0	0	1	2	0
RCA	1	0	0	1	2	0
FOND	1	0	0	2	3	1
CA	0	0	0	2	2	1
PRES	1	1	0	1	3	0
COM	0	0	0	1	1	0
VERIF	0	0	0	2	2	1
FIN1	2	0	0	1	3	1
FIN2	1	0	0	1	2	0
LEV	1	1	0	1	3	0
BOUR	0	1	0	2	3	1

Par ailleurs, en ce qui concerne l'importance individuelle des variables, nous observons que la variable CROIS2 est très importante dans trois des quatre méthodes et qu'elle est importante dans la quatrième. Conjointement avec le ratio réserves totales sur actifs totaux (RES), CROIS2 a l'importance totale la plus élevée (sept, alors que l'importance maximale est égale à huit). En regard aux résultats obtenus dans la littérature, ce constat est surprenant. En effet, à l'exception de Beneish (1999), aucun auteur n'a obtenu de

résultats significatifs en ce qui a trait à la croissance des ventes¹¹. Nos résultats indiquent donc que la croissance des ventes est un bon indicateur de la présence de fraude comptable. À cet effet, la croissance des ventes au cours des deux derniers exercices financiers de 70 entreprises ayant commis une fraude dans notre échantillon est supérieure ou égale à 16 % (0,16) (non rapporté). En comparaison, la valeur de CROIS2 de seulement 20 entreprises de contrôle est plus élevée ou égale à ce seuil (non rapporté). Bien que son importance totale soit inférieure à celle de CROIS2, CROIS1 permet aussi de différencier les entreprises des deux groupes dans notre échantillon : 65 entreprises ayant publié des états financiers frauduleux ont connu une croissance des ventes au cours de l'exercice financier dans lequel la fraude a débuté supérieure ou égale à 22 % (0,22), alors que ce n'est le cas que de 16 entreprises de contrôle (non rapporté).

RES, ainsi que DIFF, qui correspond au ratio différence entre les bénéfices et les flux monétaires liés aux opérations sur actifs totaux, sont, au minimum, très importants dans deux méthodes et importants dans une troisième. L'importance totale de ces variables dans nos modèles, en particulier celle de RES qui se situe à sept, était prévisible. Bien que Beneish (1997, 1999) ait été le seul à utiliser le ratio réserves totales sur actifs totaux dans des modèles de détection de la fraude, le coefficient de cette variable était à chaque fois très significatif. Dans notre échantillon, 51 entreprises ayant manipulé frauduleusement leurs états financiers ont un ratio réserves totales sur actifs totaux supérieur ou égal à $-0,01$, alors que tel est le cas pour seulement 23 entreprises de contrôle (non rapporté). Ainsi, la qualité des bénéfices, telle que mesurée par RES, est une autre caractéristique importante d'une entreprise permettant de prédire, à l'intérieur d'un modèle de détection ou non, si elle a commis une fraude comptable.

Nous notons aussi que les ratios comptes à recevoir sur actifs totaux (REC) et inventaires sur actifs totaux (INV) sont très importants dans trois méthodes. En effet, trois des quatre méthodes considèrent une des deux variables très importante et l'autre importante. L'importance totale de ces deux variables est aussi parmi les plus élevées. Ces résultats suggèrent que les proportions de comptes à recevoir et d'inventaires contenues dans le bilan d'une entreprise sont des facteurs importants pour départager les

¹¹ Il est à noter que tous les auteurs n'utilisent pas une même définition de la croissance des ventes. Leurs résultats ne sont donc pas directement comparables.

entreprises ayant commis une fraude dans leurs états financiers des autres firmes. Ces constats sont quelque peu surprenants, car seul Stice (1991) a obtenu des résultats significatifs pour ces variables dans son modèle. Par ailleurs, bien qu'elles soient importantes à l'intérieur des modèles, REC et INV permettent difficilement, sur une base univariée, de prédire l'appartenance d'une entreprise à un des deux groupes. Par exemple, dans notre échantillon, le ratio comptes à recevoir de 63 entreprises ayant perpétré une fraude comptable est supérieur ou égal à 0,24 (non rapporté). Or, tel est le cas aussi pour 56 entreprises de contrôle (non rapporté). Les résultats sont similaires en ce qui concerne le ratio inventaires sur actifs totaux. Utilisées individuellement, ces variables sont donc plus ou moins utiles pour prédire la présence de fraude dans les états financiers d'une firme. Fait à remarquer, l'indice de qualité des actifs (QUAL) est peu important dans trois des quatre méthodes. Cette mesure complémentaire de la composition de l'actif n'aurait donc pas un apport considérable à la performance des modèles, en raison, probablement, de leur utilisation des variables REC et INV.

Comme le ratio comptes à recevoir, nous observons que la rotation du capital (ROT) est très importante dans deux méthodes et importante dans une autre. De plus, l'importance totale de cette variable est parmi les plus élevées (cinq sur un maximum de huit). Ce résultat n'était pas totalement inattendu. En effet, peu d'auteurs ont eu recours à cette variable dans un modèle de détection. Néanmoins, parmi ceux-ci, Persons (1995) a obtenu un coefficient significatif pour cette variable dans son modèle. Par ailleurs, comme pour les variables REC et INV, nous observons dans notre échantillon que 70 entreprises ayant commis une fraude comptable ont une rotation du capital inférieure ou égale à 0,99. Toutefois, la valeur de ROT de 60 entreprises de contrôle est aussi plus petite ou égale à ce seuil. La productivité d'une entreprise, telle que mesurée par ROT, aurait donc elle aussi un impact important sur le classement d'une entreprise lorsque vient le moment de prédire si elle a commis une fraude comptable, mais seulement à l'intérieur des modèles de classification. Seule, cette variable ne serait donc pas un bon indicateur de la présence de fraude.

Les autres variables prédictives peuvent être sujettes à quelques observations intéressantes. D'une part, les variables mesurant les opportunités de croissance et, plus

particulièrement, les ratios d'évaluation qui, rappelons-le, n'ont jamais été utilisés auparavant dans un modèle de détection de la fraude, ont peu ou pas d'impact sur la performance des modèles dans les différentes méthodes. En effet, CB, VAL, PV et PFM ont une importance totale très faible (deux ou moins). D'autre part, il est quelque peu étonnant que l'importance totale de l'indice d'adéquation entre les comptes à recevoir et les ventes ne soit pas plus élevée. En effet, Beneish (1997, 1999) a obtenu des résultats très significatifs en ce qui concerne le coefficient de cette variable.

Dans la dernière colonne du tableau 8, en utilisant un critère différent pour évaluer l'importance globale des variables prédictives, nous observons qu'un plus grand nombre de variables sont considérées importantes (en fait, très importantes). Parmi ces variables, nous retrouvons REC, INV, CROIS2, ROT, DIFF, RES, comme nous pouvions nous y attendre, mais aussi CROIS1, LIQ, FOND, CA, VERIF, FIN1 et BOUR. De ces sept variables prédictives, il appert que seule CROIS1, dont il a été question précédemment, soit d'une quelconque utilité, sur une base univariée, pour distinguer les entreprises des deux groupes.

Avant de passer à la description des résultats, une dernière remarque s'impose. Un nombre considérable de variables prédictives sont importantes dans au moins deux méthodes. Cependant, nous remarquons qu'un nombre tout aussi grand de classes de variables prédictives sont, en général, peu importantes dans deux ou trois méthodes. Parmi celles-ci, nous retrouvons les variables associées à des aspects tels que la liquidité, la rentabilité et l'équipe de direction. Ainsi, leur importance totale est relativement faible (inférieure ou égale à trois), ce qui, à la vue des résultats obtenus dans la littérature, était prévisible. En effet, utilisées dans le cadre de modèles de détection de la fraude, ces variables se sont révélées peu souvent significatives (non rapporté). Ces différentes caractéristiques d'une entreprise, peu importe comment elles sont mesurées, ne permettraient donc pas, règle générale, de distinguer particulièrement bien les firmes des deux groupes.

CHAPITRE 5. - DESCRIPTION DES RÉSULTATS

Dans cette section, nous discuterons des résultats des modèles de classification développés à partir des quatre méthodes présentées précédemment. La performance des modèles est évaluée à partir de deux mesures différentes : le taux de bonne classification et le coût espéré de mauvaise classification. Un taux de bonne classification est calculé pour chacun des deux groupes et pour les deux groupes combinés. Ces deux mesures de performance sont calculées pour les échantillons d'estimation et de validation. Par ailleurs, les taux de bonne classification et les coûts espérés de mauvaise classification sont évalués pour un ensemble d'hypothèses, lorsqu'il est possible d'en faire, comprenant différentes probabilités *a priori*, coûts relatifs de mauvaise classification et seuils de classification. Avant d'aborder la performance des modèles, nous allons présenter les différentes valeurs des trois paramètres qui ont été retenues et les raisons motivant ces choix.

Peu d'informations existent concernant la probabilité *a priori* réelle qu'une entreprise commette une fraude comptable. Feroz *et al.* (2000) indiquent que la probabilité *a priori* qu'une entreprise soit l'objet d'une enquête de la SEC se situe à 1 %. De son côté, Persons (1995) a estimé cette probabilité à 2 %. Étant donné que toutes les fraudes ne sont pas détectées par la SEC, nous avons recours à trois probabilités *a priori* qu'une fraude comptable ait été commise : 1 %, 2 % et 3 %. Même si une probabilité *a priori* de 3 % peut sembler exagérée, elle aura au moins l'effet d'illustrer la sensibilité des résultats aux probabilités *a priori* utilisées.

Par ailleurs, nous utilisons six coûts relatifs de mauvaise classification : 1:1, 5:1, 10:1, 20:1, 30:1 et 50:1. Le premier chiffre correspond au coût d'une erreur de type I et le deuxième, au coût d'une erreur de type II. Une erreur de type I consiste à classer une entreprise du groupe 1 dans le groupe 2. Inversement, une erreur de type II consiste à classer une entreprise du groupe 2 dans le groupe 1. Rappelons que le groupe 1 fait référence aux entreprises ayant commis une fraude comptable et le groupe 2, aux entreprises de contrôle. Ces différents coûts relatifs de mauvaise classification sont

généralement ceux utilisés dans la littérature (Beneish, 1997; Feroz *et al.*, 2000; Persons, 1995; Stice, 1991). Par ailleurs, Persons (1995) mentionne que :

Higher cost of type I error relative to type II error (e.g., 30:1) seems to represent a more realistic assumption because losses incurred by investors as a result of investing in fraud firms, that are misclassified as nonfraud, are normally far greater than the opportunity cost of not investing in nonfraud firms as a result of misclassifying them as fraud firms (p. 44).

Enfin, cinq seuils de classification sont utilisés : 0,1, 0,3, 0,5, 0,7 et 0,9. Ces seuils ne serviront qu'à calculer les taux de bonne classification des modèles conçus à partir des régressions logistiques et des réseaux de neurones. Pour chacune des méthodes, il est probable qu'aucun seuil ne corresponde au seuil optimal, c'est-à-dire celui permettant de maximiser les taux de bonne classification ou encore de minimiser le coût espéré de mauvaise classification. Néanmoins, ils nous permettront d'évaluer l'impact d'une variation du seuil de classification sur les résultats.

5.1. - Taux de bonne classification

Étant donné le nombre important de modèles développés dans cette étude, nous ne discuterons que des taux de bonne classification moyens et des écarts types qui leur sont associés. Le tableau 9, présenté à la page suivante, regroupe ces résultats pour le groupe 1, le groupe 2 et les deux groupes réunis pour chacune des méthodes dans ce que nous considérons être un « scénario de base ». En fait, il s'agit de deux scénarios de base : un pour les modèles d'analyse discriminante linéaire et de partitionnement récursif et un autre pour les modèles de régression logistique et de réseaux de neurones. Les taux de bonne classification obtenus en utilisant une probabilité *a priori* de fraude de 2 % et un coût relatif de mauvaise classification de 20:1 constitueront le scénario de base pour les modèles d'analyse discriminante linéaire et de partitionnement récursif dans la discussion suivante. Pour leur part, les taux de bonne classification obtenus en ayant recours à un seuil de classification égal à 0,5 serviront de scénario de base pour les modèles de régression logistique et de réseaux de neurones. Le choix de deux scénarios de base est rendu obligatoire en raison de la comparabilité ou, plutôt, de la non-comparabilité des résultats. En effet, les taux de bonne classification des modèles d'analyse discriminante linéaire et de partitionnement récursif, lesquels sont obtenus en tenant compte des probabilités *a priori* et des coûts de mauvaise classification, sont

directement comparables entre eux, mais pas avec ceux des régressions logistiques et des réseaux de neurones qui, de leur côté, sont influencés uniquement par le seuil de classification utilisé. Nous présenterons d'abord les résultats des modèles d'analyse discriminante linéaire, puis ceux des arbres de classification. Nous procéderons ensuite à la description des taux de bonne classification des modèles de régression logistique. Nous terminerons cette section avec une discussion des taux de bonne classification obtenus avec les réseaux de neurones.

Tableau 9 : Taux de bonne classification moyens (écart type) des modèles d'analyse discriminante linéaire (ADL), de partitionnement récursif (PR), de régression logistique (RL) et de réseaux de neurones (RN) dans leur scénario de base respectif dans les échantillons d'estimation et de validation (%)

Échantillons d'estimation				
	ADL	PR	RL	RN
Groupe 1	49,5 (4,7)	68,2 (6,3)	82,9 (2,1)	75,8 (17,6)
Groupe 2	94,7 (1,6)	92,1 (3,8)	84,2 (2,5)	82,6 (7,6)
Global	72,1 (3,0)	80,1 4,9	83,6 (2,1)	79,2 (8,7)
Échantillons de validation				
	ADL	PR	RL	RN
Groupe 1	41,1 (9,4)	67,4 (10,1)	64,2 (18,0)	52,6 (6,4)
Groupe 2	82,1 (13,7)	89,5 (5,3)	72,6 (12,6)	60,0 (15,6)
Global	61,6 (5,5)	78,4 (3,4)	68,4 (7,7)	56,3 (5,5)

5.1.1 Analyse discriminante linéaire

Nous débutons en présentant les résultats des modèles d'analyse discriminante linéaire. Les résultats complets (taux de bonne classification et coûts espérés de mauvaise classification) des modèles d'analyse discriminante se trouvent à l'annexe 7.

Au tableau 9, nous remarquons que, avec une probabilité *a priori* de fraude de 2 % et un coût relatif de mauvaise classification de 20:1, les modèles d'analyse discriminante linéaire permettent d'obtenir un taux de bonne classification global moyen de 72,1 %. De plus, l'écart type qui lui est associé est faible (3,0 %). Tel qu'indiqué en annexe, le taux de bonne classification global moyen est, en général, inférieur à 65,0 % pour les coûts relatifs de mauvaise classification 1:1, 5:1 et 10:1 dans les échantillons d'estimation. Au contraire, il est généralement supérieur à 70,0 % pour les trois autres coûts relatifs de mauvaise classification. Dans tous les cas, les taux sont stables d'un échantillon d'estimation à l'autre. Par ailleurs, nous remarquons qu'une augmentation (diminution) de la probabilité *a priori* de fraude et/ou du coût relatif de mauvaise classification a , en général, un effet positif (négatif) sur le taux de bonne classification global moyen.

Le taux de bonne classification global est une mesure de l'efficacité générale d'un modèle de classification. Comme nous l'avons vu précédemment, un modèle de détection de la fraude comptable efficace permet d'obtenir à la fois un taux de bonne classification du groupe 1 élevé ou, ce qui est équivalent, un faible taux d'erreur de type I et un taux de bonne classification du groupe 2 élevé ou, ce qui est équivalent, un faible taux d'erreur de type II¹². Par conséquent, il est important de considérer individuellement le taux de bonne classification de chaque groupe. Ainsi, en y regardant de plus près, nous constatons que le taux de bonne classification des entreprises ayant commis une fraude est faible dans le scénario de base. En effet, moins d'une entreprise sur deux incluse dans le groupe 1 est classée, en moyenne, dans la bonne catégorie. Une analyse plus approfondie révèle que le taux de bonne classification moyen des entreprises ayant commis une fraude est faible, en général, dans les échantillons d'estimation, sauf pour les combinaisons de probabilités *a priori* et de coût relatif de mauvaise classification les plus élevés. Par exemple, en utilisant une probabilité *a priori* de fraude de 3 % et un coût relatif de mauvaise classification de 50:1, le taux de bonne classification moyen du groupe 1 se situe à 85,5 %. Dans presque tous les cas, l'écart type des taux de bonne classification du groupe 1 est inférieur à 5,0 %. Ainsi, la

¹² En raison de la disparité importante qui existe entre les coûts de mauvaise classification, l'analyse des coûts espérés de mauvaise classification et, plus encore, celle des coûts espérés de mauvaise classification relatifs à une stratégie naïve, seront particulièrement éclairantes sur la performance des modèles.

performance des modèles d'analyse discriminante linéaire est donc relativement stable – mais, en général, faible - d'un échantillon d'estimation à l'autre en ce qui concerne ces entreprises. Par ailleurs, comme pour le taux de bonne classification global moyen, une hausse de la probabilité *a priori* de fraude et/ou du coût relatif de mauvaise classification permet d'augmenter (de diminuer) significativement le taux de bonne classification moyen du groupe 1.

Comme les chiffres précédents le laissent présager, il existe une grande différence entre les taux de bonne classification des deux groupes. Le taux de bonne classification du groupe 2 est effectivement beaucoup plus élevé – environ deux fois - que celui du groupe 1 dans les échantillons d'estimation dans le scénario de base. En fait, le taux de bonne classification des entreprises de contrôle est supérieur à 80,0 %, peu importe les hypothèses utilisées, sauf pour deux scénarios (probabilités *a priori* de fraude égales à 2 % et 3 % et coût relatif de mauvaise classification égal à 50:1). Les écarts types sont aussi très faibles, suggérant, encore une fois, une stabilité élevée de la performance des modèles sur les différents échantillons d'estimation pour ce groupe. Par ailleurs, contrairement au groupe 1, une augmentation (diminution) de la probabilité *a priori* de fraude diminue (augmente) un peu le taux de bonne classification moyen du groupe 2, sauf pour les coûts relatifs de mauvaise classification 30:1 et 50:1, pour lesquels la baisse est marquée. Pour sa part, une hausse (baisse) du coût relatif de mauvaise classification décroît (accroît) le taux de bonne classification moyen des entreprises de contrôle.

Dans ce genre d'étude, les résultats obtenus en utilisant les échantillons d'estimation sont généralement biaisés à la hausse (Frank, Massy et Morrisson, 1965, cité dans Fanning et Cogger, 1998). Ainsi, les mesures de performance les plus pertinentes sont celles obtenues sur l'échantillon – les échantillons dans notre cas, car un modèle est développé pour chaque échantillon de validation croisée, qui sont au nombre de cinq - de validation. Comme nous pouvions nous y attendre, le taux de bonne classification global moyen du scénario de base a diminué dans les échantillons de validation. Il se situe maintenant à 61,6 %. L'écart type qui lui est associé a aussi augmenté à 5,5 %. Règle générale, dans les échantillons de validation, nous constatons que le taux de bonne

classification global moyen subit une baisse importante – en général, plus de dix points de pourcentage - pour un coût relatif de mauvaise classification supérieur ou égal à 10:1. Par ailleurs, nous constatons que les variations de la probabilité *a priori* de fraude et du coût relatif de mauvaise classification ont un effet similaire à ceux dans les échantillons d'estimation. D'ailleurs, il en est de même pour les groupes 1 et 2.

Le taux de bonne classification moyen des entreprises du premier groupe s'établit, pour sa part, à 41,1 %, hors-échantillon, dans le scénario de base. De plus, l'écart type qui lui est associé a doublé par rapport à celui des échantillons d'estimation, passant de 4,7 % à 9,4 %. De manière générale, nous notons que le taux de bonne classification moyen des entreprises ayant commis une fraude comptable est très faible dans les échantillons de validation. En fait, à trois exceptions près, il est inférieur à 50,0 %. Les écarts types sont aussi plus élevés que ceux des échantillons d'estimation. Ainsi, la différence de performance des modèles d'un échantillon de validation à l'autre est relativement importante.

Par ailleurs, les mêmes disparités de performance entre les deux groupes sont observables hors-échantillon. Dans le scénario de base, en moyenne 82,1 % des observations du groupe sont classées correctement. L'écart type qui lui est associé a lui aussi considérablement augmenté : il se situe à 13,7 %, plus de douze points de pourcentage de plus que sa contrepartie dans les échantillons d'estimation. Le taux de bonne classification moyen des entreprises de contrôle est, la majorité du temps, encore supérieur à 80% dans les échantillons de validation. La performance des modèles s'est tout de même détériorée par rapport aux échantillons d'estimation. Finalement, les écarts types des taux de bonne classification du groupe 2 sont significativement plus élevés dans les échantillons de validation que dans ceux d'estimation. La performance des différents modèles est donc inégale d'un échantillon de validation à l'autre.

Les taux de bonne classification des entreprises ayant commis une fraude comptable atteints par l'analyse discriminante linéaire sont donc décevants dans les échantillons de validation. Toutefois, ces résultats peuvent être expliqués, au moins, en partie, par la violation des hypothèses – normalité et égalité des matrices de covariances - à la base de

son fonctionnement. En effet, nous avons vu précédemment que la majorité des variables dans chacun des deux groupes ne sont pas distribuées normalement. De plus, les matrices de covariances des deux groupes sont différentes (non rapportées).

5.1.2. - Partitionnement récursif

Nous continuons maintenant avec l'analyse des résultats obtenus avec la méthode du partitionnement récursif. L'ensemble des résultats des arbres de classification se trouvent à l'annexe 8.

Dans les échantillons d'estimation, le taux de bonne classification global du partitionnement récursif est, en moyenne, de 78,4 % en ce qui concerne le scénario de base, comparativement à 72,1 % pour l'analyse discriminante linéaire. L'écart type associé à ce taux est similaire avec les deux méthodes. De manière générale, tous les taux de bonne classification globaux moyens des arbres de classification avoisinent les 80,0 % pour un coût relatif de mauvaise classification supérieur ou égal à 10:1 dans les échantillon d'estimation. Pour tous les coûts relatifs de mauvaise classification, peu importe la probabilité *a priori*, ils sont supérieurs à ceux atteints par l'analyse discriminante linéaire. La différence est particulièrement importante pour les coûts relatifs les plus faibles. Par ailleurs, les écart types associés aux taux de bonne classification globaux sont, en général, un peu plus faibles que dans le cas de l'analyse discriminante. Contrairement à l'analyse discriminante, une hausse (baisse) de la probabilité *a priori* de fraude et/ou du coût relatif de mauvaise classification n'augmente (diminue) pas nécessairement le taux de bonne classification global moyen, sauf pour les coûts relatifs de mauvaise classification les plus faibles. Les taux de bonne classification moyens globaux, du groupe 1 et du groupe 2 sont moins sensibles, en général, à la probabilité *a priori* et au coût relatif de mauvaise classification utilisés que ceux de l'analyse discriminante linéaire.

En portant notre attention sur le taux de bonne classification moyen des entreprises faisant partie du groupe 1, nous remarquons qu'il se situe, dans le scénario de base, à 68,2 % pour les arbres de classification. Ce taux est près de dix-neuf points de

pourcentage supérieur à celui obtenu avec l'analyse discriminante linéaire dans les échantillons d'estimation. Par ailleurs, l'écart type qui y est associé n'est que quelque peu plus élevé – 1,6 point de pourcentage – que celui associé au taux de bonne classification moyen du groupe 1 obtenu avec les modèles d'analyse discriminante linéaire. Ajoutons aussi que le taux de bonne classification moyen des entreprises ayant commis une fraude financière est habituellement supérieur à 60,0 %, toujours dans les échantillons d'estimation, pour les coûts relatifs de mauvaise classification supérieurs à 10:1. De plus, pour des coûts relatifs de mauvaise classification réalistes (i.e. 20:1 et 30:1), il varie généralement entre 65,0 % et 70,0 %. Nous constatons que le taux de bonne classification moyen des arbres de classification pour le groupe 1 est, à quelques exceptions près, substantiellement supérieur à celui des modèles d'analyse discriminante linéaire. Cependant, les écarts types sont souvent élevés - en fait, sept fois sur vingt l'écart type est supérieur à 10,0 % - et plus importants que ceux du groupe 1 de l'analyse discriminante linéaire, ce qui signifie que la performance est, en général, moins stable, pour ce groupe, qu'avec cette dernière méthode dans les différents échantillons d'estimation. Par ailleurs, élever (abaisser) la probabilité *a priori* de fraude augmente (diminue) un peu, en général, le taux de bonne classification moyen du groupe 1. De plus, une hausse (baisse) du coût relatif de mauvaise classification a un effet positif (négatif) important sur le taux de bonne classification moyen des entreprises ayant commis une fraude comptable.

De son côté, le taux de bonne classification moyen des entreprises incluses dans le groupe 2 est similaire d'une méthode à l'autre dans le scénario de base. De plus, l'écart type du taux de bonne classification du partitionnement récursif n'est qu'un peu plus élevé que celui des modèles d'analyse discriminante linéaire. Pour l'ensemble des hypothèses, le taux de bonne classification moyen des entreprises de contrôle est très élevé (de 85,6 % à 100,0 %). Sauf dans un cas, ils sont semblables à ceux obtenus à partir de l'analyse discriminante linéaire. La performance est aussi très stable d'un échantillon d'estimation à l'autre, comme dans le cas de l'analyse discriminante linéaire. Enfin, une augmentation (diminution) de la probabilité *a priori* de fraude abaisse (relève) un peu le taux de bonne classification moyen des entreprises de contrôle. De son côté, une variation à la hausse (baisse) du coût relatif de mauvaise classification se

traduit par une réduction (augmentation) du taux de bonne classification moyen du groupe 2.

Nous remarquons que la détérioration de la performance des arbres de classification est minime hors-échantillon, peu importe l'ensemble d'hypothèses utilisé. Ce n'était pas le cas, précédemment, avec les modèles d'analyse discriminante linéaire. À peu de choses près, les mêmes constatations s'appliquent dans les échantillons de validation au sujet des taux de bonne classification et de leur écart type que dans les échantillons d'estimation. Ainsi, pour presque tous les ensembles de probabilités *a priori* et de coût relatif de mauvaise classification, les taux de bonne classification moyens du groupe 1, du groupe 2 et globaux obtenus à partir du partitionnement récursif sont supérieurs à ceux obtenus à partir des modèles d'analyse discriminante linéaire dans les échantillons de validation. Dans le scénario de base, le taux de bonne classification global se situe, en moyenne, à 78,4 %, contre 61,6 % pour l'analyse discriminante linéaire. Le taux est aussi plus stable avec le partitionnement récursif qu'avec l'analyse discriminante linéaire. Pour toutes les hypothèses, la différence de performance est toujours d'au moins dix points de pourcentage en faveur des arbres de classification dans le cas des taux de bonne classification globaux moyens. De plus, treize fois sur dix-huit, l'écart type du taux de bonne classification global moyen des modèles de partitionnement récursif est inférieur à celui du taux de bonne classification global moyen des modèles d'analyse discriminante linéaire. Finalement, les changements de la probabilité *a priori* de fraude et du coût relatif de mauvaise classification ont une influence comparable à ceux dans les échantillons d'estimation. D'ailleurs, il en est de même pour les groupes 1 et 2.

Le taux de bonne classification des entreprises ayant commis une fraude dans leurs états financiers s'élève à 67,4 % dans le scénario de base. Il s'agit d'une différence marquée avec l'analyse discriminante linéaire (+64,1 %). De plus, l'écart type du taux de bonne classification du groupe 1 n'est que faiblement plus élevé pour le partitionnement récursif (10,1 % comparativement à 9,4 % pour l'analyse discriminante linéaire). La différence de performance est encore plus importante, en général, pour le groupe d'entreprises ayant commis une fraude comptable. Cependant, l'écart type des taux de

bonne classification moyens du groupe 1 des arbres de classification est habituellement supérieur à celui des modèles d'analyse discriminante linéaire. Par conséquent, une efficacité accrue, hors-échantillon, est donc associée à une augmentation de la variabilité pour ce groupe avec les arbres de classification.

Enfin, les taux de bonne classification des entreprises de contrôle sont quant à eux similaires entre les deux méthodes, sauf pour les coûts relatifs les plus élevés pour lesquels ceux du partitionnement récursif sont plus élevés. Par exemple, tel est le cas dans le scénario de base : le taux de bonne classification du groupe 2 est de 89,5 % avec le partitionnement récursif et de 82,1 % avec l'analyse discriminante linéaire. Dans le cas des écart types, la situation est inversée par rapport au groupe 1 : les écarts types des arbres de classification sont, cette fois-ci, les plus faibles. Par conséquent, les taux de bonne classification dans les échantillons de validation semblent indiquer que le partitionnement récursif domine l'analyse discriminante linéaire, résultat qui n'est pas surprenant en raison du niveau de sophistication respectif des deux méthodes.

5.1.3. - Régression logistique

Dans cette partie, nous analyserons les résultats obtenus par la méthode de régression logistique. Rappelons que les taux de bonne classification suivants, tout comme ceux des réseaux de neurones - d'ailleurs, c'est la raison pour laquelle nous présentons les résultats de ces deux méthodes les uns à la suite des autres - ont été calculés en utilisant différents seuils de classification, présentés précédemment. Ainsi, les taux de bonne classification ne tiennent pas compte, contrairement à l'analyse discriminante linéaire et au partitionnement récursif, des probabilités *a priori* et des coûts de mauvaise classification. Dans un sens, c'est une des limites d'utiliser différentes méthodes, sinon de la présente étude, car il y a impossibilité de déterminer, hors de tout doute, laquelle est supérieure. Les taux de bonne classification obtenus en ayant recours à un seuil de classification égal à 0,5 constituent le scénario de base des méthodes de régression logistique et des réseaux de neurones. L'annexe 9 contient les résultats complets obtenus à partir de la méthode de régression logistique.

Au tableau 9, nous remarquons que les modèles de régression logistique permettent d'atteindre un taux de bonne classification global élevé (moyenne égale à 83,6 %) et stable (écart type égal à 2,1 %) dans les échantillons d'estimation en utilisant un seuil de classification égal à 0,5. Pour les raisons évoquées précédemment, il serait périlleux de tenter de comparer tous les taux de bonne classification et les écarts types des modèles de régression logistique avec ceux des modèles d'analyse discriminante linéaire et des arbres de classification. Néanmoins, en nous limitant à certains taux de bonne classification - ceux, principalement, des scénarios de base et les plus élevés - nous essaierons de tirer quelques conclusions utiles au sujet de l'efficacité relative des différentes méthodes. Une comparaison plus directe sera possible avec les coûts espérés de mauvaise classification. Ainsi, nous observons que le meilleur taux de bonne classification global des modèles de régression logistique est supérieur et, en général, d'une stabilité similaire, sinon plus élevée, que n'importe quel taux de bonne classification global obtenu à partir de l'analyse discriminante linéaire. Par ailleurs, ce taux est quasi identique au meilleur taux de bonne classification global moyen des arbres de classification (83,2 %). Son écart type est aussi habituellement plus faible que celui des taux de bonne classification globaux du partitionnement récursif. Parmi les cinq seuils de classification utilisés, le seuil égal à 0,5 est le meilleur, en terme du taux de bonne classification global moyen, dans les échantillons d'estimation. Non seulement il permet d'atteindre un taux de bonne classification global moyen supérieur aux autres seuils, mais l'écart type associé à ce taux est aussi le plus faible des cinq. Par exemple, le taux de bonne classification global se situe à 80,3 % en utilisant un seuil de classification égal à 0,3. Enfin, une augmentation du seuil de classification jusqu'à 0,5 permet d'accroître le taux de bonne classification global moyen. Au-delà de ce seuil, l'effet est opposé.

Dans les échantillons d'estimation, le seuil de classification du scénario de base permet de classer correctement, en moyenne, 82,9 % des entreprises ayant commis une fraude comptable. Comme pour le taux de bonne classification global, l'écart type associé à ce taux est faible. Sauf pour un ensemble d'hypothèses (probabilité *a priori* de fraude égale à 3 % et coût relatif de mauvaise classification égal à 50:1), ce taux est plus élevé, en moyenne, que tous les taux de bonne classification du groupe 1 obtenus avec l'analyse

discriminante. En général, il est aussi moins volatil. Ce taux de bonne classification est aussi, en moyenne, plus élevé et, en général, beaucoup plus stable que tous les taux de bonne classification du groupe 1 obtenus avec les arbres de classification dans les échantillons d'estimation. Par ailleurs, nous remarquons qu'en ayant recours à un seuil de classification égal à 0,3, plus d'entreprises ayant manipulé frauduleusement leurs états financiers sont classées correctement (93,2 %). Cependant, seulement 67,4 % des observations du groupe 2 sont classées dans la bonne catégorie, une diminution de 16,8 % par rapport au seuil égal à 0,5. Pour l'instant, il n'est pas possible de déterminer quel seuil entraîne le coût espéré de mauvaise classification le plus faible. Les écarts types des taux de bonne classification du groupe 1 sont faibles, en général, bien qu'ils soient variables. Plus précisément, nous constatons que l'écart type est inversement proportionnel au taux de bonne classification : l'écart type le plus faible est associé au taux de bonne classification moyen le plus élevé et vice-versa. Par ailleurs, une augmentation (diminution) du seuil a visiblement un effet négatif (positif) sur le taux de bonne classification moyen des entreprises faisant partie du groupe 1.

Par ailleurs, le seuil de classification égal à 0,5 permet de classer correctement, en moyenne, 84,2 % des entreprises de contrôle. De plus, l'écart type associé à ce taux de bonne classification est faible. Contrairement aux taux de bonne classification globaux et du groupe 1, ce taux est, à quelque exceptions près, plus faible et plus variable que ceux des modèles d'analyse discriminante linéaire et de partitionnement récursif. Nous remarquons aussi que le seuil de classification égal à 0,7 permet de classer une proportion plus élevée d'entreprises de contrôle que celui égal à 0,5 (+10,0 %), tout en permettant d'atteindre un taux de bonne classification global élevé (78,2 %). Contrairement au seuil de classification égal à 0,3, le seuil égal à 0,7 devrait donner lieu à des coûts espérés de mauvaise classification plus élevés que le seuil égal à 0,5, car il est associé à un taux d'erreur de type I plus élevé et ce sont, selon toute vraisemblance, les erreurs de type I qui sont les plus coûteuses. En ce qui concerne les écarts types des taux de bonne classification du groupe 2, les mêmes constatations que pour le groupe 1 s'appliquent. Évidemment, les relations seuils de classification-taux de bonne classification moyen sont inversés pour le groupe 2 par rapport à l'autre groupe. Toutefois, pour les deux groupes, ces observations sont valides hors-échantillon.

Dans les échantillons de validation, la performance des modèles de classification s'est considérablement détériorée. Avec le seuil de classification égal à 0,5, 68,4 % des entreprises sont classées correctement, en moyenne. De plus, ce taux est beaucoup plus variable que dans les échantillons d'estimation. Comme dans ces derniers échantillons, ce taux de bonne classification est toujours plus élevé, en moyenne, mais aussi plus variable, que ceux des modèles d'analyse discriminante linéaire. Par rapport aux taux de bonne classification globaux moyens obtenus avec le partitionnement récursif, celui-ci est plus faible et plus volatil dans la majorité des cas. Par ailleurs, nous constatons que le seuil de classification égal à 0,3 permet lui aussi d'atteindre un taux de bonne classification global moyen de 68,4 %. Ce taux est aussi plus de deux fois plus stable que celui obtenu avec un seuil égal à 0,5. L'augmentation de l'écart type est marquée pour les seuils de classification les plus élevés. Par ailleurs, contrairement aux échantillons d'estimation, le seuil de classification n'a pas, hors-échantillon, d'effet distinctif sur le taux de bonne classification global moyen.

Un peu plus de 64,0 % des entreprises ayant eu recours à une comptabilité mensongère sont classées correctement, une diminution de près de vingt points de pourcentage (18,7 points de pourcentage pour être précis), en utilisant le seuil de classification égal à 0,5 dans les échantillons de validation. L'écart type du taux de bonne classification moyen du groupe 1 est aussi substantiellement plus élevé que dans les échantillons d'estimation. Ce taux de bonne classification moyen est, en général, plus élevé que ceux obtenus avec l'analyse discriminante linéaire hors-échantillon. Cependant, ces derniers sont toujours beaucoup plus stables. De plus, ce taux est généralement plus élevé, mais plus variable que ceux atteints par les arbres de classification en ayant recours à un des trois coûts relatifs de mauvaise classification les plus faibles. Toutefois, il est inférieur ou égal, à une exception près, aux taux de bonne classification moyens du groupe 1 que le partitionnement récursif permet d'obtenir en ayant recours à un des autres coûts relatifs de mauvaise classification. Par ailleurs, nous notons qu'avec le seuil de classification égal à 0,3, 74,7 % des entreprises qui ont manipulé leurs états financiers sont classées correctement, 10,5 points de pourcentage de plus qu'avec le seuil de classification égal à 0,5. Évidemment, avec le seuil de classification égal à 0,3, seulement 62,1 % des entreprises de contrôle sont classées correctement, contre 72,6 % avec le seuil égal à 0,5.

Enfin, nous observons une augmentation très importante des écarts types. La performance est donc très instable sur les divers échantillons de validation.

Dans le scénario de base, la diminution de la performance est moins marquée pour les entreprises de contrôle. Cependant, elle est tout de même significative. Dans le scénario de base, le taux de bonne classification du groupe 2 a baissé, en moyenne, de -13,7 %. Sa variabilité est aussi substantiellement plus élevée d'un échantillon de validation à l'autre. D'ailleurs, ce constat s'applique à tous les autres taux de bonne classification de ce groupe dans les échantillons de validation. D'une manière similaire aux échantillons d'estimation, le taux de bonne classification moyen des entreprises de contrôle du scénario de base est, à quelque exceptions près, plus faible et plus variable que ceux des modèles d'analyse discriminante linéaire et de partitionnement récursif. Ainsi, *a priori*, hors-échantillon, en ne tenant pas compte des coûts de mauvaise classification, il est difficile de déterminer quel seuil - et, encore plus, quelle méthode - est la plus efficace.

5.1.4. - Réseaux de neurones

Finalement, nous allons discuter de la performance des réseaux de neurones qui est directement comparable à celle des régressions logistiques. Les résultats pour le scénario de base, dans les échantillons d'estimation et de validation, se trouve au tableau 9. La totalité des résultats est présentée en annexe (voir annexe 10).

Comme pour les régressions logistiques, le seuil de classification égal à 0,5, celui du scénario de base, procure le meilleur taux de bonne classification global moyen (79,2 %) dans les échantillons d'estimation. Ce taux est un peu inférieur à celui des régressions logistiques (83,6 %). Son écart type (8,7 %) est également plus élevé que celui des modèles de régressions logistiques (2,1 %). D'ailleurs, les écarts types sont très importants pour tous les seuils de classification. De plus, nous observons que le meilleur taux de bonne classification global des réseaux de neurones est plus élevé, en moyenne, et d'une instabilité supérieure à tous les taux de bonne classification globaux que les modèles d'analyse discriminante linéaire permettent d'atteindre. Par ailleurs, il se compare favorablement au meilleur taux de bonne classification global moyen des arbres

de classification (83,2 %). Par contre, son écart type est plus de deux fois supérieur à celui du meilleur taux global moyen du partitionnement récursif. Enfin, comme pour les régressions logistiques, hausser le seuil de classification jusqu'à 0,5 contribue à accroître le taux de bonne classification global moyen. Cependant, l'augmenter davantage a, encore une fois, l'effet contraire. D'ailleurs, nous notons que toutes les relations seuils de classification-taux de bonne classification moyen qui étaient valides pour la méthode précédente le sont aussi pour celle-ci.

Dans le scénario de base, plus des trois-quarts (75,8 %) des entreprises ayant manipulé leurs états financiers sont classées correctement, environ sept points de pourcentage de moins qu'avec les modèles de régression logistique. Toutefois, l'écart type qui est associé à ce taux de bonne classification est plus élevé d'une quinzaine de points de pourcentage que celui des régressions logistiques. À deux exceptions près dans les deux cas, ce taux de bonne classification moyen des entreprises du groupe 1 est supérieur à n'importe quel taux de bonne classification moyen obtenu avec l'analyse discriminante linéaire et le partitionnement récursif dans les arbres de classification. Par contre, encore une fois, il est beaucoup plus variable. Par ailleurs, dans les échantillons d'estimation, 92,6 % des entreprises qui ont commis une fraude sont classées correctement en utilisant un seuil de classification égal à 0,3. Ainsi, par rapport au seuil égal à 0,5, il permet une diminution substantielle du taux d'erreurs de type I (de 24,2 % à 7,4 %), mais qui s'effectue, évidemment, au prix d'une augmentation du taux d'erreurs de type II (de 17,4 % à 42,4 %). Les taux de bonne classification moyens sont similaires à ceux des régressions logistiques, sauf pour les moins bons taux, c'est-à-dire ceux obtenus en utilisant un seuil élevé pour le groupe 1 et faible pour le groupe 2. À la limite, cette différence de performance importe peu, car il est improbable que le seuil de classification optimal, c'est-à-dire celui qui minimise les coûts de mauvaise classification espérés, se situe à un extrême ou à un autre. Cependant, il est à noter que l'écart type des taux de bonne classification associés à ces seuils est beaucoup plus important que pour les autres seuils. Ainsi, les réseaux de neurones peuvent classer correctement, avec un seuil de classification égal à 0,1, par exemple, un nombre important d'entreprises de contrôle sur un échantillon d'estimation, alors qu'il peut être

médiocre sur l'échantillon suivant. Les réseaux de neurones sont donc très instables et peuvent ne pas se révéler fiables sur certains échantillons d'estimation.

De son côté, la proportion d'entreprises de contrôle bien classées n'est, dans les échantillons d'estimation, que marginalement plus faible que celle des régressions logistiques dans le scénario de base (82,6 % versus 84,2 %). Encore une fois, l'écart type du taux de bonne classification est plus élevé pour les réseaux de neurones. Tout comme pour les régressions logistiques, le taux de bonne classification du groupe 2 est, à quelque exceptions près, plus faible et plus variable que ceux des modèles d'analyse discriminante linéaire et de partitionnement récursif.

Pour tous les seuils de classification, la détérioration de la performance est marquée dans les échantillons de validation. En ayant recours au seuil de classification égal à 0,5, le taux de bonne de classification global moyen est de 56,3 %, près de 23 points de pourcentage de moins que dans les échantillons d'estimation. Cependant, l'écart type qui y est associé est inférieur. Ce taux de bonne de classification global est aussi plus faible, en moyenne, mais plus stable que celui des modèles de régression logistique. Sauf pour trois combinaisons de probabilités *a priori* et de coût relatif de mauvaise classification, tous les taux de bonne classification globaux obtenus en utilisant l'analyse discriminante linéaire sont, en moyenne, plus élevés d'une dizaine de points de pourcentage et de variabilité comparable au taux de bonne classification global moyen atteint par les réseaux de neurones avec un seuil de classification se situant à 0,5. En ce qui concerne le partitionnement récursif, la différence de performance est, en général, encore plus marquée (environ 20 points de pourcentage) en faveur de ce dernier.

À peine plus d'une entreprise sur deux du groupe 1 est, en moyenne, classée correctement en utilisant un seuil de classification égal à 0,5 dans les échantillons de validation. Plus précisément, le taux de bonne de classification du groupe 1 se situe, en moyenne, à 52,6 %, comparativement à 75,8 % dans les échantillons d'estimation. Toutefois, l'écart type est, cette fois-ci, inférieur. Ce taux est, en général, supérieur et plus stable que n'importe quel taux de bonne classification moyen du groupe 1 obtenu hors-échantillon à partir des modèles d'analyse discriminante linéaire.

Au contraire, il est inférieur et moins variable que presque tous les taux de bonne classification moyen des entreprises ayant commis une fraude comptable obtenus avec les arbres de classification. Par ailleurs, nous notons que, même si le seuil de classification égal à 0,3 est susceptible d'être associé à des coûts espérés de mauvaise classification plus faibles que celui égal à 0,5 - son taux de bonne classification global moyen est supérieur, mais, surtout, il permet de classer correctement 79,0 % des entreprises ayant commis une fraude dans leurs états financiers, contre 52,6 % pour l'autre seuil - il n'est en mesure de classer dans le groupe 2 que le tiers des entreprises de contrôle (34,7%), c'est-à-dire plus de 25 points de pourcentage de moins que pour le seuil égal à 0,5. De plus, nous notons que les taux de bonne classification sont substantiellement inférieurs à ceux des régressions logistiques pour les seuils de 0,1 à 0,5 pour le groupe 2 et de 0,5 à 0,9 pour le groupe 1. Autrement, la performance est similaire. Enfin, nous remarquons, en général, une baisse des écarts types pour le groupe 1.

Enfin, le taux de bonne classification des entreprises de contrôle est aussi plus faible et plus instable que celui des régression logistique pour tous les seuils de classification. Par exemple, dans le scénario de base, le taux de bonne classification moyen (écart type) est égal à 60,0 % (15,6 %) pour les réseaux de neurones par rapport à 72,6 % (12,6 %) pour l'autre méthode. De plus, ce taux est, en général, significativement inférieur et plus volatil que ceux obtenus avec l'analyse discriminante linéaire et les arbres de classification. Selon ces résultats préliminaires, les régressions logistiques et le partitionnement récursif seraient supérieurs aux réseaux de neurones. La comparaison avec l'analyse discriminante linéaire est quant à elle plus difficile. L'analyse des coûts espérés de mauvaise classification, à laquelle nous allons procéder dans la section suivante, devrait permettre d'arriver à des conclusions plus définitives.

5.2. - Coûts espérés de mauvaise classification

Dans cette section, nous allons présenter les coûts espérés de mauvaise classification des modèles développés à partir des quatre méthodes. Comme pour les taux de bonne classification, il s'agit de moyenne, car un coût espéré de mauvaise classification est calculé pour chaque échantillon de validation croisée (en fait, un pour chaque

échantillon d'estimation et de validation). Les écarts types sont donc, encore une fois, inclus entre parenthèses dans les tableaux.

Le coût espéré de mauvaise classification, concept développé par Dopuch, Holthausen et Leftwich (1987, cité dans Persons, 1995), se calcule ainsi :

$$CMCE = P(2|1) * P(F) * C(2|1) + P(1|2) * P(NF) * C(1|2)$$

où :

CMCE = coût de mauvaise classification espéré;

$P(1|2)$ = probabilité d'une erreur de type II (classer dans le groupe 1 une entreprise du groupe 2);

$P(2|1)$ = probabilité d'une erreur de type I (classer dans le groupe 2 une entreprise du groupe 1).

La définition de $C(1|2)$, $C(2|1)$, $P(F)$ et $P(NF)$ est inchangée. Les différentes valeurs prises par les probabilités *a priori* et les coûts de mauvaise classification ont été définies précédemment.

Le coût espéré de mauvaise classification moyen d'un modèle est comparé à celui d'une stratégie naïve qui correspond à classer toutes les entreprises dans le groupe 2 (erreur de type I égale à 100,0% et de type II, bien sûr, à zéro). Nous mettrons principalement l'accent sur le coût espéré de mauvaise classification moyen (d'un modèle) relatif à la stratégie naïve.

Par ailleurs, le scénario de base de l'analyse discriminante linéaire et du partitionnement récursif est inchangé. Cependant, celui des régressions logistiques et des réseaux de neurones l'est : il correspond maintenant à seuil de classification égal à 0,5, une probabilité *a priori* de fraude de 2 % et un coût relatif de mauvaise classification de 20:1. Le tableau 10, présentée à la page suivante, contient les coûts espérés de mauvaise

classification moyens et leur écart type des quatre méthodes pour ces scénarios dans les échantillons d'estimation et de validation.

Tableau 10 : Coûts espérés de mauvaise classification (écart type) des modèles d'analyse discriminante linéaire (ADL), de partitionnement récursif (PR), de régression logistique (RL) et de réseaux de neurones (RN) dans leur scénario de base respectif dans les échantillons d'estimation et de validation

Échantillons d'estimation				
	ADL	PR	RL	RN
M	0,254 (0,032)	0,205 (0,061)	0,223 (0,030)	0,267 (0,089)
SN	0,400 -	0,400 -	0,400 -	0,400 -
M/SN	0,634 (0,079)	0,512 (0,152)	0,558 (0,076)	0,668 (0,223)
Échantillons de validation				
	ADL	PR	RL	RN
M	0,411 (0,115)	0,234 (0,032)	0,411 (0,103)	0,581 (0,133)
SN	0,400 -	0,400 -	0,400 -	0,400 -
M/SN	1,028 (0,289)	0,584 (0,081)	1,028 (0,258)	1,454 (0,331)

Légende : M : Modèle; SN : Stratégie naïve

5.2.1. - Analyse discriminante linéaire

Nous présentons d'abord les coûts de mauvaise classification espérés des modèles d'analyse discriminante linéaire. Pour le scénario de base, les modèles d'analyse discriminante linéaire entraînent un coût espéré de mauvaise classification moyen de 0,254 dans les échantillons d'estimation, comparativement à 0,400 pour la stratégie naïve, pour un coût espéré de mauvaise classification moyen relatif à la stratégie naïve de 0,634. Ainsi, les modèles d'analyse discriminante linéaire se révèlent être, en moyenne, près de 40,0 % plus performants que la stratégie naïve avec cet ensemble d'hypothèses. De plus, nous remarquons que tous les coûts espérés de mauvaise classification relatifs à la stratégie naïve sont, en moyenne, inférieurs à un. L'écart type qui leur est associé est aussi, en général, faible. Peu importe les hypothèses utilisées, les

modèles d'analyse discriminante linéaire sont donc plus performants, en moyenne, que la stratégie naïve dans les échantillons d'estimation. Par ailleurs, nous constatons qu'une augmentation (diminution) de la probabilité *a priori* de fraude entraîne une hausse (baisse) du coût espéré de mauvaise classification moyen des modèles d'analyse discriminante linéaire proportionnellement inférieure à celle de la stratégie naïve. Par conséquent, le coût espéré de mauvaise classification moyen relatif à la stratégie naïve s'abaisse (s'élève). Il en est de même avec le coût relatif de mauvaise classification. Dans les deux cas, les relations sont aussi valides hors-échantillon.

Dans les échantillons de validation, nous observons, évidemment, une augmentation des coûts espérés de mauvaise classification moyens du modèle et de la stratégie naïve par rapport aux échantillons d'estimation. Ainsi, le coût espéré de mauvaise classification moyen relatif à la stratégie naïve est maintenant supérieur à un (1,028) dans le scénario de base. Les modèles d'analyse discriminante sont donc, en moyenne, quelque peu moins performants que la stratégie naïve en considérant une probabilité *a priori* de fraude de 2 % et un coût relatif de mauvaise classification de 20:1. Cependant, l'écart type du coût espéré de mauvaise classification est important (0,289), ce qui indique que les modèles d'analyse discriminante linéaire peuvent entraîner un coût plus faible que la stratégie naïve dans un échantillon de validation et, au contraire, plus élevé dans le suivant. Par ailleurs, le coût espéré de mauvaise classification relatif à la stratégie naïve est presque toujours supérieur à un, en moyenne, sauf pour les combinaisons de probabilités *a priori* et de coût relatif de mauvaise classification élevées (tout de même, il n'est que six fois inférieur à un). Nous notons aussi un accroissement marqué de la variabilité des résultats par rapport aux échantillons d'estimation. Par conséquent, comme nous l'avons observé avec les taux de bonne classification, il y a une détérioration significative de la performance des modèles d'analyse discriminante linéaire hors-échantillon.

5.2.2. - Partitionnement récursif

Nous continuons en présentant les coûts espérés de mauvaise classification des modèles de partitionnement récursif qui, comme pour les taux de bonne classification, se

comparent directement à ceux des modèles d'analyse discriminante linéaire. Dans les échantillons d'estimation, le coût espéré de mauvaise classification moyen des arbres de classification (0,205) est inférieur à celui des modèles d'analyse discriminante linéaire (0,254) et à celui de la stratégie naïve (0,400) pour le scénario de base. Ainsi, le coût espéré de mauvaise classification relatif à la stratégie naïve est, en moyenne, plus faible pour les modèles de partitionnement récursif (0,512) que pour ceux d'analyse discriminante linéaire (0,634). Toutefois, il est plus variable que ce dernier (écart type égal à 0,152 par rapport à 0,079). Les autres résultats indiquent que le coût espéré de mauvaise classification moyen relatif à la stratégie naïve est toujours inférieur à un et qu'en plus, il est toujours plus faible que celui des modèles d'analyse discriminante linéaire. Toutefois, les résultats sont, en général, plus variables, comme pour le scénario de base. L'effet associé à une probabilité *a priori* de fraude supérieure (inférieure) est le même que dans le cas de l'analyse discriminante linéaire. Pour sa part, une augmentation (diminution) du coût relatif de mauvaise classification a un impact positif (négatif) sur le coût espéré de mauvaise classification moyen du modèle, mais, encore une fois, il est proportionnellement moins prononcé que pour la stratégie naïve. Ainsi, la tendance du coût espéré de mauvaise classification moyen relatif à la stratégie naïve est à la baisse (hausse).

Par ailleurs, le coût espéré de mauvaise classification moyen relatif à la stratégie naïve est inférieur à un, à deux exceptions près, pour les coûts relatifs de mauvaise classification supérieurs ou égaux à 5:1 hors-échantillon. Par exemple, il est égal à 0,584 pour le scénario de base, comparativement à 1,028, comme nous l'avons vu précédemment, pour les modèles d'analyse discriminante linéaire. De plus, ce coût espéré de mauvaise classification relatif à stratégie naïve est significativement plus stable que celui des modèles d'analyse discriminante linéaire. Ces résultats sont généralisables aux autres ensembles d'hypothèses. Ainsi, le coût espéré de mauvaise classification moyen des arbres de classification est toujours inférieur à celui des modèles d'analyse discriminante linéaire et, contrairement aux résultats dans les échantillons de validation, à une exception près, il est stable. Les coûts espérés de mauvaise classification moyens et leur écart type dans les échantillons de validation nous permettent d'affirmer sans équivoque que les arbres de classification sont plus

performants que les modèles d'analyse discriminante. Par ailleurs, les variations des probabilités *a priori* et du coût relatif de mauvaise classification ont essentiellement les mêmes effets que dans les échantillons d'estimation.

5.2.3. - Régression logistique

Nous procédons maintenant à l'analyse des coûts espérés de mauvaise classification des modèles de régression logistique. En utilisant un seuil de classification égal à 0,5, une probabilité à probabilité *a priori* de fraude de 2 % et un coût relatif de mauvaise classification 20:1, les modèles de régression logistique entraînent eux aussi un coût espéré de mauvaise classification moyen relatif à la stratégie naïve inférieur à un (0,558) dans les échantillons d'estimation. De plus, en comparant les résultats des scénarios de base, nous observons que les modèles de régression logistique sont plus performants (13,7 %) et aussi stables que ceux d'analyse discriminante linéaire, mais qu'ils sont moins performants (-9,0 %) et moins instables que ceux des arbres de classification. Par ailleurs, nous constatons que le coût espéré de mauvaise classification relatif à la stratégie naïve est souvent inférieur à un pour les seuils de classification élevés, les probabilités *a priori* de fraude élevées et les coûts relatifs de mauvaise classification élevés. Pour les mêmes probabilités *a priori* et pour les seuils de classification égaux à 0,1 et 0,3, le coût espéré de mauvaise classification moyen relatif à la stratégie naïve est aussi, en moyenne, supérieur et plus variable, à quelques exceptions près dans chacun des cas, à celui des modèles d'analyse discriminante linéaire. Pour les mêmes probabilités *a priori* et pour les seuils de classification égaux à 0,5, 0,7, et 0,9, le coût espéré de mauvaise classification moyen relatif à la stratégie naïve est supérieur dans environ la moitié des scénarios et inférieur dans l'autre à celui des modèles d'analyse discriminante. Il est aussi parfois plus stable, alors que d'autres fois il ne l'est pas. Par ailleurs, pour les mêmes probabilités *a priori* et ce, pour tous les seuils de classification, le coût espéré de mauvaise classification relatif à la stratégie naïve est, en moyenne, généralement supérieur et plus instable que celui équivalent obtenu avec le partitionnement récursif. Finalement, une hausse (baisse) du seuil de classification entraîne une diminution (augmentation) du coût espéré de mauvaise classification moyen des modèles de régression logistique relativement plus forte que celle de la

stratégie naïve. Ainsi, le coût espéré de mauvaise classification relatif à la stratégie naïve, en moyenne, décroît (s'accroît). La sensibilité des résultats des régressions logistiques aux autres paramètres, comme ceux, d'ailleurs, des réseaux de neurones, est identique à celle des résultats des arbres de classification. Ces résultats s'appliquent aussi hors-échantillon pour les deux méthodes.

Dans les échantillons de validation, le coût espéré de mauvaise classification relatif à la stratégie naïve est maintenant supérieur à un (1,028) dans le scénario de base. Par le fait même, il est égal à celui des modèles d'analyse discriminante linéaire dans leur propre scénario de base. De plus, les deux coûts ont un écart type similaire. Toutefois, ce coût espéré de mauvaise classification relatif à la stratégie naïve est 76,0 % plus élevé que celui obtenu avec les arbres de classification en utilisant une probabilité *a priori* de fraude de 2 % et un coût relatif de mauvaise classification de 20:1. En plus d'être supérieur, il est aussi plus variable. Par ailleurs, les coûts espérés de mauvaise classification relatifs à la stratégie naïve sont encore fréquemment inférieurs à un pour les seuils de classification élevés, les probabilités *a priori* de fraude élevées et les coûts relatifs de mauvaise classification élevés. Pour les mêmes probabilités *a priori* et pour tous les seuils de classification, les coûts espérés de mauvaise classification moyens relatifs à la stratégie naïve sont, en général, supérieurs et plus instables que ceux des modèles d'analyse discriminante linéaire. Cela n'empêche pas les modèles de régression logistique d'avoir une performance similaire et même supérieure à ceux des modèles d'analyse discriminante linéaire. Cependant, la différence de performance dépasse rarement plus de 10,0 %. (En fait, elle ne dépasse ce niveau que pour le seuil de classification égal à 0,9.) Règle générale, les résultats hors-échantillon indiquent que les modèles d'analyse discriminante linéaire sont plus performants que ceux de régression logistique. La performance de ces derniers est aussi, en général, plus instables. Pour les mêmes probabilités *a priori*, peu importe le seuil de classification, les coûts espérés de mauvaise classification relatifs à la stratégie naïve sont, en moyenne, toujours grandement supérieurs à ceux du partitionnement récursif. De plus, à une exception près, ils sont aussi beaucoup plus variables. Par conséquent, bien qu'ils semblent supérieurs aux modèles d'analyse discriminante linéaire, les modèles de régression logistique sont dominés par les arbres de classification.

5.2.4. - Réseaux de neurones

Enfin, nous complétons l'analyse des résultats avec l'étude des coûts espérés de mauvaise classification des réseaux de neurones. Comme pour les trois autres méthodes, les réseaux de neurones sont plus performants que la stratégie naïve dans le scénario de base dans les échantillons d'estimation. Cependant, le coût espéré de mauvaise classification relatif à la stratégie naïve de cette méthode (0,668) est, en moyenne, supérieur à celui des modèles d'analyse discriminante linéaire (0,634), de partitionnement récursif (0,512) et de régression logistique (0,558) dans leur scénario de base respectif. Dans tous les cas, il est aussi beaucoup plus volatil. Dans les échantillons d'estimation, les coûts espérés de mauvaise classification relatifs à la stratégie naïve sont généralement inférieurs à un pour les seuils de classification élevés, les probabilités *a priori* de fraude élevées et les coûts relatifs de mauvaise classification élevés. Pour les mêmes probabilités *a priori* et pour tous les seuils de classification, les coûts espérés de mauvaise classification relatifs à la stratégie naïve sont, en moyenne, beaucoup plus élevés pour les réseaux de neurones que pour les modèles de régression logistique. Toutefois, la différence de performance tend à s'amenuiser et peut même favoriser les réseaux de neurones pour les seuils de classification élevés, les probabilités *a priori* de fraude élevées et les coûts relatifs de mauvaise classification élevés. Par contre, la variabilité des résultats des réseaux de neurones est, en général, significativement plus grande. Pour les mêmes probabilités *a priori* et pour les seuils de classification égaux à 0,1 et 0,3, les coûts espérés de mauvaise classification relatifs à la stratégie naïve sont, en moyenne, substantiellement plus élevés et plus instables que ceux des modèles d'analyse discriminante. Pour les mêmes probabilités *a priori* et pour les seuils de classification égaux à 0,5, 0,7 et 0,9, la différence de performance est réduite. Les réseaux de neurones sont même quelques fois un peu plus performants que les modèles d'analyse discriminante linéaire. Toutefois, les coûts espérés de mauvaise classification relatifs à la stratégie naïve sont toujours aussi volatils. Pour les mêmes probabilités *a priori* et pour tous les seuils de classification, les coûts espérés de mauvaise classification moyens relatifs à la stratégie naïve des modèles de partitionnement récursif sont inférieurs et plus stables, à quelques exceptions près dans ce dernier cas, que ceux des réseaux de neurones.

Similairement aux taux de bonne classification, le coût espéré de mauvaise classification relatif à la stratégie naïve des réseaux de neurones s'est détérioré, en moyenne, dans les échantillons de validation dans le scénario de base. Il est maintenant égale à 1,454 et son écart type se situe quant à lui à 0,331. Les arbres de classification sont donc les seuls à être plus performants hors-échantillon que la stratégie naïve dans le scénario de base de chacune de ces méthodes. Contrairement aux échantillons d'estimation, les coûts espérés de mauvaise classification relatifs à la stratégie naïve sont seulement quelque fois inférieurs à un pour les seuils de classification élevés, les probabilités *a priori* de fraude élevées et les coûts relatifs de mauvaise classification élevés, reflétant, par le fait même, la chute des taux de bonne classification. Pour tous les seuils de classification, sauf celui égal à 0,9, les coûts espérés de mauvaise classification relatifs à la stratégie naïve sont, en moyenne, significativement plus élevés et instables que ceux des modèles de régression logistique. Pour le seuil de classification égal à 0,9, la différence de performance est plus faible. Pour certains ensembles d'hypothèses, les réseaux de neurones sont mêmes plus performants que les régressions logistiques. Dans tous les cas, le coût espéré de mauvaise classification relatif à la stratégie naïve est plus stable avec les réseaux de neurones avec le seuil de classification de 0,9. Cependant, étant donné que le coût espéré de mauvaise classification minimal des modèles n'est généralement pas atteint en utilisant un seuil de classification aussi élevé, nous pouvons affirmer que les régressions logistiques sont une méthode plus performante et plus stable, hors-échantillon, que les réseaux de neurones dans le contexte particulier de notre étude. Par ailleurs, pour les mêmes probabilités *a priori* et pour tous les seuils de classification, les coûts espérés de mauvaise classification relatifs à la stratégie naïve des réseaux de neurones sont, en moyenne, largement supérieurs à ceux des modèles d'analyse discriminante linéaire. De plus, en général, ils sont aussi plus variables. Dans le cas du partitionnement récursif, la différence de performance est encore plus importante, en faveur de ce dernier, bien sûr.

Les coûts espérés de mauvaise classification relatifs à la stratégie naïve dans les échantillons de validation nous permettent de formuler quelques constatations. En premier lieu, il appert que le partitionnement récursif est une méthode plus performante que l'analyse discriminante linéaire, la régression logistique et les réseaux de neurones.

Pour la presque totalité des hypothèses, il permet aussi d'obtenir des résultats plus stables d'un échantillon de validation croisée à l'autre que les trois autres méthodes. Par ailleurs, le partitionnement récursif est plus performant que la stratégie naïve à laquelle nous avons eu recours. Ces résultats indiquent qu'un modèle de détection de la fraude comptable développé à partir de cette technique pourrait être utile aux vérificateurs externes, aux investisseurs et aux agences de réglementation dans leur champ d'activités particulier. En second lieu, l'analyse discriminante linéaire permet, en général, d'atteindre un niveau de performance plus élevé et moins variable que la régression logistique et que les réseaux de neurones. Ces résultats sont surprenants pour deux raisons. D'une part, tel que nous l'avons établi précédemment, les deux hypothèses à la base du fonctionnement de l'analyse discriminante linéaire sont ne sont pas respectées dans notre étude. D'autre part, les réseaux de neurones sont une technique, *a priori*, beaucoup plus sophistiquée. Néanmoins, ils permettent d'obtenir de bons résultats, en général, pour les échantillons de grande taille. Notre échantillon contient 190 observations, ce qui, visiblement, n'est pas suffisant pour éviter le phénomène du *data mining*. En dernier lieu, il semble que la régression logistique soit elle aussi plus performante que les réseaux de neurones. Les modèles construits à partir de ces derniers seraient donc, en général, les moins performants et les plus instables.

CONCLUSION

Nous avons développé une variété de modèles de détection de la fraude comptable. Les entreprises ayant commis une fraude ont été obtenues par le biais des *Accounting and Auditing Enforcement Releases*, émis par la *Securities and Exchange Commission*, aux États-Unis, entre octobre 1999 et décembre 2004.

Les variables prédictives utilisées dans la conception des modèles étaient comprises dans trois catégories : les variables financières, mesurant des aspects d'une entreprise tels que la composition de ses actifs, sa croissance et sa liquidité et qui comprennent la majorité des variables; les variables de gouvernance, reliées à différents mécanismes (conseil d'administration, comité de vérification, *etc.*) qui peuvent permettre de prévenir la perpétration d'une fraude; enfin, les variables liées à des motivations pour commettre une fraude. Cet ensemble de variables prédictives est unique à notre étude. De plus, quelques-unes des variables qui y sont incluses n'ont jamais été utilisées pour développer un modèle de détection de la fraude comptable (par exemple, les ratios d'évaluation mesurant les opportunités de croissance).

Quatre méthodes de classification ont été utilisées pour construire les modèles : l'analyse discriminante linéaire, la régression logistique, le partitionnement récursif, qui est une méthode nouvelle à ce champ de recherche, et les réseaux de neurones. Afin de nous assurer de la validité des résultats, nous avons eu recours à la validation croisée. Par ailleurs, la sensibilité des résultats aux hypothèses utilisées a été vérifiée, lors du développement des modèles, en supposant différentes probabilités *a priori* de fraude et coûts de mauvaise classification. Cependant, ces hypothèses n'ont pu être incorporées pour calculer les taux de bonne classification des modèles de régression logistique et de réseaux de neurones. Ainsi, afin de procéder à une comparaison plus directe et une analyse plus exhaustive des résultats, nous avons aussi calculé le coût espéré de mauvaise classification de chaque modèle.

Trois conclusions principales sont à tirer de cette étude. La première, qui est probablement la plus importante, concerne la prévisibilité de la fraude comptable.

Comme nous pouvions nous y attendre, sur la base des études antérieures, nos résultats démontrent que la fraude comptable est un phénomène prévisible ou, encore, détectable à l'aide d'un modèle de classification. Pour appuyer cette affirmation, mentionnons que, dans les échantillons de validation, les taux de bonne classification moyens obtenus avec le partitionnement récursif indiquent qu'il est possible de détecter près de 70,0 % des entreprises ayant commis une fraude comptable et, en même temps, près de 90,0 % des entreprises de contrôle. Qui plus est, ces résultats ont été obtenus en utilisant un ensemble d'hypothèses « réalistes » (probabilité *a priori* de fraude de 2 % et coût relatif de mauvaise classification de 20:1).

La seconde conclusion a trait à l'efficacité des méthodes. En ayant recours aux taux de bonne classification, nous constatons que, règle générale, les arbres de classification sont, hors-échantillon, plus efficaces, en moyenne, que les modèles d'analyse discriminante linéaire. Ils sont aussi, en général, plus stables. Le partitionnement récursif semble aussi supérieur à la régression logistique et aux réseaux de neurones, toutefois, de manière moins définitive. Utiliser les coûts espérés de mauvaise classification relatifs à la stratégie naïve, hors-échantillon, permet de renforcer les conclusions précédentes. En effet, pour presque tous les ensembles d'hypothèses, les arbres de classification permettent d'atteindre un niveau de performance plus élevé ou, en d'autres mots, des coûts espérés de mauvaise classification relatifs à la stratégie naïve inférieurs à ceux des modèles d'analyse discriminante, de régression logistique et de réseaux de neurones. Les résultats des arbres de classification sont aussi moins volatils que ceux des autres méthodes sur les différents échantillons de validation croisée. Ainsi, nos résultats indiquent que le partitionnement récursif est une méthode plus efficace que l'analyse discriminante linéaire, la régression logistique et les réseaux de neurones dans le contexte de la détection de la fraude comptable.

La troisième conclusion porte sur les variables prédictives les plus utiles pour détecter une fraude contenue dans les états financiers. En effet, parmi les vingt-huit variables auxquelles nous avons eu recours pour développer les modèles, certaines se sont révélées plus importantes que d'autres. Six variables se sont particulièrement démarquées des autres : elles mesurent des aspects d'une entreprise tels que sa croissance (croissance des

ventes aux cours des deux derniers exercices financiers), la qualité de ses bénéfices (ratios réserves totales sur actifs totaux et différence entre les bénéfices et les flux monétaires liés aux opérations sur actifs totaux), la composition de ses actifs (ratios comptes à recevoir sur actifs totaux et inventaires sur actifs totaux) et sa productivité (rotation du capital). Utilisées à l'extérieur du cadre d'un modèle de classification, ces variables peuvent potentiellement indiquer si une entreprise a commis une fraude comptable. En ce sens, elles peuvent être associées à des facteurs de risques (*red flags*).

Diverses avenues de recherche peuvent être empruntées pour améliorer l'étude. Tout d'abord, bien qu'elle se compare favorablement à la taille de n'importe quel échantillon utilisé dans une étude précédente portant sur la fraude comptable, la taille de notre échantillon n'en est pas moins limitée à moins d'une centaine d'observations de chaque groupe. Il est possible d'accroître le nombre d'entreprises ayant commis une fraude dans leurs états financiers en ayant recours à de nouvelles sources de données ou encore en allongeant la période considérée. Par ailleurs, utiliser un plus grand nombre d'entreprises de contrôle pourrait permettre de tester l'effet de différentes hypothèses d'échantillonnage, recréant ainsi, en partie, à la manière de Feroz et al. (2000), les conditions dans la population.

Ensuite, il est possible d'utiliser un ensemble de variables prédictives plus varié. D'une part, le nombre de variables de gouvernance peut être accru en utilisant des variables portant sur l'indépendance, la formation académique ou encore l'expérience professionnelle des administrateurs d'une entreprise. D'autre part, nous avons vu au cours de la revue de la littérature que certains auteurs (Dunn, 2004; Summers et Sweeney, 1998) ont établi des liens entre des caractéristiques des initiés et la fraude dans les états financiers. Tout en permettant d'améliorer potentiellement les résultats, l'inclusion de ces variables risque, toutefois, de réduire la taille de l'échantillon. En effet, les données sur les transactions d'initiés sont peu nombreuses. Et encore faut-il que les transactions soient rapportées à l'agence de réglementation. Il y a donc un équilibre évident à trouver entre le nombre et la diversité des variables prédictives et la taille de l'échantillon.

Par ailleurs, il pourrait être pertinent de procéder à une pré-sélection des variables, dans la mesure où elle permettrait, évidemment, d'améliorer les résultats. Cette sélection peut être effectuée « manuellement » (par exemple, inclure dans les modèles seulement les variables dont la moyenne est statistiquement différente d'un groupe à l'autre). Un algorithme génétique pourrait aussi être utilisé pour sélectionner les meilleures variables prédictives.

Enfin, l'objectif premier de l'étude n'étant pas de déterminer la configuration optimale des modèles, nous nous sommes donc limités aux spécifications de base des logiciels. En ce sens, le partitionnement récursif et les réseaux de neurones pourraient vraisemblablement bénéficier d'un ajustement de leurs paramètres afin de les adapter aux caractéristiques de ce type de problème. Cependant, ce processus d'ajustement se fait souvent par essai et erreur. Par conséquent, il peut être long. De plus, il ne provoque pas nécessairement une amélioration des résultats.

BIBLIOGRAPHIE

AI ACCESS (2005). *Régression logistique (LR)* [en ligne], Les Ulis, France, AI Access, [référence du 5 juin 2005], 1 p.

<http://www.aiaccess.net/f_reg/log.htm>.

ALTMAN, Edward I. (1968). « Financial Ratios, Discriminant Analysis and the Prediction of Corporate Bankruptcy », *Journal of Finance*, septembre, p. 589-609.

ALTMAN, Edward I., Robert B. AVERY, Robert A. EISENBEIS et Joseph F. SINKEY JR (1981). *Application of Classification Techniques in Business, Banking and Finance*, Ai Jai Press, Greenwich, CN, États-Unis, p. 33-57.

BEASLEY, Mark S. (1996). « An Empirical Analysis of the Relation Between the Board of Director Composition and Financial Statement Fraud », *The Accounting Review*, vol. 17, n° 4, (octobre), p. 443-465.

BEASLEY, Mark S., Joseph V. CARCELLO et Dana R. HERMANSON (1999). « Fraudulent Financial Reporting : 1987-1997 : An Analysis of US Public Companies », Committee of Sponsoring Organizations of the Treadway Commission, Washington, D.C., États-Unis, 67 p.

BEASLEY, Mark S., Joseph V. CARCELLO, Dana R. HERMANSON et Paul D. LAPIDES (2000). « Fraudulent Financial Reporting : Consideration of Industry Traits and Corporate Governance Mechanisms », *Accounting Horizons*, vol. 14, n° 4 (décembre), p. 441-454.

BELL, Timothy B. et Joseph V. CARCELLO (2000). « A decision Aid for Assessing the Likelihood of Fraudulent Financial Reporting », *Auditing : A Journal of Practice & Theory*, vol. 19, n° 1 (printemps), p. 169-184.

BENEISH, Messod D. (1997). « Detecting GAAP violation : Implications for Assessing Earnings Management Among Firms with Extreme Financial Performance », *Journal of Accounting and Public Policy*, vol. 16 (automne), p. 271-309.

BENEISH, Messod D. (1999). « The Detection of Earnings Manipulation », *Financial Analysts Journal*, vol. 55, n° 5 (septembre/octobre), p. 24-36.

BOSSARD, Kelly E. et Steven G. BLUM (2004). « Reading the Red Flags of Fraud », *Pennsylvania CPA Journal*, vol. 74, n° 4 (hiver) p. 26-29.

BREIMAN, Leo, Jerome H. FRIEDMAN, Richard A. OLSHEN et Charles J. STONE (1984). *Classification and Regression Trees*, Wadsworth International Group, Belmont, CA, États-Unis, p. 18-58.

BRILOFF, Abraham J. (2001). « Garbage In/Garbage Out : A Critique of Fraudulent Financial Reporting : 1987–1997 (The COSO Report) and the SEC Accounting Regulatory Process », *Critical Perspectives on Accounting*, vol. 12, n° 2 (avril), p. 125-148.

CALDERON, Thoma G. et John J. CHEH (2002). « A Roadmap for Future Neural Networks Research in Auditing and Risk Assessment », *International Journal of Accounting Information Systems*, vol. 3, n° 4 (décembre), p. 203-236.

DECHOW, Patricia M., Richard G. SLOAN et Amy P. SWEENEY (1996). « Causes and Consequences of Earnings Manipulation : An Analysis of Firms Subject to Enforcement Actions by the SEC », *Contemporary Accounting Research*, vol. 13, n° 1 (printemps), p. 1–36.

DEFOND, Mark L. et James JIAMBALVO (1991). « Incidence and Circumstances of Accounting Errors », *The Accounting Review*, vol. 66, n° 3 (juillet), p. 643-655.

DUNN, Paul (2004). « The Impact of Insider Power on Fraudulent Financial Reporting », *Journal of Management*, vol. 30, n° 3 (juin), p. 397-412.

EINING, Martha M., Donald R. JONES et James K. LOEBBECKE (1997). « Reliance on Decision Aids : An Examination of Auditors' Assessment of Management Fraud », *Auditing : A Journal of Practice & Theory*, vol. 16, n° 2 (automne), p. 1-19.

FANNING, Kurt M. et Kenneth O. COGGER (1998). « Neural Network Detection of Management Fraud Using Published Financial Data », *International Journal of Intelligent Systems in Accounting, Finance and Management*, vol. 7, n° 1, p. 21–41.

FEROZ, Ehsan H., Kyungjoo PARK et Victor S. PASTENA (1991). « The Financial and Market Effects of the SEC's Accounting and Enforcement Releases », *Journal of Accounting Research*, vol. 29, supplément, p. 107–142.

FEROZ, Ehsan Habib, Taek Mu KWON, Victor S. PASTENA et Kyungjoo PARK (2000). « The Efficacy of Red Flags in Predicting the SEC's Targets : An Artificial Neural Networks Approach », *International Journal of Intelligent Systems in Accounting, Finance and Management*, vol. 9, n° 3 (septembre), p. 145-157.

GREEN, Brian Patrick et Jae Hwa CHOI (1997). « Assessing the Risk of Management Fraud Through Neural Network Technology », *Auditing : A Journal of Practice & Theory*, vol. 16, n° 1 (printemps), p. 14-29.

GREEN, Brian Patrick et Thomas G. CALDERON (1994). « Using Real-World Cases to Illustrate the Power of Analytical Procedures », *Journal of Accounting Education*, vol. 12, n° 3 (été), p. 245-268.

GROVE, Hugh et Tom COOK (2004). « Lessons for Auditors : Quantitative and Qualitative Red Flags », *Journal of Forensic Accounting*, vol. 5, n° 1 (juin), p. 131-146.

KAMINSKI, Kathleen A. et T. Sterling WETZEL (2004). « Financial Ratios and Fraud : An Exploratory Study Using Chaos Theory », *Journal of Forensic Accounting*, vol. 5, n° 1 (juin), p. 147-171.

KERWIN, Richard J. (1995), « Financial Statement Fraud », *The Secured Lender*, vol. 51, n° 2, (mars/avril), p. 36-42.

KWON Taek Mu et Ehsan H. FEROZ (1996). « A Multilayered Perceptron Approach to the Prediction of the SEC's Investigation Targets », *IEEE Transactions on Neural Networks*, vol. 7, n° 4 (septembre), p. 1286-1290.

LEE, Thomas A., Robert W. INGRAM et Thomas P. HOWARD (1999). « The Difference Between Earnings and Operating Cash Flow as an Indicator of Financial Reporting Fraud », *Contemporary Accounting Research*, vol. 16, n° 4 (hiver), p. 749-786.

MEDSKER, Larry, Efraim TURBAN et Robert R. Trippi (1993). *Neural Networks in Finance and Investing*, Probus Publishing Company, Chicago, IL, États-Unis, p. 3-25.

NATIONAL COMMISSION ON FRAUDULENT FINANCIAL REPORTING (1987). « Report of the National Commission on Fraudulent Financial Reporting », National Commission on Fraudulent Financial Reporting, Washington, D.C., États-Unis, 192 p.

O'CONNELL, Brendan (2001). « An analysis of Key Issues Arising from Professor A. J. Briloff's Paper entitled, "Garbage In/Garbage Out : A Critique of Fraudulent Financial Reporting : 1987-1997 (The COSO Report, 1999) The SEC Accounting Regulatory Process (AAERs)" », *Critical Perspectives on Accounting*, vol. 12, n° 2 (avril), p. 167-186.

PERSONS, Obeua S. (1995). « Using Financial Statement Data to Identify Factors Associated with Fraudulent Financing Reporting », *Journal of Applied Business Research*, vol. 11, n° 3 (été), p. 38-46.

PETERSON, Bonita K. (2004). « Education as a New Approach to Fighting Financial Crime in the USA », *Journal of Financial Crime*, vol. 11, n° 3 (février), p. 262-267.

PEZZULLO, John C. (2005). *Logistic Regression*, [en ligne], [référence du 5 juin 2005], 1 p.
< <http://members.aol.com/johnp71/logistic.html>>.

RAGOTHAMAN, Srinivasan, Jon CARPENTER et Thomas BUTTARS (1995). « Using Rule Induction for Knowledge Acquisition : An Expert Systems Approach to Evaluating Material Errors and Irregularities », *Expert Systems with Applications*, vol. 9, n° 4, p. 483-490.

REZAEI, Zabihollah (2003). « Causes, Consequences, and Deterrence of Financial Statement Fraud », *Critical Perspectives on Accounting*, article à paraître, 22 p.

SAN FRANCISCO STATE UNIVERSITY (2002). *Logistic Regression* [en ligne], [référence du 5 juin 2005], 1 p.

<<http://userwww.sfsu.edu/~efc/classes/biol710/logistic/logisticreg.htm>>.

ST. PERRE, Kent et James A. Anderson (1984). « An Analysis of the Factors Associated with Lawsuits Against Public Accountants », *The Accounting Review*, vol. 59, n° 2 (avril), p. 242-263.

STICE, James D. (1991). « Using Financial and Market Information to Identify Pre-Engagement Market Factors Associated with Lawsuits Against Auditors », *The Accounting Review*, vol. 66, n° 3 (juillet), p. 516-533.

SUMMERS, Scott L. et John T. SWEENEY (1998). « Fraudulently Misstated Financial Statements and Insider Trading : An Empirical Analysis », *The Accounting Review*, vol. 73, n° 1, p. 131-146.

UNITED STATES GENERAL ACCOUNTING OFFICE (2002). « Financial Statement Restatements : Trends, Market Impacts, Regulatory Responses, and Remaining Challenges », United States General Accounting Office, Washington, D.C., États-Unis, 263 p.

ANNEXES

ANNEXE 1. - DÉFINITION DES VARIABLES PRÉDICTIVES

Dans la présentation suivante, la mention « en t » fait référence à l'exercice financier dans lequel la fraude comptable a débuté et la mention « en t-1 », à l'exercice financier précédant celui dans lequel la fraude a débuté. Par ailleurs, les chiffres entre parenthèses correspondent aux numéros des éléments dans COMPUSTAT.

REC : comptes à recevoir en t (2) / actifs totaux en t (6)

INV : inventaires en t (3) / actifs totaux en t (6)

QUAL : $(1 - ((\text{actifs à court terme en t (4)} + \text{immobilisations en t (8)}) / \text{actifs totaux en t (6)})) / (1 - ((\text{actifs à court terme en t-1 (4)} + \text{immobilisations en t-1 (8)}) / \text{actifs totaux en t-1 (6)}))$

CROIS1 : $(\text{ventes en t (12)} / \text{ventes en t-1 (12)}) - 1$

CROIS2 : $((\text{ventes en t (12)} / \text{ventes en t-2 (12)})^{1/2}) - 1$

LIQ : actifs à court terme en t (4) / passifs à court terme en t (5)

ROUL : $(\text{actifs à court terme en t (4)} - \text{passifs à court terme en t (5)}) / \text{actifs totaux en t (6)}$

BRUT : $((\text{ventes en t-1 (12)} - \text{coût des marchandises vendues en t-1 (41)}) / \text{ventes en t-1 (12)}) / ((\text{ventes en t (12)} - \text{coût des marchandises vendues en t (41)}) / \text{ventes en t (12)})$

CB : prix d'une action ordinaire en t (199) / bénéfice par action excluant les éléments extraordinaires en t (58)

VAL : prix d'une action ordinaire en t (199) / (valeur comptable des actions ordinaires en t (60) / nombre d'actions ordinaires en t (25))

PV : prix d'une action ordinaire en t (199) / (ventes en t (12) / nombre d'actions ordinaires en t (25) t)

PFM : prix d'une action en t (199) / ((flux monétaire net lié aux opérations en t (308) + flux monétaire net lié aux investissements en t (311) + flux monétaire net lié au financement en t (313) / nombre d'actions en t (25))

ROT : ventes en t (12) / actifs totaux en t (6)

ADEQ : (compte à recevoir en t (2) / ventes en t (12)) / (compte à recevoir en t-1 (2) / ventes en t-1 (12))

Dans la formule suivante, qui est celle du ratio différence entre les bénéfices et les flux monétaires liés aux opérations, le premier terme du numérateur entre parenthèses (bénéfice avant éléments extraordinaires en t (18) + amortissement en t (14)) correspond aux bénéfices, alors que le second (bénéfice avant éléments extraordinaires en t (18) + amortissement en t (14) + ... + ((actifs à court terme en t (4) – encaisse en t (1)) – (actifs à court terme en t-1 (4) – encaisse en t-1 (1)))) correspond aux flux monétaires liés aux opérations. La formule n'est pas simplifiée afin de démontrer la construction de chacun de ses éléments.

DIFF : ((bénéfice avant éléments extraordinaires en t (18) + amortissement en t (14)) – (bénéfice avant éléments extraordinaires en t (18) + amortissement en t (14) + *equity in earnings* en t (106) + gain ou perte lié à la vente d'actifs à long terme en t (213) + impôts reportés en t (126) + ((passifs à court terme en t (5) – dette à court terme en t (34)) – (passifs à court terme en t-1 (5) – dette à court terme en t-1 (34))) + ((actifs à court terme en t (4) – encaisse en t (1)) – (actifs à court terme en t-1 (4) – encaisse en t-1 (1)))))) / actifs totaux en t-1 (6)

RES : $((\text{Actifs à court terme en } t (4) - \text{actifs à court terme en } t-1 (4)) - (\text{encaisse en } t (1) - \text{encaisse en } t-1 (1)) - (\text{passifs à court terme en } t (5) - \text{passifs à court terme en } t-1 (5)) - (\text{portion à court terme de la dette à long terme en } t (44) - \text{portion à court terme de la dette à long terme en } t-1 (44)) - (\text{impôts à payer en } t (71) - \text{impôts à payer en } t-1 (71)) - \text{amortissement en } t (14)) / \text{actifs totaux en } t (6)$

RA : bénéfice net en t (172) / actifs totaux en t (6)

RFP : bénéfice net en t (172) / fonds propres en t (216)

RCA : bénéfice net en t (172) / (nombre d'actions ordinaires en t (25) * prix d'une action ordinaire en t (199))

FOND : =1 si le président et/ou chef de la direction en t = fondateur ou co-fondateur de l'entreprise; autrement, =0.

CA : nombre d'administrateurs siégeant sur le conseil d'administration en t

PRES : =1 si le président et/ou chef de la direction = président du conseil en t; autrement, =0.

COM : =1 si l'entreprise a un comité de vérification en t; autrement, =0.

VERIF : =1 si la firme de vérification comptable en t (149) = *Big Four Auditor*; autrement, =0.

FIN1 : =1 si $\text{FreeC } t < -0,5$; autrement, =0; $\text{FreeC } t = (\text{flux monétaire net lié aux opérations en } t (308) - \text{dépenses de capital en } t-1 (128)) / \text{actifs à court terme en } t-1 (4)$

FIN2 : =1 si $\text{FreeC } t < -0,5$; autrement, =0; $\text{FreeC } t = (\text{flux monétaire net lié aux opérations en } t (308) - (\text{dépenses de capital en } t-2 (128) + \text{dépenses de capital en } t-1 (128)) / 2) / \text{actifs à court terme en } t-1 (4)$

LEV : actifs totaux en t (6) / fonds propres en t (216)

BOUR : =1 si l'entreprise est cotée sur le NASDAQ National Stock Market en t (ZLIST); autrement, =0.

ANNEXE 2. - STATISTIQUES DESCRIPTIVES

Tableau 11 : Statistiques descriptives

Variable	Groupe	Moyenne	Médiane	Écart type	Kurtose	Coef. d'asym.	Indice de normalité	Valeurs extrêmes	Stat. t (P(T<=t))
REC	1	0,21	0,19	0,12	-0,07	0,44	1	1	1,55
	2	0,18	0,18	0,11	-0,01	0,47	1	0	(0,12)
INV	1	0,17	0,15	0,15	-0,65	0,60	0	0	0,14
	2	0,17	0,13	0,17	0,15	0,95	0	1	(0,89)
QUAL	1	4,29	1,01	16,15	38,14	6,04	0	1	1,78
	2	1,34	1,04	0,97	5,89	2,40	0	2	(0,08)
CROIS1	1	1,01	0,42	2,06	20,94	4,10	0	1	4,34
	2	0,08	0,07	0,29	12,91	2,01	0	1	(0,00)
CROIS2	1	0,74	0,35	1,66	22,90	4,73	0	3	3,71
	2	0,11	0,09	0,19	2,66	0,76	0	1	(0,00)
LIQ	1	2,83	2,27	2,28	6,34	2,32	0	2	-0,78
	2	3,17	2,31	3,66	15,67	3,73	0	3	(0,44)
ROUL	1	0,31	0,34	0,25	0,01	-0,27	1	1	0,54
	2	0,29	0,33	0,28	1,75	-0,81	0	1	(0,59)
BRUT	1	1,01	1,00	0,29	10,65	1,11	0	3	-0,53
	2	1,04	0,99	0,55	27,38	0,70	0	2	(0,60)
CB	1	18,62	16,59	72,34	10,17	-1,48	0	2	0,06
	2	18,12	15,76	43,25	14,49	0,51	0	2	(0,95)
VAL	1	4,30	2,55	5,45	5,43	1,88	0	2	1,87
	2	3,03	1,95	3,75	13,03	3,20	0	2	(0,06)
PV	1	3,03	1,68	4,61	18,55	3,98	0	2	1,61
	2	2,10	1,16	3,24	16,38	3,81	0	2	(0,11)
PFM	1	72,12	20,21	302,57	10,20	1,26	0	3	1,87
	2	-98,18	-10,21	834,77	28,53	-4,19	0	2	(0,06)
ROT	1	1,07	0,99	0,67	3,42	1,63	0	4	-1,44
	2	1,22	1,08	0,72	1,79	1,23	0	2	(0,15)
ADEQ	1	1,10	1,05	0,54	8,21	2,41	0	2	0,82
	2	1,05	1,00	0,35	5,44	1,73	0	2	(0,41)
DIFF	1	-0,61	-0,19	1,73	23,98	-4,88	0	2	-3,03
	2	-0,07	-0,04	0,20	7,15	-0,06	0	1	(0,00)
RES	1	0,01	-0,01	0,17	2,05	0,29	0	1	3,88
	2	-0,09	-0,06	0,19	14,51	-3,28	0	1	(0,00)
RA	1	-0,04	0,04	0,35	18,74	-3,99	0	2	-0,12
	2	-0,04	0,05	0,36	18,27	-4,10	0	2	(0,90)
RFP	1	-0,22	0,08	1,55	34,22	-5,74	0	2	-1,28
	2	0,01	0,11	0,85	21,31	-3,21	0	1	(0,20)
RCA	1	-0,02	0,03	0,24	51,59	-6,62	0	1	-0,65
	2	0,00	0,04	0,17	6,57	-2,59	0	4	(0,52)

Tableau 11 : Statistiques descriptives (suite)

Variable	Groupe	Moyenne	Médiane	Écart type	Kurtose	Coef. d'asym.	Indice de normalité	Valeurs extrêmes	Stat. t (P(T<=t))
FOND	1	0,35	0,00	0,48	-	-	-	-	2,12
	2	0,21	0,00	0,41	-	-	-	-	(0,04)
CA	1	6,85	7,00	2,66	0,73	0,68	0	0	-0,77
	2	7,15	7,00	2,60	1,21	1,10	0	1	(0,44)
PRES	1	0,67	1,00	0,47	-	-	-	-	0,31
	2	0,65	1,00	0,48	-	-	-	-	(0,76)
COM	1	0,88	1,00	0,32	-	-	-	-	-1,57
	2	0,95	1,00	0,22	-	-	-	-	(0,12)
VERIF	1	0,79	1,00	0,41	-	-	-	-	-1,34
	2	0,86	1,00	0,35	-	-	-	-	(0,18)
FIN1	1	0,17	0,00	0,38	-	-	-	-	2,29
	2	0,06	0,00	0,24	-	-	-	-	(0,02)
FIN2	1	0,15	0,00	0,36	-	-	-	-	1,90
	2	0,06	0,00	0,24	-	-	-	-	(0,06)
LEV	1	2,20	1,89	1,27	5,98	0,29	0	1	0,37
	2	2,13	1,69	1,49	3,17	1,00	0	1	(0,71)
BOUR	1	0,47	0,00	0,50	-	-	-	-	0,29
	2	0,45	0,00	0,50	-	-	-	-	(0,77)

Légende : Indice de normalité=1 si $-1 \leq \text{Kurtose} \leq 1$ et $-0,5 \leq \text{Coefficient d'asymétrie} \leq 0,5$; autrement, =0

ANNEXE 3. – MATRICES DE CORRÉLATION

Tableau 12 : Matrice de corrélation du groupe 1

	REC	INV	QUAL	CROISI	CROISI2	LIQ	ROUL	BRUT	CB	VAL	PV	PFM	ROT	ADEQ	DIFF	RES	RA	RFP	RCA	FOND	CA	PRES	COM	VERIF	FIN1	FIN2	LEV	BOUR
REC	1,00																											
INV	0,13	1,00																										
QUAL	-0,01	-0,12	1,00																									
CROISI	-0,04	-0,08	0,09	1,00																								
CROISI2	-0,20	-0,23	0,41	0,46	1,00																							
LIQ	-0,01	0,06	0,09	0,08	0,11	1,00																						
ROUL	0,33	0,26	0,03	-0,07	0,01	0,78	1,00																					
BRUT	-0,05	0,02	-0,10	0,14	-0,10	-0,01	0,09	1,00																				
CB	0,12	0,04	-0,05	-0,07	-0,04	0,13	0,20	-0,01	1,00																			
VAL	-0,02	-0,25	0,00	0,08	0,23	0,02	0,05	-0,12	0,09	1,00																		
PV	-0,15	-0,34	0,10	0,11	0,24	0,17	0,11	-0,10	-0,04	0,79	1,00																	
PFM	0,00	-0,06	-0,03	-0,12	-0,08	-0,02	-0,04	0,02	-0,15	0,09	0,15	1,00																
ROT	0,35	0,35	-0,14	-0,09	-0,02	-0,03	0,17	0,00	0,07	-0,11	-0,29	-0,03	1,00															
ADEQ	0,11	-0,07	0,30	-0,01	0,02	0,09	0,10	-0,12	0,07	0,08	0,10	-0,03	-0,15	1,00														
DIFF	-0,04	0,07	-0,07	-0,64	-0,04	-0,19	-0,08	-0,28	0,04	0,02	-0,03	0,08	0,10	-0,42	1,00													
RES	0,29	0,32	-0,06	-0,13	-0,33	0,29	0,42	0,09	0,09	-0,16	-0,13	-0,09	0,21	0,26	-0,15	1,00												
RA	0,21	0,05	-0,10	-0,36	-0,29	0,11	0,21	0,31	0,11	-0,14	-0,15	0,04	0,34	-0,17	0,04	0,33	1,00											
RFP	0,23	0,04	-0,02	-0,41	-0,41	0,08	0,20	0,32	0,05	-0,25	-0,19	0,04	0,26	-0,02	-0,03	0,40	0,93	1,00										
RCA	0,20	0,14	-0,07	-0,13	-0,20	0,02	0,14	0,07	0,07	-0,08	-0,13	0,03	0,29	-0,10	0,07	0,28	0,40	0,29	1,00									
FOND	-0,04	-0,08	0,07	0,04	0,17	0,15	0,08	-0,12	0,09	-0,05	0,01	0,02	0,01	0,02	0,00	-0,13	-0,07	-0,10	0,03	1,00								
CA	-0,18	-0,16	-0,02	-0,24	-0,14	-0,24	-0,31	-0,09	-0,13	0,08	0,03	0,20	-0,08	-0,21	0,24	-0,03	0,16	0,14	0,07	-0,10	1,00							
PRES	0,11	0,13	-0,01	-0,30	-0,18	0,07	0,16	-0,03	0,21	-0,07	-0,11	-0,01	0,19	-0,04	0,23	0,07	0,17	0,18	0,00	0,13	0,05	1,00						
COM	-0,03	0,00	0,07	-0,32	-0,10	0,15	0,27	0,02	-0,02	0,21	0,13	0,05	-0,01	0,02	0,26	0,19	0,28	0,24	0,26	-0,08	0,42	0,10	1,00					
VERIF	0,01	-0,16	0,10	-0,24	-0,05	-0,03	-0,01	-0,05	-0,07	0,12	0,05	-0,02	0,04	-0,01	0,20	0,07	0,13	0,13	0,13	-0,11	0,39	0,03	0,46	1,00				
FIN1	-0,06	-0,01	-0,09	0,45	0,09	-0,01	-0,10	0,08	-0,03	-0,04	0,01	-0,20	-0,13	0,29	-0,45	0,12	-0,46	-0,39	-0,33	-0,09	-0,32	-0,11	-0,36	-0,32	1,00			
FIN2	-0,02	0,03	-0,09	0,40	0,10	-0,13	-0,16	0,02	-0,01	-0,01	0,01	-0,20	-0,10	0,17	-0,31	0,05	-0,46	-0,41	-0,31	-0,12	-0,31	-0,03	-0,41	-0,37	0,92	1,00		
LEV	-0,05	-0,07	-0,01	0,30	0,23	-0,32	-0,44	0,03	0,05	0,24	-0,05	0,03	-0,09	-0,14	-0,02	-0,36	-0,29	-0,38	-0,05	0,04	0,23	-0,04	0,02	0,08	0,07	0,11	1,00	
BOUR	0,14	-0,03	0,08	-0,02	0,13	0,37	0,42	-0,06	-0,06	0,16	0,23	-0,20	-0,09	0,14	-0,02	0,26	0,04	0,00	0,04	0,10	-0,16	-0,01	0,28	0,13	-0,03	-0,10	-0,22	1,00

Tableau 13 : Matrice de corrélation du groupe 2

	REC	INV	QUAL	CROIS1	CROIS2	LIQ	ROUL	BRUT	CB	VAL	PV	PFM	ROT	ADEQ	DIFF	RES	RA	RFP	RCA	FOND	CA	PRES	COM	VERIF	FIN1	FIN2	LEV	BOUR	
REC	1,00																												
INV	-0,10	1,00																											
QUAL	-0,03	-0,05	1,00																										
CROIS1	0,10	-0,14	0,06	1,00																									
CROIS2	-0,03	-0,19	0,16	0,63	1,00																								
LIQ	-0,20	0,18	0,06	0,01	-0,03	1,00																							
ROUL	0,15	0,29	0,14	0,08	-0,07	0,64	1,00																						
BRUT	0,03	0,01	-0,03	0,17	-0,04	-0,15	1,00																						
CB	-0,08	0,06	-0,02	0,16	0,17	0,16	0,09	-0,08	1,00																				
VAL	-0,03	-0,11	0,25	0,12	0,24	0,19	0,14	-0,04	-0,03	1,00																			
PV	-0,18	-0,17	0,12	-0,07	0,36	-0,04	-0,24	-0,07	0,06	0,47	1,00																		
PFM	0,03	-0,08	0,04	0,03	0,04	0,03	0,02	0,01	-0,04	-0,08	0,07	1,00																	
ROT	0,45	0,40	0,09	-0,08	-0,13	-0,22	0,14	-0,04	-0,07	-0,21	-0,41	-0,16	1,00																
ADEQ	0,02	-0,06	0,01	-0,31	-0,42	-0,09	-0,04	-0,22	-0,06	-0,01	0,04	0,01	-0,14	1,00															
DIFF	-0,01	0,09	-0,06	-0,41	-0,35	0,12	0,17	-0,04	-0,02	-0,12	-0,27	-0,05	0,23	-0,17	1,00														
RES	0,11	0,05	-0,02	0,43	0,13	0,20	0,50	-0,12	0,14	0,09	-0,39	-0,04	0,05	0,06	-0,03	1,00													
RA	0,13	-0,04	-0,01	0,29	-0,06	0,11	0,41	-0,24	0,16	-0,18	-0,67	-0,05	0,19	-0,03	0,09	0,66	1,00												
RFP	-0,01	-0,16	0,14	-0,12	0,01	0,02	0,02	-0,34	0,06	-0,44	-0,24	-0,08	0,16	0,02	0,07	0,02	0,46	1,00											
RCA	0,02	0,09	-0,20	0,45	0,17	0,08	0,31	-0,15	0,14	0,02	-0,41	-0,03	0,10	-0,18	-0,08	0,69	0,75	0,12	1,00										
FOND	0,04	0,01	0,23	0,08	0,08	0,37	0,35	-0,03	0,15	0,12	-0,02	0,05	-0,05	-0,16	-0,03	0,17	0,15	0,07	0,11	1,00									
CA	-0,17	-0,09	-0,08	0,03	-0,01	-0,20	-0,21	-0,15	0,03	0,05	-0,13	-0,18	0,00	-0,04	0,02	0,12	0,31	0,23	0,26	-0,17	1,00								
PRES	-0,18	0,05	0,15	-0,02	0,09	0,14	0,07	-0,01	0,03	0,00	0,03	-0,13	0,03	-0,01	-0,13	0,00	0,16	0,33	0,17	0,16	0,17	1,00							
COM	-0,14	0,01	-0,05	0,03	-0,12	0,09	0,12	0,04	0,07	0,12	-0,21	-0,19	-0,13	0,00	0,09	0,14	0,23	-0,10	0,12	0,01	0,27	0,03	1,00						
VERIF	0,06	-0,04	0,07	0,11	0,11	-0,11	0,07	0,06	0,00	0,10	0,00	-0,15	-0,03	-0,15	-0,02	0,10	0,09	0,02	0,08	-0,17	0,27	-0,03	0,32	1,00					
FIN1	-0,20	-0,11	-0,08	0,10	0,33	-0,16	-0,50	0,31	-0,06	0,06	0,51	0,03	-0,28	-0,13	-0,26	-0,46	-0,64	-0,32	-0,36	-0,13	-0,23	-0,08	-0,13	-0,02	1,00				
FIN2	-0,20	-0,11	-0,08	0,10	0,33	-0,16	-0,50	0,31	-0,06	0,06	0,51	0,03	-0,28	-0,13	-0,26	-0,46	-0,64	-0,32	-0,36	-0,13	-0,23	-0,08	-0,13	-0,02	1,00	1,00			
LEV	0,09	0,13	-0,24	0,28	0,12	-0,29	-0,28	0,20	-0,05	0,23	-0,09	-0,24	0,07	-0,05	-0,26	0,18	-0,01	-0,45	0,28	-0,17	0,06	-0,08	0,01	0,08	0,26	0,26	1,00		
BOUR	0,04	-0,17	0,21	0,14	0,12	0,13	0,34	-0,22	0,16	0,17	0,02	0,09	0,01	-0,01	-0,05	0,11	0,18	0,02	0,06	0,36	-0,17	-0,05	0,21	0,12	-0,24	-0,24	-0,25	1,00	

Tableau 14 : Matrice de corrélation des groupes 1 et 2

	REC	INV	QUAL	CROIS1	CROIS2	LIQ	ROUL	BRUT	CB	VAL	PV	PFM	ROT	ADEQ	DIFF	RES	RA	RFP	RCA	FOND	CA	PRES	COM	VERIF	FIN1	FIN2	LEV	BOUR	
REC	1,00																												
INV	0,01	1,00																											
QUAL	0,01	-0,08	1,00																										
CROIS1	0,01	-0,06	0,13	1,00																									
CROIS2	-0,11	-0,16	0,42	0,50	1,00																								
LIQ	-0,12	0,13	0,04	0,02	0,04	1,00																							
ROUL	0,24	0,28	0,03	-0,03	0,01	0,67	1,00																						
BRUT	0,00	0,01	-0,05	0,07	-0,06	-0,03	-0,07	1,00																					
CB	0,04	0,05	-0,04	-0,04	-0,02	0,13	0,15	-0,04	1,00																				
VAL	-0,01	-0,18	0,02	0,11	0,23	0,09	0,09	-0,07	0,05	1,00																			
PV	-0,14	-0,26	0,10	0,11	0,24	0,05	-0,04	-0,08	-0,01	0,69	1,00																		
PFM	0,03	-0,07	0,01	0,01	0,01	0,01	0,01	0,00	-0,06	0,00	0,09	1,00																	
ROT	0,38	0,37	-0,10	-0,10	-0,05	-0,14	0,14	-0,02	0,01	-0,16	-0,34	-0,13	1,00																
ADEQ	0,08	-0,06	0,26	-0,01	0,00	-0,01	0,04	-0,16	0,03	0,06	0,09	0,00	-0,15	1,00															
DIFF	-0,06	0,05	-0,09	-0,66	-0,10	-0,07	-0,05	-0,12	0,03	-0,02	-0,06	-0,01	0,11	-0,37	1,00														
RES	0,21	0,17	-0,01	0,05	-0,12	0,20	0,46	-0,06	0,10	-0,01	-0,20	-0,01	0,08	0,18	-0,15	1,00													
RA	0,17	0,00	-0,07	-0,21	-0,20	0,11	0,32	-0,06	0,12	-0,16	-0,36	-0,03	0,26	-0,11	0,04	0,49	1,00												
RFP	0,13	-0,03	-0,03	-0,38	-0,37	0,05	0,12	-0,01	0,05	-0,31	-0,21	-0,04	0,22	-0,01	-0,01	0,20	0,72	1,00											
RCA	0,12	0,11	-0,07	-0,08	-0,16	0,05	0,21	-0,04	0,09	-0,05	-0,22	-0,02	0,20	-0,12	0,06	0,42	0,54	0,25	1,00										
FOND	0,01	-0,04	0,08	0,08	0,17	0,25	0,21	-0,06	0,11	0,04	0,01	0,06	-0,03	-0,04	-0,03	0,06	0,03	-0,06	0,05	1,00									
CA	-0,18	-0,13	-0,02	-0,17	-0,11	-0,21	-0,26	-0,12	-0,07	0,06	-0,04	-0,08	-0,04	-0,14	0,18	0,03	0,24	0,17	0,14	-0,14	1,00								
PRES	-0,03	0,09	0,00	-0,19	-0,11	0,11	0,12	-0,02	0,14	-0,04	-0,05	-0,09	0,10	-0,03	0,14	0,04	0,16	0,22	0,07	0,15	0,11	1,00							
COM	-0,08	0,00	0,04	-0,28	-0,12	0,12	0,20	0,03	0,01	0,16	0,00	-0,10	-0,05	0,01	0,24	0,12	0,25	0,15	0,22	-0,06	0,35	0,06	1,00						
VERIF	0,02	-0,10	0,07	-0,19	-0,06	-0,07	0,03	0,02	-0,05	0,10	0,02	-0,11	0,02	-0,06	0,17	0,05	0,11	0,10	0,11	-0,15	0,34	0,00	0,41	1,00					
FIN1	-0,09	-0,04	-0,06	0,41	0,13	-0,09	-0,25	0,17	-0,04	0,01	0,18	-0,02	-0,20	0,17	-0,41	-0,07	-0,51	-0,38	-0,34	-0,08	-0,28	-0,09	-0,30	-0,22	1,00				
FIN2	-0,07	-0,03	-0,06	0,36	0,14	-0,14	-0,29	0,16	-0,02	0,03	0,18	-0,02	-0,18	0,09	-0,30	-0,12	-0,52	-0,39	-0,33	-0,10	-0,28	-0,05	-0,33	-0,25	0,95	1,00			
LEV	0,02	0,04	-0,02	0,22	0,16	-0,30	-0,35	0,14	0,01	0,23	-0,06	-0,16	-0,01	-0,10	-0,04	-0,04	-0,13	-0,38	0,09	-0,05	0,14	-0,06	0,01	0,07	0,15	0,17	1,00		
BOUR	0,09	-0,11	0,07	0,01	0,10	0,21	0,38	-0,15	0,03	0,17	0,14	0,01	-0,04	0,08	-0,02	0,18	0,11	0,01	0,05	0,22	-0,17	-0,03	0,24	0,12	-0,11	-0,15	-0,24	1,00	

ANNEXE 4. – ARBRES DE CLASSIFICATION DÉVELOPPÉS DANS LE SCÉNARIO DE BASE

Figure 5 : Arbre de classification développé dans le scénario de base à partir du premier échantillon de validation croisée

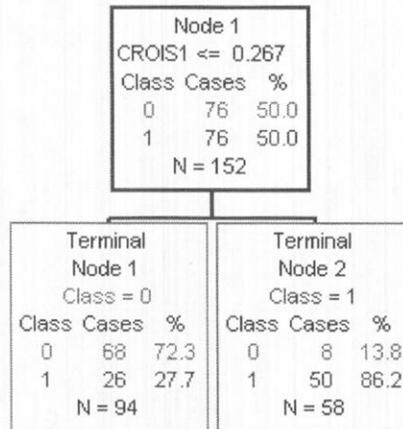


Figure 6 : Arbre de classification développé dans le scénario de base à partir du deuxième échantillon de validation croisée

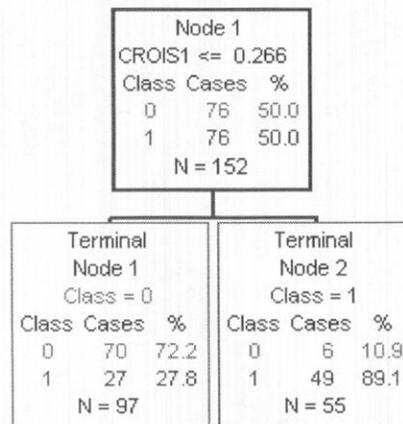


Figure 7 : Arbre de classification développé dans le scénario de base à partir du troisième échantillon de validation croisée

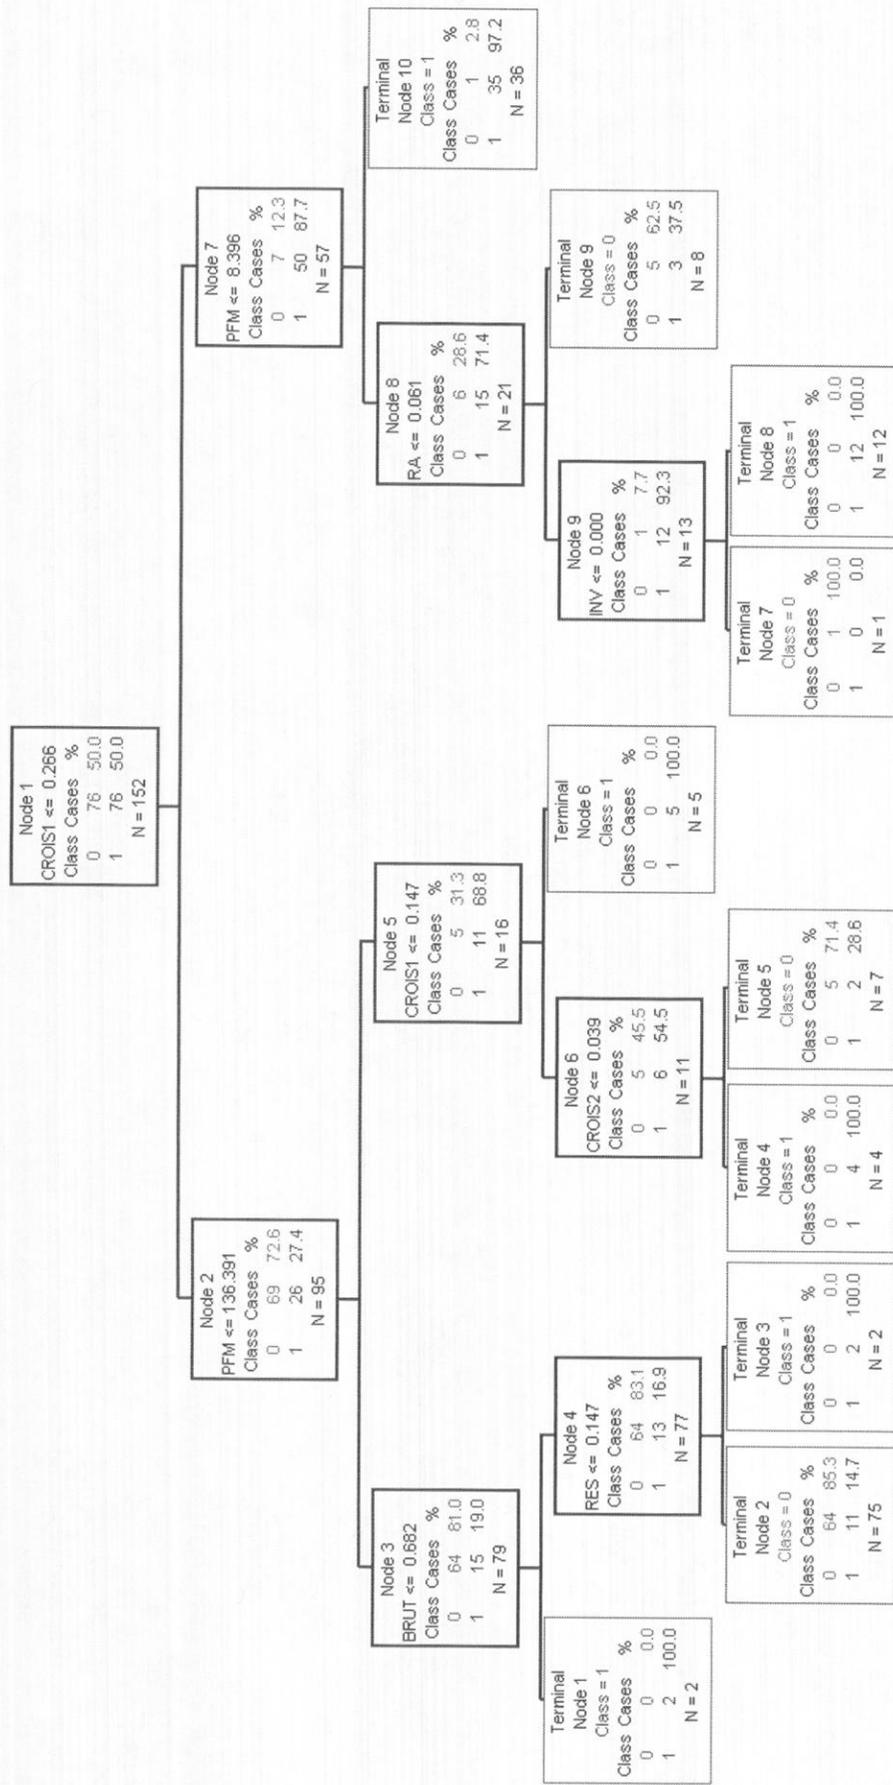


Figure 8 : Arbre de classification développé dans le scénario de base à partir du quatrième échantillon de validation croisée

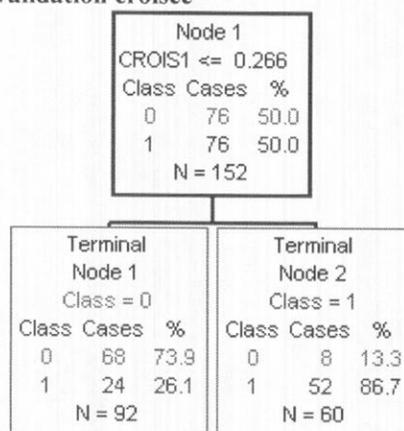
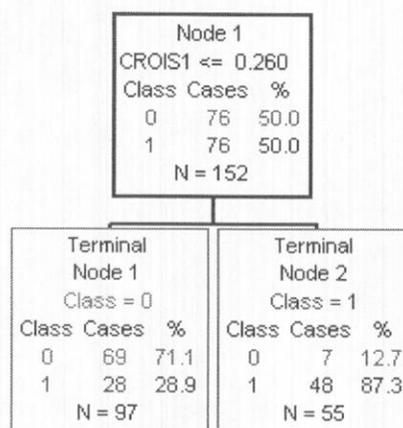


Figure 9 : Arbre de classification développé dans le scénario de base à partir du cinquième échantillon de validation croisée



ANNEXE 5. – RÉSULTATS DES MODÈLES D'ANALYSE DISCRIMINANTE LINÉAIRE

Tableau 15 : Résultats des modèles d'analyse discriminante linéaire

Coefficients						
Variable	Signe attendu	Modèle 1	Modèle 2	Modèle 3	Modèle 4	Modèle 5
Constante	-	0,22	1,56	1,69	0,65	1,68
REC	(+)	4,88	3,12	3,35	3,70	2,99
INV	(+)	2,84	2,76	2,04	2,02	2,19
QUAL	(+)	0,00	-0,02	0,01	0,01	0,02
CROIS1	(+)	0,09	-0,17	0,45	0,38	-0,02
CROIS2	(+)	0,48	0,80	0,27	0,35	0,77
LIQ	(-)	-0,02	-0,21	-0,12	-0,11	-0,12
ROUL	(-)	-1,65	-0,72	-1,11	-1,38	-1,21
BRUT	(+)	0,00	0,00	0,00	0,00	0,00
CB	(-)	1,34	-3,91	-0,14	-0,36	0,13
VAL	(-)	-0,11	0,89	0,18	0,19	0,03
PV	(-)	-2,59	-0,57	-1,37	-0,93	-1,00
PFM	(-)	-0,05	-0,41	-0,30	0,37	-0,24
ROT	(-)	-0,90	-0,72	-0,65	-0,53	-0,53
ADEQ	(+)	-0,48	-1,22	-0,94	-0,56	-0,56
DIFF	(+)	0,03	0,00	-0,06	-0,06	0,00
RES	(+)	4,31	5,41	3,45	4,28	4,84
RA	(-)	0,31	-0,07	-0,43	-0,39	-0,39
RFP	(-)	0,00	0,00	0,00	0,00	0,00
RCA	(-)	0,03	0,09	0,10	0,12	0,05
FOND	(+)	0,61	0,49	0,45	0,65	0,69
CA	(+)	0,00	-0,03	-0,03	0,00	-0,03
PRES	(+)	0,34	0,50	0,47	0,59	0,49
COM	(-)	-0,15	0,58	0,09	0,72	-0,65
VERIF	(-)	0,07	-0,17	-0,33	-0,26	0,08
FIN1	(+)	1,62	1,44	-0,80	2,68	1,34
FIN2	(+)	-1,09	-1,52	0,64	-2,15	-1,64
LEV	(+)	-0,15	-0,23	-0,16	-0,30	-0,17
BOUR	(-)	-0,47	-0,51	-0,22	-0,43	-0,10
Test du Lambda de Wilks						
Lambda		0,64	0,60	0,67	0,65	0,62
Statistique F		2,47	2,91	2,13	2,40	2,74
P(T<=t)		0,00	0,00	0,00	0,00	0,00
Test de Bartlett						
Khi ²		60,74	69,18	53,67	59,30	65,90
P(T<=t)		0,00	0,00	0,00	0,00	0,00

ANNEXE 6. – RÉSULTATS DES MODÈLES DE RÉGRESSION LOGISTIQUE

Tableau 16 : Résultats du premier modèle de régression logistique

Variable	Signe attendu	Valeur estimée	Écart type	Khi ²	Pr. > Khi ²
Constante	-	-4,47	2,75	2,64	0,10
REC	(+)	9,81	3,35	8,59	0,00
INV	(+)	5,83	2,26	6,63	0,01
QUAL	(+)	0,05	0,08	0,45	0,50
CROIS1	(+)	1,66	1,70	0,95	0,33
CROIS2	(+)	4,89	2,11	5,36	0,02
LIQ	(-)	-0,15	0,25	0,37	0,54
ROUL	(-)	0,14	2,84	0,00	0,96
BRUT	(+)	1,09	0,78	1,93	0,16
CB	(-)	0,00	0,00	0,12	0,73
VAL	(-)	0,10	0,13	0,65	0,42
PV	(-)	-0,08	0,14	0,38	0,54
PFM	(-)	0,00	0,00	2,31	0,13
ROT	(-)	-1,67	0,66	6,39	0,01
ADEQ	(+)	0,58	1,06	0,29	0,59
DIFF	(+)	0,33	0,84	0,15	0,69
RES	(+)	8,65	2,66	10,56	0,00
RA	(-)	1,48	3,00	0,24	0,62
RFP	(-)	0,23	0,94	0,06	0,80
RCA	(-)	-6,56	4,14	2,52	0,11
FOND	(+)	0,93	0,67	1,94	0,16
CA	(+)	0,07	0,13	0,33	0,57
PRES	(+)	0,54	0,63	0,73	0,39
COM	(-)	0,08	1,45	0,00	0,96
VERIF	(-)	0,19	1,00	0,04	0,85
FIN1	(+)	31,49	16 521 060,26	0,00	1,00
FIN2	(+)	-31,20	16 521 060,26	0,00	1,00
LEV	(+)	-0,07	0,29	0,06	0,81
BOUR	(-)	-1,93	0,75	6,53	0,01

Évaluation de l'ajustement du modèle :

Log Vrais.	-52,72
L.R. Khi-2	105,28
ddl (L.R. Khi ²)	28
Pr. > L.R. Khi ²	0,00
R ² (McFadden)	0,50

Tableau 17 : Résultats du deuxième modèle de régression logistique

Variable	Signe attendu	Valeur estimée	Écart type	Khi ²	Pr. > Khi ²
Constante	-	1,87	2,48	0,57	0,45
REC	(+)	4,01	3,23	1,54	0,21
INV	(+)	4,65	2,51	3,43	0,06
QUAL	(+)	-0,04	0,05	0,64	0,42
CROIS1	(+)	-1,77	1,32	1,80	0,18
CROIS2	(+)	6,96	1,74	15,99	< 0,0001
LIQ	(-)	-0,46	0,30	2,34	0,13
ROUL	(-)	-0,89	2,63	0,11	0,73
BRUT	(+)	-0,10	0,49	0,04	0,84
CB	(-)	0,00	0,01	0,00	0,98
VAL	(-)	0,10	0,16	0,37	0,54
PV	(-)	0,00	0,18	0,00	0,98
PFM	(-)	0,00	0,00	2,04	0,15
ROT	(-)	-1,03	0,52	3,90	0,05
ADEQ	(+)	-1,17	1,22	0,92	0,34
DIFF	(+)	-3,04	1,95	2,44	0,12
RES	(+)	8,69	2,80	9,61	0,00
RA	(-)	-6,24	3,44	3,29	0,07
RFP	(-)	0,58	0,90	0,42	0,52
RCA	(-)	-0,51	2,18	0,05	0,82
FOND	(+)	0,78	0,64	1,51	0,22
CA	(+)	-0,11	0,14	0,70	0,40
PRES	(+)	1,15	0,69	2,75	0,10
COM	(-)	1,22	1,24	0,98	0,32
VERIF	(-)	-0,37	0,85	0,18	0,67
FIN1	(+)	35,17	38 745 320,70	0,00	1,00
FIN2	(+)	-36,18	38 745 320,70	0,00	1,00
LEV	(+)	-0,56	0,30	3,55	0,06
BOUR	(-)	-1,79	0,77	5,38	0,02

Évaluation de l'ajustement du modèle :

Log Vrais.	-54,47
L.R. Khi-2	101,77
ddl (L.R. Khi ²)	28
Pr. > L.R. Khi ²	0,00
R ² (McFadden)	0,48

Tableau 18 : Résultats du troisième modèle de régression logistique

Variable	Signe attendu	Valeur estimée	Écart type	Khi ²	Pr. > Khi ²
Constante	-	0,23	2,01	0,01	0,91
REC	(+)	1,97	2,99	0,43	0,51
INV	(+)	4,14	2,11	3,83	0,05
QUAL	(+)	0,07	0,09	0,53	0,47
CROIS1	(+)	0,78	1,20	0,42	0,52
CROIS2	(+)	5,51	1,79	9,50	0,00
LIQ	(-)	-0,24	0,16	2,28	0,13
ROUL	(-)	-1,26	2,19	0,33	0,57
BRUT	(+)	-0,36	0,54	0,43	0,51
CB	(-)	0,00	0,01	0,13	0,72
VAL	(-)	0,15	0,12	1,60	0,21
PV	(-)	-0,14	0,15	0,80	0,37
PFM	(-)	0,00	0,00	0,39	0,53
ROT	(-)	-0,58	0,51	1,33	0,25
ADEQ	(+)	0,53	0,94	0,31	0,58
DIFF	(+)	-0,24	1,06	0,05	0,82
RES	(+)	3,60	2,38	2,29	0,13
RA	(-)	1,69	2,44	0,48	0,49
RFP	(-)	-0,50	0,65	0,60	0,44
RCA	(-)	-5,06	3,04	2,77	0,10
FOND	(+)	0,68	0,57	1,42	0,23
CA	(+)	-0,03	0,12	0,08	0,77
PRES	(+)	1,28	0,61	4,41	0,04
COM	(-)	-0,55	1,19	0,21	0,64
VERIF	(-)	-0,85	0,75	1,28	0,26
FIN1	(+)	26,21	9 894 662,18	0,00	1,00
FIN2	(+)	-26,82	9 894 662,18	0,00	1,00
LEV	(+)	-0,31	0,25	1,49	0,22
BOUR	(-)	-0,83	0,63	1,78	0,18

Évaluation de l'ajustement du modèle :

Log Vrais.	-62,75
L.R. Khi-2	85,22
ddl (L.R. Khi ²)	28
Pr. > L.R. Khi ²	0,00
R ² (McFadden)	0,40

Tableau 19 : Résultats du quatrième modèle de régression logistique

Variable	Signe attendu	Valeur estimée	Écart type	Khi ²	Pr. > Khi ²
Constante	-	-1,56	2,26	0,47	0,49
REC	(+)	6,52	3,58	3,32	0,07
INV	(+)	5,51	2,30	5,74	0,02
QUAL	(+)	0,14	0,21	0,47	0,50
CROIS1	(+)	1,68	1,22	1,90	0,17
CROIS2	(+)	6,45	1,96	10,84	0,00
LIQ	(-)	-0,33	0,27	1,42	0,23
ROUL	(-)	-1,80	2,62	0,47	0,49
BRUT	(+)	-0,62	0,55	1,24	0,27
CB	(-)	-0,01	0,01	2,33	0,13
VAL	(-)	0,21	0,14	2,19	0,14
PV	(-)	-0,35	0,18	3,89	0,05
PFM	(-)	0,00	0,00	0,66	0,42
ROT	(-)	-0,99	0,52	3,63	0,06
ADEQ	(+)	1,06	1,00	1,12	0,29
DIFF	(+)	1,71	1,35	1,61	0,20
RES	(+)	4,89	2,54	3,71	0,05
RA	(-)	-1,59	2,09	0,58	0,45
RFP	(-)	-0,07	0,60	0,01	0,91
RCA	(-)	-0,59	1,81	0,11	0,75
FOND	(+)	1,25	0,62	4,08	0,04
CA	(+)	-0,02	0,13	0,02	0,89
PRES	(+)	1,36	0,63	4,65	0,03
COM	(-)	1,11	1,29	0,74	0,39
VERIF	(-)	-0,67	0,82	0,66	0,42
FIN1	(+)	32,03	9 686 330,17	0,00	1,00
FIN2	(+)	-31,77	9 686 330,17	0,00	1,00
LEV	(+)	-0,63	0,32	3,93	0,05
BOUR	(-)	-1,26	0,64	3,85	0,05

Évaluation de l'ajustement du modèle :

Log Vrais.	-56,21
L.R. Khi-2	98,29
ddl (L.R. Khi ²)	28
Pr. > L.R. Khi ²	0,00
R ² (McFadden)	0,47

Tableau 20 : Résultats du cinquième modèle de régression logistique

Variable	Signe attendu	Valeur estimée	Écart type	Khi ²	Pr. > Khi ²
Constante	-	0,52	2,23	0,05	0,81
REC	(+)	5,92	3,14	3,55	0,06
INV	(+)	2,66	2,12	1,58	0,21
QUAL	(+)	0,04	0,06	0,44	0,51
CROIS1	(+)	1,06	1,45	0,54	0,46
CROIS2	(+)	4,69	2,02	5,40	0,02
LIQ	(-)	-0,29	0,22	1,73	0,19
ROUL	(-)	1,00	2,45	0,17	0,68
BRUT	(+)	-2,01	1,00	4,02	0,04
CB	(-)	0,00	0,00	0,09	0,76
VAL	(-)	0,01	0,13	0,00	0,95
PV	(-)	-0,04	0,15	0,08	0,78
PFM	(-)	0,00	0,00	4,90	0,03
ROT	(-)	-0,61	0,48	1,64	0,20
ADEQ	(+)	-0,04	0,93	0,00	0,97
DIFF	(+)	-0,24	0,77	0,10	0,75
RES	(+)	7,63	2,90	6,93	0,01
RA	(-)	-0,10	2,57	0,00	0,97
RFP	(-)	-0,45	0,73	0,38	0,54
RCA	(-)	-3,57	2,78	1,65	0,20
FOND	(+)	0,96	0,62	2,39	0,12
CA	(+)	0,05	0,13	0,16	0,69
PRES	(+)	0,37	0,59	0,39	0,53
COM	(-)	-0,05	1,17	0,00	0,97
VERIF	(-)	-0,12	0,79	0,02	0,88
FIN1	(+)	32,07	9 196 447,19	0,00	1,00
FIN2	(+)	-31,83	9 196 447,19	0,00	1,00
LEV	(+)	-0,20	0,28	0,51	0,48
BOUR	(-)	-0,69	0,62	1,21	0,27

Évaluation de l'ajustement du modèle :

Log Vrais.	-57,14
L.R. Khi-2	96,43
ddl (L.R. Khi ²)	28
Pr. > L.R. Khi ²	0,00
R ² (McFadden)	0,46

ANNEXE 7. – TAUX DE BONNE CLASSIFICATION ET COÛTS ESPÉRÉS DE MAUVAISE CLASSIFICATION DES MODÈLES D'ANALYSE DISCRIMINANTE LINÉAIRE

**Tableau 21 : Taux de bonne classification moyens (écart type) des modèles
d'analyse discriminante linéaire**

Probabilité *a priori* - Fraude : 1 %

Échantillon d'estimation

	Coût relatif de mauvaise classification					
	1:1	5:1	10:1	20:1	30:1	50:1
Groupe 1	4,7 (2,0)	12,6 (2,0)	21,6 (5,6)	35,5 (3,7)	42,1 (5,3)	56,1 (4,3)
Groupe 2	100,0 (0,0)	100,0 (0,0)	100,0 (0,0)	98,4 (1,1)	97,1 (0,6)	92,1 (2,5)
Global	52,4 (1,0)	56,3 (1,0)	60,8 (2,8)	67,0 (1,7)	69,6 (2,4)	74,1 (3,0)

Échantillon de validation

	Coût relatif de mauvaise classification					
	1:1	5:1	10:1	20:1	30:1	50:1
Groupe 1	5,3 (5,3)	11,6 (7,8)	20,0 (5,8)	27,4 (4,4)	35,8 (10,1)	45,3 (8,0)
Groupe 2	96,8 (7,1)	95,8 (6,9)	94,7 (6,4)	91,6 (8,0)	87,4 (10,3)	82,1 (13,7)
Global	51,1 (5,5)	53,7 (5,1)	57,4 (3,4)	59,5 (4,0)	61,6 (5,5)	63,7 (7,3)

Tableau 21 : Taux de bonne classification moyens (écart type) des modèles d'analyse discriminante linéaire (suite)

Probabilité *a priori* - Fraude : 2 %

Échantillon d'estimation

	Coût relatif de mauvaise classification					
	1:1	5:1	10:1	20:1	30:1	50:1
Groupe 1	6,6 (2,8)	21,8 (5,3)	35,8 (4,0)	49,5 (4,7)	62,1 (4,7)	76,8 (3,2)
Groupe 2	100,0 (0,0)	100,0 (0,0)	98,4 (1,1)	94,7 (1,6)	89,5 (3,8)	79,7 (1,5)
Global	53,3 (1,4)	60,9 (2,7)	67,1 (1,9)	72,1 (3,0)	75,8 (4,1)	78,3 (2,0)

Échantillon de validation

	Coût relatif de mauvaise classification					
	1:1	5:1	10:1	20:1	30:1	50:1
Groupe 1	6,3 (4,4)	20,0 (5,8)	27,4 (4,4)	41,1 (9,4)	48,4 (5,8)	68,4 (6,4)
Groupe 2	96,8 (7,1)	94,7 (6,4)	90,5 (10,1)	82,1 (13,7)	81,1 (12,1)	65,3 (12,7)
Global	51,6 4,4	57,4 3,4	58,9 4,8	61,6 5,5	64,7 5,5	66,8 5,5

Probabilité *a priori* - Fraude : 3 %

Échantillon d'estimation

	Coût relatif de mauvaise classification					
	1:1	5:1	10:1	20:1	30:1	50:1
Groupe 1	8,7 (2,9)	29,5 (5,0)	42,6 (5,5)	62,1 (4,7)	74,2 (3,6)	85,5 (3,1)
Groupe 2	100,0 (0,0)	98,9 (1,1)	96,8 (0,7)	89,2 (3,7)	81,1 (1,2)	68,7 (4,4)
Global	54,3 (1,4)	64,2 (2,7)	69,7 (2,6)	75,7 (3,9)	77,6 (2,3)	77,1 (2,2)

Échantillon de validation

	Coût relatif de mauvaise classification					
	1:1	5:1	10:1	20:1	30:1	50:1
Groupe 1	10,5 (7,4)	23,2 (8,0)	35,8 (10,1)	48,4 (5,8)	65,3 (8,8)	76,8 (4,7)
Groupe 2	96,8 (7,1)	93,7 (5,8)	87,4 (10,3)	81,1 (12,1)	70,5 (16,9)	53,7 (8,6)
Global	53,7 (5,1)	58,4 (5,1)	61,6 (5,5)	64,7 (5,5)	67,9 (5,7)	65,3 (4,7)

Tableau 22 : Coûts espérés de mauvaise classification moyens (écart type) des modèles d'analyse discriminante linéaire

Échantillon d'estimation

Coût d'erreur		Probabilité <i>a priori</i> - Fraude								
		1 %			2 %			3 %		
		Type I	Type II	M	SN	M/SN	M	SN	M/SN	M
1	1	0,010 (0,000)	0,010 -	0,953 (0,020)	0,019 (0,001)	0,020 -	0,934 (0,028)	0,027 (0,001)	0,030 -	0,913 (0,029)
5	1	0,044 (0,001)	0,050 -	0,874 (0,020)	0,078 (0,005)	0,100 -	0,782 (0,053)	0,116 (0,014)	0,150 -	0,773 (0,095)
10	1	0,078 (0,006)	0,100 -	0,784 (0,056)	0,144 (0,011)	0,200 -	0,719 (0,054)	0,203 (0,015)	0,300 -	0,676 (0,051)
20	1	0,145 (0,010)	0,200 -	0,723 (0,051)	0,254 (0,032)	0,400 -	0,634 (0,079)	0,332 (0,060)	0,600 -	0,553 (0,100)
30	1	0,202 (0,011)	0,300 -	0,674 (0,038)	0,331 (0,063)	0,600 -	0,551 (0,105)	0,416 (0,043)	0,900 -	0,462 (0,047)
50	1	0,298 (0,040)	0,500 -	0,596 (0,079)	0,430 (0,040)	1,000 -	0,430 (0,040)	0,521 (0,050)	1,500 -	0,347 (0,033)

Échantillon de validation

Coût d'erreur		Probabilité <i>a priori</i> - Fraude								
		1 %			2 %			3 %		
		Type I	Type II	M	SN	M/SN	M	SN	M/SN	M
1	1	0,041 (0,070)	0,010 -	4,074 (7,020)	0,050 (0,069)	0,020 -	2,484 (3,466)	0,057 (0,069)	0,030 -	1,916 (2,284)
5	1	0,086 (0,068)	0,050 -	1,718 (1,359)	0,132 (0,061)	0,100 -	1,316 (0,613)	0,177 (0,058)	0,150 -	1,177 (0,386)
10	1	0,132 (0,062)	0,100 -	1,321 (0,619)	0,238 (0,097)	0,200 -	1,191 (0,483)	0,315 (0,091)	0,300 -	1,051 (0,303)
20	1	0,229 (0,077)	0,200 -	1,143 (0,385)	0,411 (0,115)	0,400 -	1,028 (0,289)	0,493 (0,107)	0,600 -	0,822 (0,178)
30	1	0,318 (0,093)	0,300 -	1,059 (0,309)	0,495 (0,108)	0,600 -	0,825 (0,180)	0,599 (0,113)	0,900 -	0,665 (0,126)
50	1	0,451 (0,135)	0,500 -	0,902 (0,269)	0,656 (0,107)	1,000 -	0,656 (0,107)	0,797 (0,104)	1,500 -	0,531 (0,069)

Légende : M : Modèle; SN : Stratégie naïve.

ANNEXE 8. – TAUX DE BONNE CLASSIFICATION ET COÛTS ESPÉRÉS DE MAUVAISE CLASSIFICATION DES MODÈLES DE PARTITIONNEMENT RÉCURSIF

Tableau 23 : Taux de bonne classification moyens (écart type) des modèles de partitionnement récursif

Probabilité *a priori* - Fraude : 1 %

Échantillon d'estimation

	Coût relatif de mauvaise classification					
	1:1	5:1	10:1	20:1	30:1	50:1
Groupe 1	27,4 (5,4)	32,6 (15,5)	60,0 (6,8)	59,5 (11,3)	64,7 (2,5)	65,0 (1,2)
Groupe 2	100,0 (0,0)	100,0 (0,0)	99,7 (0,6)	98,2 (3,4)	91,8 (3,3)	90,8 (0,9)
Global	63,7 (2,7)	66,3 (7,7)	79,9 (3,6)	78,8 (5,4)	78,3 (1,0)	77,9 (0,6)

Échantillon de validation

	Coût relatif de mauvaise classification					
	1:1	5:1	10:1	20:1	30:1	50:1
Groupe 1	27,4 (8,6)	30,5 (8,6)	55,8 (16,1)	58,9 (15,1)	64,2 (10,1)	67,4 (6,9)
Groupe 2	98,9 (2,4)	98,9 (2,4)	93,7 (5,8)	93,7 (5,8)	90,5 (5,8)	88,4 (4,4)
Global	63,2 (4,9)	64,7 (5,1)	74,7 (8,4)	76,3 (6,7)	77,4 (3,0)	77,9 (2,4)

Tableau 23 : Taux de bonne classification moyens (écart type) des modèles de partitionnement récursif (suite)

Probabilité *a priori* - Fraude : 2 %

Échantillon d'estimation

	Coût relatif de mauvaise classification					
	1:1	5:1	10:1	20:1	30:1	50:1
Groupe 1	32,6 (15,5)	56,6 (12,8)	60,8 (12,7)	68,2 (6,3)	65,5 (2,0)	80,5 (10,5)
Groupe 2	100,0 (0,0)	99,7 (0,6)	98,2 (3,4)	92,1 (3,8)	90,5 (1,1)	85,8 (2,9)
Global	66,3 (7,7)	78,2 (6,5)	79,5 (6,1)	80,1 (4,9)	78,0 (0,8)	83,2 (3,9)

Échantillon de validation

	Coût relatif de mauvaise classification					
	1:1	5:1	10:1	20:1	30:1	50:1
Groupe 1	30,5 (8,6)	56,8 (18,0)	60,0 (16,9)	67,4 (10,1)	65,3 (9,6)	77,9 (7,8)
Groupe 2	98,9 (2,4)	93,7 (5,8)	93,7 (5,8)	89,5 (5,3)	89,5 (5,3)	80,0 (7,8)
Global	64,7 (5,1)	75,3 (9,4)	76,8 (7,8)	78,4 (3,4)	77,4 (3,0)	78,9 (1,9)

Probabilité *a priori* - Fraude : 3 %

Échantillon d'estimation

	Coût relatif de mauvaise classification					
	1:1	5:1	10:1	20:1	30:1	50:1
Groupe 1	32,6 (15,5)	56,6 (8,2)	64,7 (2,5)	65,5 (2,0)	71,6 (9,2)	78,2 8,6
Groupe 2	100,0 (0,0)	99,7 (0,6)	91,8 (3,3)	90,5 (1,1)	88,4 (2,7)	85,8 (3,0)
Global	66,3 (7,7)	78,2 (4,2)	78,3 (1,0)	78,0 (0,8)	80,0 (3,3)	82,0 (2,9)

Échantillon de validation

	Coût relatif de mauvaise classification					
	1:1	5:1	10:1	20:1	30:1	50:1
Groupe 1	30,5 (8,6)	56,8 (14,6)	64,2 (10,1)	65,3 (9,6)	70,5 (8,0)	75,8 (7,1)
Groupe 2	98,9 (2,4)	93,7 (5,8)	90,5 (5,8)	89,5 (5,3)	86,3 (6,0)	80,0 (10,1)
Global	64,7 (5,1)	75,3 (7,8)	77,4 (3,0)	77,4 (3,0)	78,4 (2,2)	77,9 (3,0)

Tableau 24 : Coûts espérés de mauvaise classification moyens (écart type) des modèles de partitionnement récursif

Échantillon d'estimation

Coût d'erreur		Probabilité <i>a priori</i> - Fraude								
		1 %			2 %			3 %		
Type I	Type II	M	SN	M/SN	M	SN	M/SN	M	SN	M/SN
1	1	0,007 (0,001)	0,010 -	0,726 (0,054)	0,013 (0,003)	0,020 -	0,674 (0,155)	0,020 (0,005)	0,030 -	0,674 (0,155)
5	1	0,034 (0,008)	0,050 -	0,674 (0,155)	0,046 (0,015)	0,100 -	0,460 (0,149)	0,068 (0,015)	0,150 -	0,451 (0,099)
10	1	0,043 (0,011)	0,100 -	0,426 (0,113)	0,096 (0,036)	0,200 -	0,482 (0,182)	0,185 (0,026)	0,300 -	0,616 (0,088)
20	1	0,099 (0,034)	0,200 -	0,496 (0,171)	0,205 (0,061)	0,400 -	0,512 (0,152)	0,299 (0,009)	0,600 -	0,498 (0,016)
30	1	0,187 (0,027)	0,300 -	0,622 (0,090)	0,300 (0,010)	0,600 -	0,499 (0,016)	0,368 (0,058)	0,900 -	0,409 (0,064)
50	1	0,266 (0,009)	0,500 -	0,532 (0,018)	0,334 (0,079)	1,000 -	0,334 (0,079)	0,465 (0,101)	1,500 -	0,310 (0,067)

Échantillon de validation

Coût d'erreur		Probabilité <i>a priori</i> - Fraude								
		1 %			2 %			3 %		
Type I	Type II	M	SN	M/SN	M	SN	M/SN	M	SN	M/SN
1	1	0,018 (0,024)	0,010 -	1,768 (2,367)	0,024 (0,024)	0,020 -	1,211 (1,208)	0,031 (0,025)	0,030 -	1,035 (0,817)
5	1	0,045 (0,026)	0,050 -	0,903 (0,523)	0,105 (0,059)	0,100 -	1,051 (0,591)	0,126 (0,060)	0,150 -	0,840 (0,398)
10	1	0,107 (0,059)	0,100 -	1,067 (0,588)	0,142 (0,053)	0,200 -	0,709 (0,265)	0,199 (0,034)	0,300 -	0,664 (0,113)
20	1	0,145 (0,051)	0,200 -	0,723 (0,254)	0,234 (0,032)	0,400 -	0,584 (0,081)	0,311 (0,033)	0,600 -	0,518 (0,054)
30	1	0,201 (0,035)	0,300 -	0,671 (0,116)	0,312 (0,033)	0,600 -	0,519 (0,054)	0,398 (0,039)	0,900 -	0,442 (0,044)
50	1	0,278 (0,030)	0,500 -	0,556 (0,059)	0,417 (0,037)	1,000 -	0,417 (0,037)	0,557 (0,063)	1,500 -	0,371 (0,042)

Légende : M : Modèle; SN : Stratégie naïve.

ANNEXE 9. – TAUX DE BONNE CLASSIFICATION ET COÛTS ESPÉRÉS DE MAUVAISE CLASSIFICATION DES MODÈLES DE RÉGRESSION LOGISTIQUE

**Tableau 25 : Taux de bonne classification moyens (écart type)
des modèles de régression logistique**

Échantillon d'estimation					
	Seuil de classification				
	0,1	0,3	0,5	0,7	0,9
Groupe 1	98,2	93,2	82,9	63,7	41,3
	(0,7)	(1,7)	(2,1)	(4,7)	(6,0)
Groupe 2	39,7	67,4	84,2	92,6	98,9
	(6,0)	(4,7)	(2,5)	(0,7)	(1,1)
Global	68,9	80,3	83,6	78,2	70,1
	(3,2)	(3,0)	(2,1)	(2,5)	(3,2)
Échantillon de validation					
	Seuil de classification				
	0,1	0,3	0,5	0,7	0,9
Groupe 1	89,5	74,7	64,2	50,5	43,2
	(11,2)	(10,1)	(18,0)	(16,5)	(16,0)
Groupe 2	38,9	62,1	72,6	80,0	89,5
	(9,6)	(14,6)	(12,6)	(11,4)	(7,4)
Global	64,2	68,4	68,4	65,3	66,3
	(4,0)	(3,2)	(7,7)	(6,8)	(7,3)

Tableau 26 : Coûts espérés de mauvaise classification moyens (écart type) des modèles de régression logistique

Probabilité *a priori* - Fraude : 1 %

Échantillon d'estimation

Coût d'erreur			Seuil de classification									
			0,1		0,3		0,5		0,7		0,9	
Type I	Type II	SN	M	M/SN	M	M/SN	M	M/SN	M	M/SN	M	M/SN
1	1	0,010	0,597	59,679	0,324	32,374	0,158	15,803	0,077	7,658	0,016	1,629
		-	(0,059)	(5,930)	(0,047)	(4,653)	(0,025)	(2,451)	(0,007)	(0,734)	(0,011)	(1,113)
5	1	0,050	0,598	11,951	0,326	6,529	0,165	3,297	0,091	1,822	0,040	0,795
		-	(0,059)	(1,189)	(0,047)	(0,940)	(0,025)	(0,502)	(0,008)	(0,168)	(0,012)	(0,246)
10	1	0,100	0,598	5,984	0,330	3,299	0,173	1,734	0,109	1,093	0,069	0,691
		-	(0,060)	(0,596)	(0,048)	(0,476)	(0,026)	(0,258)	(0,010)	(0,100)	(0,014)	(0,142)
20	1	0,200	0,600	3,001	0,337	1,684	0,191	0,953	0,146	0,728	0,128	0,639
		-	(0,060)	(0,300)	(0,049)	(0,244)	(0,027)	(0,137)	(0,014)	(0,070)	(0,019)	(0,095)
30	1	0,300	0,602	2,007	0,344	1,145	0,208	0,692	0,182	0,606	0,186	0,622
		-	(0,060)	(0,201)	(0,050)	(0,167)	(0,029)	(0,097)	(0,018)	(0,061)	(0,024)	(0,081)
50	1	0,500	0,606	1,212	0,357	0,715	0,242	0,484	0,255	0,509	0,304	0,608
		-	(0,061)	(0,122)	(0,052)	(0,105)	(0,032)	(0,065)	(0,027)	(0,054)	(0,035)	(0,071)

Échantillon de validation

Coût d'erreur			Seuil de classification									
			0,1		0,3		0,5		0,7		0,9	
Type I	Type II	SN	M	M/SN	M	M/SN	M	M/SN	M	M/SN	M	M/SN
1	1	0,010	0,605	60,547	0,378	37,768	0,275	27,453	0,203	20,295	0,110	10,989
		-	(0,094)	(9,386)	(0,144)	(14,365)	(0,123)	(12,343)	(0,112)	(11,202)	(0,073)	(7,305)
5	1	0,050	0,610	12,194	0,388	7,756	0,289	5,777	0,223	4,455	0,133	2,653
		-	(0,091)	(1,815)	(0,140)	(2,798)	(0,120)	(2,395)	(0,108)	(2,169)	(0,071)	(1,416)
10	1	0,100	0,615	6,149	0,400	4,004	0,307	3,067	0,247	2,475	0,161	1,611
		-	(0,087)	(0,870)	(0,135)	(1,353)	(0,116)	(1,156)	(0,104)	(1,044)	(0,069)	(0,687)
20	1	0,200	0,625	3,127	0,426	2,128	0,343	1,713	0,297	1,485	0,218	1,089
		-	(0,080)	(0,401)	(0,126)	(0,630)	(0,109)	(0,545)	(0,098)	(0,489)	(0,067)	(0,337)
30	1	0,300	0,636	2,120	0,451	1,503	0,378	1,261	0,346	1,155	0,275	0,916
		-	(0,075)	(0,248)	(0,117)	(0,390)	(0,105)	(0,351)	(0,094)	(0,312)	(0,070)	(0,232)
50	1	0,500	0,657	1,314	0,501	1,003	0,450	0,900	0,445	0,891	0,388	0,777
		-	(0,067)	(0,135)	(0,099)	(0,199)	(0,107)	(0,213)	(0,094)	(0,188)	(0,084)	(0,167)

Tableau 26 : Coûts espérés de mauvaise classification moyens (écart type) des modèles de régression logistique (suite)

Probabilité *a priori* - Fraude : 2 %

Échantillon d'estimation

Coût d'erreur			Seuil de classification									
			0,1		0,3		0,5		0,7		0,9	
Type I	Type II	SN	M	M/SN	M	M/SN	M	M/SN	M	M/SN	M	M/SN
1	1	0,020	0,591	29,547	0,321	16,058	0,158	7,908	0,079	3,974	0,022	1,103
		-	(0,059)	(2,937)	(0,046)	(2,309)	(0,024)	(1,220)	(0,007)	(0,375)	(0,011)	(0,564)
5	1	0,100	0,592	5,924	0,327	3,266	0,172	1,718	0,109	1,085	0,069	0,690
		-	(0,059)	(0,590)	(0,047)	(0,471)	(0,026)	(0,256)	(0,010)	(0,100)	(0,014)	(0,141)
10	1	0,200	0,594	2,971	0,333	1,667	0,189	0,945	0,145	0,724	0,128	0,638
		-	(0,059)	(0,297)	(0,048)	(0,241)	(0,027)	(0,136)	(0,014)	(0,069)	(0,019)	(0,094)
20	1	0,400	0,598	1,495	0,347	0,868	0,223	0,558	0,217	0,544	0,245	0,613
		-	(0,060)	(0,150)	(0,051)	(0,127)	(0,030)	(0,076)	(0,023)	(0,057)	(0,030)	(0,074)
30	1	0,600	0,602	1,003	0,361	0,601	0,257	0,429	0,290	0,484	0,362	0,604
		-	(0,061)	(0,101)	(0,053)	(0,089)	(0,034)	(0,056)	(0,032)	(0,053)	(0,041)	(0,069)
50	1	1,000	0,609	0,609	0,388	0,388	0,326	0,326	0,435	0,435	0,597	0,597
		-	(0,062)	(0,062)	(0,059)	(0,059)	(0,041)	(0,041)	(0,050)	(0,050)	(0,065)	(0,065)

Échantillon de validation

Coût d'erreur			Seuil de classification									
			0,1		0,3		0,5		0,7		0,9	
Type I	Type II	SN	M	M/SN	M	M/SN	M	M/SN	M	M/SN	M	M/SN
1	1	0,020	0,600	30,021	0,376	18,821	0,275	13,768	0,206	10,295	0,115	5,726
		-	(0,092)	(4,606)	(0,141)	(7,063)	(0,121)	(6,061)	(0,110)	(5,498)	(0,072)	(3,585)
5	1	0,100	0,609	6,088	0,397	3,966	0,304	3,040	0,245	2,455	0,160	1,600
		-	(0,086)	(0,861)	(0,134)	(1,338)	(0,114)	(1,143)	(0,103)	(1,032)	(0,068)	(0,680)
10	1	0,200	0,619	3,097	0,422	2,109	0,340	1,699	0,295	1,475	0,217	1,084
		-	(0,079)	(0,397)	(0,125)	(0,623)	(0,108)	(0,539)	(0,097)	(0,484)	(0,067)	(0,333)
20	1	0,400	0,640	1,601	0,472	1,181	0,411	1,028	0,394	0,985	0,331	0,826
		-	(0,069)	(0,173)	(0,107)	(0,267)	(0,103)	(0,258)	(0,092)	(0,229)	(0,075)	(0,187)
30	1	0,600	0,661	1,102	0,523	0,872	0,483	0,805	0,493	0,821	0,444	0,740
		-	(0,066)	(0,109)	(0,090)	(0,150)	(0,111)	(0,185)	(0,098)	(0,163)	(0,094)	(0,156)
50	1	1,000	0,704	0,704	0,624	0,624	0,626	0,626	0,691	0,691	0,672	0,672
		-	(0,079)	(0,079)	(0,062)	(0,062)	(0,153)	(0,153)	(0,136)	(0,136)	(0,146)	(0,146)

Tableau 26 : Coûts espérés de mauvaise classification moyens (écart type) des modèles de régression logistique (suite)

Probabilité *a priori* - Fraude : 3 %

Échantillon d'estimation

Coût d'erreur			Seuil de classification									
			0,1		0,3		0,5		0,7		0,9	
Type I	Type II	SN	M	M/SN	M	M/SN	M	M/SN	M	M/SN	M	M/SN
1	1	0,030	0,585	19,504	0,319	10,619	0,158	5,276	0,082	2,746	0,028	0,927
		-	(0,058)	(1,939)	(0,046)	(1,527)	(0,024)	(0,810)	(0,008)	(0,256)	(0,011)	(0,382)
5	1	0,150	0,587	3,915	0,327	2,179	0,179	1,192	0,126	0,840	0,098	0,655
		-	(0,059)	(0,390)	(0,047)	(0,315)	(0,026)	(0,174)	(0,012)	(0,079)	(0,016)	(0,109)
10	1	0,300	0,590	1,967	0,337	1,124	0,204	0,682	0,180	0,601	0,186	0,621
		-	(0,059)	(0,197)	(0,049)	(0,163)	(0,028)	(0,095)	(0,018)	(0,060)	(0,024)	(0,080)
20	1	0,600	0,596	0,993	0,358	0,596	0,256	0,426	0,289	0,482	0,362	0,604
		-	(0,060)	(0,100)	(0,053)	(0,088)	(0,034)	(0,056)	(0,032)	(0,053)	(0,041)	(0,069)
30	1	0,900	0,601	0,668	0,378	0,420	0,307	0,341	0,398	0,443	0,538	0,598
		-	(0,061)	(0,068)	(0,057)	(0,063)	(0,039)	(0,043)	(0,046)	(0,051)	(0,059)	(0,065)
50	1	1,500	0,612	0,408	0,419	0,279	0,410	0,273	0,616	0,411	0,890	0,594
		-	(0,064)	(0,042)	(0,065)	(0,044)	(0,051)	(0,034)	(0,074)	(0,049)	(0,094)	(0,063)

Échantillon de validation

Coût d'erreur			Seuil de classification									
			0,1		0,3		0,5		0,7		0,9	
Type I	Type II	SN	M	M/SN	M	M/SN	M	M/SN	M	M/SN	M	M/SN
1	1	0,030	0,595	19,846	0,375	12,505	0,276	9,207	0,209	6,961	0,119	3,972
		-	(0,090)	(3,013)	(0,139)	(4,628)	(0,119)	(3,968)	(0,108)	(3,597)	(0,070)	(2,346)
5	1	0,150	0,608	4,053	0,405	2,703	0,319	2,128	0,268	1,788	0,187	1,249
		-	(0,082)	(0,544)	(0,128)	(0,851)	(0,110)	(0,730)	(0,099)	(0,657)	(0,066)	(0,441)
10	1	0,300	0,624	2,079	0,443	1,478	0,373	1,243	0,342	1,141	0,273	0,909
		-	(0,073)	(0,242)	(0,114)	(0,380)	(0,103)	(0,343)	(0,092)	(0,306)	(0,068)	(0,228)
20	1	0,600	0,655	1,092	0,519	0,865	0,480	0,800	0,491	0,818	0,443	0,739
		-	(0,065)	(0,108)	(0,088)	(0,147)	(0,110)	(0,184)	(0,097)	(0,162)	(0,094)	(0,156)
30	1	0,900	0,687	0,763	0,595	0,661	0,588	0,653	0,639	0,710	0,614	0,682
		-	(0,073)	(0,082)	(0,067)	(0,074)	(0,140)	(0,155)	(0,124)	(0,138)	(0,132)	(0,147)
50	1	1,500	0,750	0,500	0,747	0,498	0,802	0,535	0,936	0,624	0,955	0,636
		-	(0,120)	(0,080)	(0,057)	(0,038)	(0,228)	(0,152)	(0,205)	(0,136)	(0,220)	(0,147)

Légende : M : Modèle; SN : Stratégie naïve.

Note : Pour une probabilité *a priori* de fraude donnée et un coût relatif de mauvaise classification donné, le coût relatif de mauvaise classification de la stratégie naïve est identique pour tous les seuils de classification.

ANNEXE 10. – TAUX DE BONNE CLASSIFICATION ET COÛTS ESPÉRÉS DE MAUVAISE CLASSIFICATION DES MODÈLES DE RÉSEAUX DE NEURONES

**Tableau 27 : Taux de bonne classification moyens (écart type)
des modèles de réseaux de neurones**

		Seuil de classification				
		0,1	0,3	0,5	0,7	0,9
Échantillon d'estimation						
Groupe 1	99,7	92,6	75,8	56,1	34,5	
	(0,6)	(4,5)	(17,6)	(24,6)	(27,1)	
Groupe 2	27,9	57,6	82,6	93,9	99,2	
	(31,8)	(18,1)	(7,6)	(5,6)	(0,7)	
Global	63,8	75,1	79,2	75,0	66,8	
	(16,0)	(10,3)	(8,7)	(12,3)	(13,4)	
Échantillon de validation						
		Seuil de classification				
		0,1	0,3	0,5	0,7	0,9
Groupe 1	92,6	78,9	52,6	28,4	17,9	
	(8,0)	(11,8)	(6,4)	(13,7)	(14,7)	
Groupe 2	14,7	34,7	60,0	81,1	91,6	
	(20,2)	(20,2)	(15,6)	(13,7)	(6,0)	
Global	53,7	56,8	56,3	54,7	54,7	
	(7,1)	(9,0)	(5,5)	(5,1)	(4,7)	

Tableau 28 : Coûts espérés de mauvaise classification moyens (écart type) des modèles de réseaux de neurones

Probabilité *a priori* - Fraude : 1 %

Échantillon d'estimation

Coût d'erreur			Seuil de classification									
			0,1		0,3		0,5		0,7		0,9	
Type I	Type II	SN	M	M/SN	M	M/SN	M	M/SN	M	M/SN	M	M/SN
1	1	0,010	0,714	71,387	0,420	42,018	0,174	17,437	0,064	6,432	0,014	1,437
		-	(0,315)	(31,526)	(0,179)	(17,916)	(0,075)	(7,521)	(0,056)	(5,551)	(0,006)	(0,611)
5	1	0,050	0,714	14,279	0,423	8,463	0,184	3,681	0,082	1,638	0,041	0,812
		-	(0,315)	(6,306)	(0,180)	(3,601)	(0,074)	(1,480)	(0,056)	(1,115)	(0,011)	(0,228)
10	1	0,100	0,714	7,141	0,427	4,268	0,196	1,962	0,104	1,039	0,073	0,733
		-	(0,315)	(3,154)	(0,181)	(1,811)	(0,073)	(0,734)	(0,058)	(0,584)	(0,024)	(0,240)
20	1	0,200	0,714	3,572	0,434	2,171	0,220	1,102	0,148	0,739	0,139	0,694
		-	(0,315)	(1,577)	(0,183)	(0,917)	(0,075)	(0,376)	(0,070)	(0,351)	(0,051)	(0,254)
30	1	0,300	0,715	2,382	0,442	1,472	0,245	0,815	0,192	0,639	0,204	0,681
		-	(0,316)	(1,052)	(0,186)	(0,619)	(0,081)	(0,270)	(0,087)	(0,291)	(0,078)	(0,259)
50	1	0,500	0,715	1,430	0,456	0,913	0,293	0,586	0,280	0,559	0,335	0,671
		-	(0,316)	(0,632)	(0,191)	(0,382)	(0,101)	(0,202)	(0,129)	(0,259)	(0,132)	(0,264)

Échantillon de validation

Coût d'erreur			Seuil de classification									
			0,1		0,3		0,5		0,7		0,9	
Type I	Type II	SN	M	M/SN	M	M/SN	M	M/SN	M	M/SN	M	M/SN
1	1	0,010	0,845	84,484	0,648	64,821	0,401	40,074	0,195	19,474	0,092	9,158
		-	(0,199)	(19,911)	(0,200)	(19,991)	(0,154)	(15,404)	(0,135)	(13,488)	(0,058)	(5,805)
5	1	0,050	0,848	16,956	0,657	13,133	0,420	8,394	0,223	4,467	0,124	2,488
		-	(0,196)	(3,929)	(0,198)	(3,956)	(0,152)	(3,038)	(0,131)	(2,619)	(0,053)	(1,053)
10	1	0,100	0,851	8,515	0,667	6,672	0,443	4,434	0,259	2,592	0,165	1,655
		-	(0,193)	(1,932)	(0,195)	(1,953)	(0,149)	(1,493)	(0,126)	(1,262)	(0,046)	(0,461)
20	1	0,200	0,859	4,294	0,688	3,441	0,491	2,454	0,331	1,654	0,248	1,238
		-	(0,187)	(0,933)	(0,191)	(0,953)	(0,144)	(0,721)	(0,117)	(0,587)	(0,034)	(0,170)
30	1	0,300	0,866	2,887	0,709	2,364	0,538	1,794	0,402	1,341	0,330	1,099
		-	(0,180)	(0,601)	(0,187)	(0,622)	(0,139)	(0,463)	(0,110)	(0,365)	(0,025)	(0,083)
50	1	0,500	0,881	1,762	0,751	1,503	0,633	1,266	0,545	1,091	0,494	0,988
		-	(0,168)	(0,336)	(0,181)	(0,362)	(0,129)	(0,258)	(0,098)	(0,196)	(0,029)	(0,058)

Tableau 28 : Coûts espérés de mauvaise classification moyens (écart type) des modèles de réseaux de neurones (suite)

Probabilité *a priori* - Fraude : 2 %

Échantillon d'estimation

Coût d'erreur			Seuil de classification									
			0,1		0,3		0,5		0,7		0,9	
Type I	Type II	SN	M	M/SN	M	M/SN	M	M/SN	M	M/SN	M	M/SN
1	1	0,020	0,707	35,334	0,417	20,834	0,175	8,753	0,068	3,405	0,021	1,042
		-	(0,312)	(15,604)	(0,178)	(8,878)	(0,074)	(3,704)	(0,055)	(2,742)	(0,006)	(0,308)
5	1	0,100	0,707	7,069	0,423	4,226	0,194	1,944	0,103	1,033	0,073	0,733
		-	(0,312)	(3,122)	(0,179)	(1,793)	(0,073)	(0,726)	(0,058)	(0,579)	(0,024)	(0,241)
10	1	0,200	0,707	3,536	0,430	2,150	0,219	1,093	0,147	0,736	0,139	0,694
		-	(0,312)	(1,561)	(0,182)	(0,908)	(0,075)	(0,373)	(0,070)	(0,349)	(0,051)	(0,254)
20	1	0,400	0,708	1,769	0,445	1,112	0,267	0,668	0,235	0,588	0,270	0,675
		-	(0,312)	(0,781)	(0,186)	(0,466)	(0,089)	(0,223)	(0,107)	(0,268)	(0,105)	(0,262)
30	1	0,600	0,708	1,180	0,459	0,766	0,315	0,526	0,323	0,538	0,401	0,668
		-	(0,313)	(0,521)	(0,192)	(0,319)	(0,113)	(0,189)	(0,152)	(0,253)	(0,159)	(0,265)
50	1	1,000	0,709	0,709	0,489	0,489	0,412	0,412	0,499	0,499	0,663	0,663
		-	(0,313)	(0,313)	(0,203)	(0,203)	(0,173)	(0,173)	(0,246)	(0,246)	(0,268)	(0,268)

Échantillon de validation

Coût d'erreur			Seuil de classification									
			0,1		0,3		0,5		0,7		0,9	
Type I	Type II	SN	M	M/SN	M	M/SN	M	M/SN	M	M/SN	M	M/SN
1	1	0,020	0,837	41,853	0,644	32,189	0,401	20,074	0,200	10,000	0,099	4,947
		-	(0,196)	(9,821)	(0,197)	(9,867)	(0,152)	(7,597)	(0,133)	(6,626)	(0,056)	(2,805)
5	1	0,100	0,843	8,429	0,661	6,606	0,439	4,394	0,257	2,573	0,165	1,646
		-	(0,191)	(1,911)	(0,193)	(1,932)	(0,148)	(1,477)	(0,125)	(1,249)	(0,046)	(0,455)
10	1	0,200	0,850	4,252	0,682	3,408	0,487	2,434	0,329	1,644	0,247	1,234
		-	(0,185)	(0,923)	(0,189)	(0,943)	(0,143)	(0,713)	(0,116)	(0,580)	(0,033)	(0,167)
20	1	0,400	0,865	2,163	0,724	1,809	0,581	1,454	0,472	1,180	0,411	1,027
		-	(0,172)	(0,430)	(0,181)	(0,453)	(0,133)	(0,331)	(0,102)	(0,254)	(0,023)	(0,056)
30	1	0,600	0,880	1,466	0,766	1,276	0,676	1,127	0,615	1,025	0,575	0,959
		-	(0,160)	(0,267)	(0,177)	(0,295)	(0,123)	(0,205)	(0,094)	(0,156)	(0,040)	(0,067)
50	1	1,000	0,909	0,909	0,850	0,850	0,866	0,866	0,901	0,901	0,904	0,904
		-	(0,138)	(0,138)	(0,178)	(0,178)	(0,106)	(0,106)	(0,100)	(0,100)	(0,095)	(0,095)

Tableau 28 : Coûts espérés de mauvaise classification moyens (écart type) des modèles de réseaux de neurones (suite)

Probabilité *a priori* - Fraude : 3 %

Échantillon d'estimation

Coût d'erreur			Seuil de classification									
			0,1		0,3		0,5		0,7		0,9	
Type I	Type II	SN	M	M/SN	M	M/SN	M	M/SN	M	M/SN	M	M/SN
1	1	0,030	0,700	23,317	0,413	13,773	0,176	5,858	0,072	2,396	0,027	0,911
		-	(0,309)	(10,297)	(0,176)	(5,866)	(0,073)	(2,433)	(0,054)	(1,809)	(0,007)	(0,244)
5	1	0,150	0,700	4,665	0,422	2,814	0,205	1,365	0,125	0,831	0,106	0,706
		-	(0,309)	(2,060)	(0,179)	(1,191)	(0,072)	(0,482)	(0,062)	(0,416)	(0,037)	(0,249)
10	1	0,300	0,700	2,334	0,433	1,444	0,241	0,804	0,191	0,635	0,204	0,681
		-	(0,309)	(1,031)	(0,182)	(0,607)	(0,080)	(0,266)	(0,087)	(0,289)	(0,078)	(0,259)
20	1	0,600	0,701	1,168	0,455	0,759	0,314	0,523	0,322	0,537	0,401	0,668
		-	(0,309)	(0,516)	(0,190)	(0,316)	(0,113)	(0,189)	(0,152)	(0,253)	(0,159)	(0,265)
30	1	0,900	0,702	0,780	0,477	0,530	0,386	0,429	0,454	0,505	0,597	0,664
		-	(0,310)	(0,344)	(0,198)	(0,220)	(0,157)	(0,175)	(0,222)	(0,247)	(0,240)	(0,267)
50	1	1,500	0,703	0,469	0,522	0,348	0,532	0,354	0,718	0,479	0,991	0,660
		-	(0,310)	(0,207)	(0,216)	(0,144)	(0,256)	(0,171)	(0,367)	(0,245)	(0,403)	(0,269)

Échantillon de validation

Coût d'erreur			Seuil de classification									
			0,1		0,3		0,5		0,7		0,9	
Type I	Type II	SN	M	M/SN	M	M/SN	M	M/SN	M	M/SN	M	M/SN
1	1	0,030	0,829	27,642	0,639	21,312	0,402	13,407	0,205	6,842	0,106	3,544
		-	(0,194)	(6,458)	(0,195)	(6,493)	(0,150)	(4,995)	(0,130)	(4,339)	(0,054)	(1,805)
5	1	0,150	0,838	5,587	0,665	4,431	0,459	3,060	0,291	1,941	0,205	1,366
		-	(0,186)	(1,239)	(0,189)	(1,259)	(0,144)	(0,957)	(0,119)	(0,793)	(0,039)	(0,258)
10	1	0,300	0,849	2,831	0,696	2,321	0,530	1,767	0,399	1,328	0,328	1,093
		-	(0,176)	(0,588)	(0,183)	(0,609)	(0,136)	(0,453)	(0,107)	(0,356)	(0,024)	(0,080)
20	1	0,600	0,871	1,452	0,759	1,266	0,672	1,120	0,613	1,022	0,574	0,957
		-	(0,158)	(0,263)	(0,175)	(0,292)	(0,121)	(0,202)	(0,092)	(0,154)	(0,041)	(0,068)
30	1	0,900	0,893	0,993	0,823	0,914	0,814	0,905	0,828	0,920	0,821	0,912
		-	(0,141)	(0,157)	(0,174)	(0,194)	(0,109)	(0,121)	(0,095)	(0,106)	(0,081)	(0,090)
50	1	1,500	0,938	0,625	0,949	0,633	1,099	0,732	1,257	0,838	1,313	0,876
		-	(0,116)	(0,078)	(0,194)	(0,129)	(0,090)	(0,060)	(0,142)	(0,095)	(0,168)	(0,112)

Légende : M : Modèle; SN : Stratégie naïve.

Note : Pour une probabilité *a priori* de fraude donnée et un coût relatif de mauvaise classification donné, le coût relatif de mauvaise classification de la stratégie naïve est identique pour tous les seuils de classification.