



SCORING ET ANTICIPATION DE DEFAILLANCE DES ENTREPRISES : UNE APPROCHE PAR LA REGRESSION LOGISTIQUE

Patrick Boisselier, Dominique Dufour

► To cite this version:

Patrick Boisselier, Dominique Dufour. SCORING ET ANTICIPATION DE DEFAILLANCE DES ENTREPRISES : UNE APPROCHE PAR LA REGRESSION LOGISTIQUE. Identification et maîtrise des risques : enjeux pour l'audit, la comptabilité et le contrôle de gestion, May 2003, Belgique. pp.CD-Rom. halshs-00582740

HAL Id: halshs-00582740

<https://shs.hal.science/halshs-00582740>

Submitted on 4 Apr 2011

HAL is a multi-disciplinary open access archive for the deposit and dissemination of scientific research documents, whether they are published or not. The documents may come from teaching and research institutions in France or abroad, or from public or private research centers.

L'archive ouverte pluridisciplinaire **HAL**, est destinée au dépôt et à la diffusion de documents scientifiques de niveau recherche, publiés ou non, émanant des établissements d'enseignement et de recherche français ou étrangers, des laboratoires publics ou privés.

SCORING ET ANTICIPATION DE DEFAILLANCE DES ENTREPRISES : UNE APPROCHE PAR LA REGRESSION LOGISTIQUE

Patrick BOISSELIER

*Maître de conférences, chercheur au CRIFP¹, Responsable de l'axe « Edhec Risk and Asset, Management Research Center » de l'EDHEC, IUT de Nice, 41, bd. Napoléon III
06041 NICE Cedex, boisseli@idefi.cnrs.fr*

Dominique DUFOUR

*Maître de conférences, chercheur au CRIFP, chercheur associé au centre de recherche de l'EDHEC, IAE de Nice, av. Emile Henriot
06050 NICE Cedex, dufour@idefi.cnrs.fr*

L'anticipation de la défaillance des entreprises a été étudiée en détail et de manière récurrente dans la littérature comptable et financière. Cette analyse peut s'appuyer sur la mise en œuvre de différents modèles statistiques. L'analyse discriminante popularisée par les travaux de la Banque de France en est une illustration. Dans ce travail, l'application de la technique de la régression logistique à deux échantillons d'entreprises –saines et faillies en 2002– nous permet d'obtenir des résultats significatifs et de proposer un modèle de prévision.

Mots-clés : prévision, défaillance, régression logistique.

The bankruptcy prediction has been studied in detail in accounting and finance literature. Results yielded by the application of statistical methods to the bankruptcy prediction problem suggest that the financial ratios are a valid discriminator between bankrupt and nonbankrupt companies and several researchers have used discriminant analysis to predict bankruptcies. Our purpose is to develop a bankruptcy model using the logistic regression technique. We obtain significant results and we propose a prediction model.

Key-words : Bankruptcy prediction, Logistic regression.

1 Introduction

La défaillance des entreprises a fait maintenant depuis plusieurs années, l'objet de nombreux travaux. Elle est aujourd'hui, particulièrement remise au goût du jour avec l'obligation pour les banques de noter leurs créances, dans le respect de la nouvelle réglementation dite « Bâle II ». La grande majorité des travaux s'appuie sur des outils d'analyse statistique de grandeurs comptables et de ratios financiers pour discriminer les entreprises saines des entreprises défaillantes. Elle débouche sur un calcul de score. Un score est un indicateur de synthèse censé donner en un chiffre, le degré de défaillance possible d'un débiteur. Il permet d'aider à la notation des créances, par une approche quantitative du risque de défaillance. La notation est entendue comme « une opinion indépendante et publique sur la qualité de crédit d'une entité » (J-F. de Polignac, 2002, p.19). Celle-ci n'est pas exclusivement liée à la santé

¹ Centre de Recherche en Ingénierie Financière et Finances Publiques (CRIFP), dirigé par le Professeur Jacques SPINDLER.

financière, puisqu'une entreprise peut avoir des résultats désastreux et conserver une bonne note, dès lors qu'elle soutenue par un Etat solide.

En reprenant le même type de données comptables et financières que les études statistiques réalisées par le passé sur la question, nous mettons en œuvre dans cette recherche exploratoire, la méthode de la régression logistique avec, comme variable expliquée dichotomique, la défaillance. Nous verrons que cette approche se distingue sur certains points essentiels, de la méthode de l'analyse discriminante popularisée par la Centrale des Bilans de la Banque de France. La première partie de ce travail fait le point sur les enjeux actuels de la prévision de la défaillance et définit la problématique de notre travail (2). Dans une deuxième partie, nous argumentons sur l'intérêt et les avantages de la régression logistique, comparativement à d'autres techniques statistiques (3). Suite à cela, nous présentons dans une troisième partie, l'échantillon utilisé ainsi que les résultats obtenus (4). Enfin, nous concluons et proposons des extensions possibles au modèle (5).

2 Un nombre de défaillances en croissance et la nécessité d'instruments de prévision

Après plusieurs années de baisse, le nombre de défaillances a tendance à progresser à nouveau en France (2.1). La défaillance d'une entreprise est un événement lourd de conséquences. En conséquences humaines d'abord, puisqu'elle conduit à des pertes d'emplois, mais aussi financières puisqu'elle s'accompagne presque inmanquablement de pertes d'actifs chez ses partenaires : organismes sociaux, fournisseurs ou encore banques. La disposition d'instruments de prévision est donc indispensable (2.2), surtout dans le climat actuel de renforcement du contrôle des risques bancaires (2.3).

2.1 Un nombre de défaillances en croissance nette

Par défaillance, nous entendons tout type de dépôt de bilan se traduisant aussi bien par une liquidation effective, qu'un plan de continuation ou de cession de l'activité. La défaillance se caractérise par l'état de cessation des paiements et n'entraîne ainsi, pas automatiquement la cessation de l'activité. On notera que le terme de faillite, souvent usité, est plutôt réservé à la personne du gérant (on parle de « faillite personnelle ») et correspond de nos jours à du langage courant, pour désigner la cessation définitive de l'activité de l'entreprise. Nous lui préférons donc, systématiquement le terme de défaillance.

Dans une publication récente (C. Rieg, 2002), l'INSEE analyse l'évolution des défaillances en France entre 1997 et 2001. Les phénomènes les plus remarquables sont les suivants : recul d'un quart entre 1997 et 2000 des défaillances (de 48 600 à 35 400, soit - 10 % en moyenne par an), poursuite de la réduction au cours du premier semestre 2001 (baisse de 7,1 % par rapport au premier semestre 2000), puis inversion de la tendance à partir du second semestre 2001 (augmentation de 4,8 % par rapport au semestre correspondant de 2000).

Le ralentissement de la conjoncture et la crise ayant affecté les entreprises liées aux nouvelles technologies de l'information et de la communication (NTIC) sont les grandes responsables de

cette inversion de tendance. Dans le même temps l'INSEE signale que désormais, des entreprises de grande taille sont victimes de défaillances. Cette tendance est confirmée par une étude de Dun & Bradstreet², selon laquelle, « le nombre d'entreprises de plus de 100 personnes ayant déposé le bilan sur le premier trimestre 2002 atteint 63 contre seulement 34 pour 2001, soit une progression de 85% alors que le niveau était resté stable en 2001. Le chiffre d'affaires réalisé par les 10 plus grosses sociétés ayant enregistré une ouverture de procédures collectives sur le premier trimestre 2002 atteint 1,7 Milliards d'euros. La défaillance du grossiste informatique METROLOGIE pèse pour 0,8 Milliard d'euros, le répartiteur en pharmacie OUEST REPARTITION pour 0,2 et le transporteur routier VIALLE pour 0,1 Milliard d'Euros ». Il est à craindre que l'année 2003 ne se caractérise par une conjoncture médiocre et que l'augmentation du nombre de défaillances se poursuive compte tenu de l'effet « boule de neige » engendré par les dépôts de bilan.

Dans un tel contexte, les entreprises déjà sensibilisées au risque de défaillance depuis le début des années 90 se doivent d'anticiper celle de leurs clients, voire de leurs fournisseurs. Elles découvrent, grâce notamment à la généralisation de l'Internet, des outils de prévision du risque de défaillance, fondés sur une meilleure accessibilité à l'information comptable et le calcul d'indicateurs *ad hoc*.

2.2 La prévision de la défaillance

La défaillance d'une entreprise a souvent pour origine, la défaillance d'un client. La France se caractérise encore par un niveau élevé de crédit interentreprises. Dans une étude récente, F. Sauvage (2002) indique en 2001 un encours de 290 Md€ pour un montant de 122 Md€ de crédits bancaires de trésorerie aux entreprises³. L'auteur précise à ce sujet, que ce crédit est un facteur de transmission des défaillances et que l'une des meilleures sources de prévention est l'information économique et financière. Ces dernières années ont vu d'ailleurs, l'émergence de la fonction de credit-manager, dont l'une des missions est l'analyse du risque client.

Dans le cas de la France, l'obligation de dépôt des comptes annuels des entreprises met à la disposition de tous, les informations comptables de base : bilan et compte de résultat. Le développement du Minitel et de l'Internet a par ailleurs, autorisé un accès plus rapide et plus large à ces informations, favorisant également le développement de sociétés spécialisées dans le stockage, l'analyse et la mise à disposition de données financières et comptables. Un des arguments publicitaires majeurs de ces sociétés est la nécessité pour une entreprise quelconque, de vérifier la solidité financière de ses clients.

Il est par ailleurs, intéressant de noter qu'une des bases de données leader sur ce marché, Diane, fournit pour chaque entreprise, le score Conan-Holder issu d'une analyse discriminante⁴. Relevons que l'utilisation telle quelle de ce score est fort contestable, car la

² In Duval T., « Inversion de tendance pour les défaillances d'entreprises : les indicateurs repartent à la hausse sur le premier trimestre 2002 », <http://www.exafi.fr>, page web : <http://www.netpme.fr/procedure-collective/article.php?article=196>

³ Sommes converties et arrondies en euros par les auteurs

⁴ Rappelons que le score Conan/Holder prend en compte 5 ratios : R1 = EBE/Endettement Global ; R2 = Capitaux permanents/Total Bilan ; R3 = VRD/Total Bilan ; R4 = Frais Financiers/CA HT ; R5 = Frais de

fonction n'a *a priori*, fait l'objet d'aucune actualisation et qu'elle repose par ailleurs, sur une hypothèse critiquable de normalité des données (cf. *infra*).

S'agissant des banques, l'analyse du risque de défaillance de l'emprunteur a toujours constitué le cœur de la problématique de l'analyse financière qui accompagne toute demande de crédit. Mais, le renforcement des contraintes prudentielles les conduira certainement à développer plus encore, les outils de quantification de ce même risque.

2.3 Contraintes prudentielles et analyse du risque

Etre banquier, c'est analyser le risque. C'est dans cet esprit que l'analyse financière s'est construite. Son objet est d'évaluer la solvabilité future de l'entreprise à partir de l'analyse des informations comptables qu'elle fournit, du fonctionnement de la relation banque-entreprise et éventuellement de la conjoncture globale et sectorielle. Il s'agit principalement d'une approche quantitative, même si des éléments qualitatifs tels que l'évaluation de la qualité de l'équipe dirigeante peuvent être intégrés. L'information comptable, bien que rétrospective, est donc censée contenir suffisamment d'informations pour élaborer un diagnostic fiable.

Les contraintes prudentielles pesant sur les banques n'ont cessé de se renforcer ces dernières années. La crainte des autorités de tutelle est celle d'une crise systémique dans laquelle il y aurait propagation de faillites bancaires. L'interpénétration croissante des économies, combinée à la complexification croissante des instruments financiers est le moteur du renforcement des contraintes. En Europe le groupe appelé « Comité de Bâle » a en charge une réflexion sur les risques ainsi que sur la mise en place, à l'initiative de la Commission Européenne, de moyens permettant leur quantification ainsi que leur gestion. Un premier accord (l'Accord dit de « Bâle I » en date de 1988) est intervenu, mettant en place une norme prudentielle de fonds propres. Une nouvelle réglementation est en cours de mise en œuvre (l'Accord de « Bâle II » en date de 2002) dont l'objectif est d'amener les exigences en matière de solvabilité des banques à un niveau correspondant davantage au risque réellement encouru.

Aux termes de cet accord, qui n'entrera en accord qu'au 31 décembre 2006, les établissements financiers seront obligés de procéder à une évaluation de leurs créances⁵. Cette dernière, fondée sur le principe de notations internes des créances (Internal Rating Based ou IRB Approach) s'opérera à travers deux modalités : l'approche de base qui imposera aux établissements concernés de procéder à des évaluations internes uniquement en relation avec la probabilité de défaillance de l'emprunteur ; et l'approche avancée (Advanced Approach), au titre de laquelle seront également prises en considération l'évaluation des pertes en cas de réalisation de ce risque et les montants alors exposés.

Les six standards dont le Comité de Bâle demande le respect aux futurs notateurs externes de portefeuilles de risques bancaires sont les suivants :

Personnel/VA. Le score (S) est défini par la fonction : $S = 0,24 R1 + 0,22 R2 + 0,16 R3 - 0,87 R4 - 0,10 R5$. Le diagnostic s'établit comme suit : $S < 4$: risque élevé ; $4 \leq S < 9$: risque à surveiller ; $S \geq 9$: bon risque

⁵ cf. « Document de travail des services de la commission sur les exigences de fonds propres applicables aux établissements de crédit et aux entreprises d'investissement », novembre 2002, p. 5 et *passim*. Cf. également, « Vue d'ensemble du nouvel accord de Bâle sur les fonds propres », janvier 2001.

- l'objectivité, garantie pour le score par une méthodologie de notation rigoureuse et une actualisation permanente des notes ;
- l'indépendance, par l'assurance qu'il n'y a pas de pressions économiques possibles de la part des entreprises notées ;
- un large accès possible aux notes ;
- la transparence de la méthodologie, donnée par l'indication de la signification de l'échelle des notes, celle des taux historiques de défaillance et des matrices de transition ;
- la crédibilité de la méthodologie à travers une confiance reconnue portée par les tiers ;
- enfin les moyens mis en oeuvre doivent être adaptés, grâce à des ressources humaines et financières suffisantes, au service d'une évaluation à la fois qualitative et quantitative⁶.

D'ores et déjà, la Coface a présenté un outil d'analyse des risques⁷, appelé le [score@rating](#), qui « respecte les standards imposés aux notateurs par le Comité de Bâle »⁸.

L'objet de notre étude ne débouche pas sur l'établissement d'un rating permettant d'établir un classement par niveau de risque des actifs de la banque. Le scoring qui résulte de la mise en oeuvre de la régression logistique donne seulement une estimation du risque lié à la survenance possible de la défaillance. Il nécessite d'être complété par un jugement qualitatif des actifs pour aboutir à une note. Toutefois, la détermination de grandeurs et de ratios comptables peut permettre d'élaborer de manière empirique, un modèle plus global de suivi des entreprises. Ainsi, une dégradation ou une altération dans le temps, de ces indicateurs amènera une modification du score et une éventuelle remise en question du rating. En revanche, il ne permet pas d'estimer le montant éventuel des pertes liées à la défaillance, ainsi que veulent l'imposer les accords de Bâle II dans sa version développée.

3 Choix et mise en oeuvre d'une méthodologie : la régression logistique

La défaillance d'entreprise n'est pas un thème nouveau dans la littérature scientifique consacrée à l'analyse du risque des entreprises. Pour cette raison, il convient au préalable, de préciser dans quelle tradition de recherche se situe notre travail (3.1). Puis, nous examinerons les finalités et les spécificités de la méthode de la régression logistique au regard de la régression linéaire ordinaire et de l'analyse discriminante (3.2), avant de nous pencher sur les conditions concrètes de sa mise en oeuvre (3.3).

3.1 Défaillance d'entreprise et choix d'un modèle de régression

Cette étude s'inscrit dans un courant de recherche empirique fondé sur une analyse multivariée du risque, initiée par E. Altman (1968). Elle a pour objectif de développer un modèle statistique permettant de « noter » les entreprises, sur leur risque de défaillance. La revue de littérature de C. Zavgren (1983) rappelle quelles ont été les contributions successives à l'amélioration du modèle d'Altman. Il s'avère que nombre d'entre elles souffrent des

⁶ Documents cités, cf. note 6.

⁷ <http://www.cofacerating.fr>

restrictions imposées par l'analyse discriminante qui exige que les variables soient distribuées normalement. R. Eisenbeis (1977) montre notamment, que la capacité prédictive des modèles peut être sévèrement affectée par le caractère non normal des variables. Partant de ce constat, C. Zavgren (1985) développe elle-même un modèle de type logit sur la base d'une fonction logistique, avec pour objectif de détecter les signes de défaillance au cours des cinq ans qui précèdent. Il s'avère néanmoins, que si le modèle est particulièrement performant, il l'est essentiellement pour les années les plus proches de l'échéance. Malgré quelques réserves à l'égard des modèles de régression, y compris la régression logistique (cf. E. Laitinen, 2000), il semble que cette dernière soit malgré tout, la plus adaptée aux caractéristiques des données concernées.

Dans une première approche, nous retiendrons le modèle de la régression logistique, même si celle dernière présente également des faiblesses. Nous nous contenterons par ailleurs, de l'appliquer sur les données N-1, qui apparaissent être les plus pertinentes. Le choix des grandeurs comptables et des ratios est discuté *infra*.

3.2 Finalités et spécificités de la régression logistique

Les finalités se définissent en termes d'objectifs pour notre étude, tandis que les spécificités portent sur les aspects techniques du modèle de la régression logistique et notamment de son choix *versus* d'autres modèles.

3.2.1 Finalités du modèle

Dans notre optique, la finalité principale de l'outil est de déterminer un score global permettant d'identifier les entreprises en bonne santé et celles présentant un risque de faillite. De manière concomitante, la construction du modèle doit également permettre de mettre en évidence les ratios ou les grandeurs comptables les plus discriminants.

Il est cependant clair que le modèle trouve ses limites dans le fait que les variables explicatives, comme les coefficients, sont extrêmement dépendants du contexte économique-financier et de la population elle-même ayant servi de base au calcul de la fonction de score. Par ailleurs et comme tout modèle extrapolatoire, il suppose une répétition dans le futur de comportements passés, dont on sait la versatilité. Enfin, l'étude est fondée sur des éléments purement quantitatifs dont on connaît les faiblesses, non seulement eu égard à des critères qualitatifs, mais aussi au mode de calcul des grandeurs comptables. On peut toutefois souligner l'intérêt supplémentaire présenté par la régression logistique, qui est de pouvoir intégrer des facteurs qualitatifs, tel que par exemple, un incident de paiement ou un engagement hors bilan, ce qui n'est pas le cas notamment, de l'analyse discriminante.

3.2.2 Les spécificités du modèle

La régression logistique est une technique utilisée pour analyser les déterminants d'une variable, que par commodité nous appellerons variable expliquée. Cette variable est binaire et ne prend donc que deux valeurs. Les variables explicatives peuvent être continues ou discrètes. Indiquons tout de suite, que la méthodologie de la régression logistique peut être étendue au cas de plus de deux valeurs pour une variable expliquée. Nous n'envisagerons cependant pas cette configuration dans notre travail, car le recours à une variable binaire est commode pour l'analyse d'une variable qualitative. Conventionnellement, il est simple de coder ainsi la variable qualitative : 0 si elle est absente chez l'individu étudié et 1 si elle est présente chez ce même individu. Dans le cadre de cette recherche, nous coderons 1 l'entreprise défaillante en 2002 et 0 dans le cas contraire.

L'objectif du modèle n'est pas non plus, de prédire une valeur numérique de la variable expliquée, ce qui n'aurait pas grand sens, mais de prévoir la probabilité notée π que cet individu ait la caractéristique associée au code 1 de la variable expliquée, sachant les valeurs prises par les variables explicatives chez un individu donné. Dans le cas qui nous intéresse, il s'agit de connaître la probabilité de défaillance d'une entreprise, sachant ses caractéristiques comptables et financières.

Le choix de la régression logistique en tant que technique statistique doit être également justifié au regard de la régression linéaire ordinaire et de l'analyse discriminante. Dans le premier cas, il s'avère que la méthode rencontre des difficultés majeures. La régression linéaire ordinaire ne peut pas de fait, être mise en œuvre, car les erreurs ne sont pas distribuées normalement. De plus, la variance des erreurs n'est pas constante et certaines prévisions de la variable expliquée se situent à l'extérieur de l'intervalle $[0 ; 1]$ ⁹. C'est pour lever ces difficultés, qu'il est nécessaire de transformer la variable expliquée. Cette transformation, appelée logit, consiste à régresser les variables explicatives non pas sur π , mais sur la variable transformée : $\text{Log}[(\pi)/(1 - \pi)]$. L'expression $[(\pi)/(1 - \pi)]$ est appelé l'odd de la probabilité. L'idée en amont de cette transformation est assez simple : la relation entre variable expliquée et variable explicative n'est pas une droite mais plutôt une courbe en S. Le modèle s'écrit alors : $\text{Log}[(\pi)/(1 - \pi)] = \beta_0 + \beta_i X_i$ avec X_i variables explicatives. La régression logistique permet de combiner plusieurs variables indépendantes sans que l'hypothèse de normalité soit une condition nécessaire.

L'analyse discriminante, quant à elle, se propose de prévoir l'appartenance d'un individu à deux ou plus sous groupes mutuellement exclusifs. Son propos est donc le même que celui de la régression logistique. De nombreux travaux de prévision de la défaillance se sont appuyés sur l'analyse discriminante. Dans le cas de la France il est permis de citer les travaux de la Centrale des Bilans de la Banque de France (M. Bardos, 2001a). L'analyse discriminante se présente comme l'inverse d'une analyse de la variance. Les conditions qui doivent être satisfaites pour sa mise en œuvre sont de même nature : normalité des distributions, homogénéité des matrices des variances/covariances entre les deux groupes et absence de

⁹ Cf. notamment à ce sujet, J. Neter, M. Kutner, C. Nachtsheim et W. Wasserman, 1996.

corrélations entre moyennes et variances. A nouveau, le grand intérêt que présente la régression logistique, comparativement à l'analyse discriminante est d'être une méthode statistique non-paramétrique et qui n'impose pas la condition de normalité. Or, les données ne suivent pas forcément une loi normale¹⁰. Ces quelques raisons nous conduisent en définitive, à privilégier la régression logistique aux autres méthodes, même si les arguments en faveur de l'une ou de l'autre restent discutables (S. Press et S. Wilson, 1978 ; P. Theodossiou, 1991; M. Bardos, 2001b), et qu'existent par ailleurs des modèles alternatifs, tels les réseaux de neurones (M. Bardos et W. Zhu, 1997).

3.3 Mise en oeuvre de la régression logistique

La mise en oeuvre du modèle de régression logistique pose des difficultés à différents niveaux. En premier lieu, il s'agit de déterminer les coefficients de la fonction logistique. En second lieu, il convient de procéder à la sélection d'un modèle.

3.3.1 L'extraction des coefficients.

La régression logistique est représentée sous la forme d'une fonction reliant une variable Y à une ou plusieurs variables dépendantes $X_1, X_2 \dots X_n$; soit : $Y = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \dots \beta_n X_n$. Les coefficients β sont calculés à l'aide de la méthode du maximum de vraisemblance. Leur interprétation est plus délicate que dans le modèle de la régression multiple ordinaire. Dans ce dernier cas, en effet, le coefficient β_i associé à une variable explicative X_i indique la variation de Y provoquée par une variation de X_i pour une unité, les autres variables explicatives étant maintenues constantes. Dans le cas de la régression logistique, il n'y a pas de relation linéaire entre Y –soit π la probabilité que le caractère soit présent chez l'individu– et X_i ¹¹. La relation est linéaire entre $\text{Log} [(\pi)/(1 - \pi)]$ et X_i . Il est permis d'en déduire que quand β_i est positif (resp. négatif), cela signifie qu'une augmentation de X_i a un effet positif (resp. négatif) sur π .

En règle générale les logiciels proposent une table de classement. Il s'agit d'un tableau à double entrée dans lequel sont reportés pour les deux sous groupes, le nombre total d'individus, ainsi que le nombre total d'individus bien classés à l'aide du modèle.

3.3.2 Le choix d'une technique de traitement statistique

Comment arbitrer entre plusieurs modèles sachant une variable expliquée et plusieurs variables explicatives ? Pour cela, on peut opérer une distinction entre les différents objectifs recherchés par la mise en oeuvre de la méthode. On peut en distinguer trois : descriptifs, explicatifs ou prédictifs.

- Modèle à finalité descriptive

Il s'agit ici, d'explorer les associations de plusieurs variables indépendantes avec une variable indépendante Y , dite « variable-réponse ». Parmi celles-ci, on cherche à identifier celles qui

¹⁰ Nous avons procédé à un test de normalité sur quelques variables et les résultats se sont avérés très nettement négatifs.

¹¹ J. Neter et al. (1996) notent cependant, que quand π est compris entre 0,2 et 0,8, il est possible de considérer cette relation comme étant à peu près linéaire, op. cit. p. 581.

décrivent le mieux la variable-réponse. Il est possible à cette fin, d'utiliser des procédures automatiques de sélection pour la construction du modèle : « forward stepwise », « backward stepwise » ou encore « step-by-step ». La première consiste à introduire les variables une par une, en commençant par celle qui est le plus significativement associée, et les autres conditionnellement aux variables déjà dans le modèle. Une variable sélectionnée pour le modèle fera partie du modèle final. La deuxième élimine du modèle global, les variables les moins significatives pour ne conserver que celles qui, suivant un seuil préalablement fixé, sont significativement associées à l'événement, conditionnellement aux variables déjà dans le modèle. Enfin, la troisième est une version combinée des deux précédentes : à chaque pas, elle procède à un réexamen des variables introduites dans le modèle aux étapes antérieures. Elle consiste donc en une sélection ascendante avec une élimination descendante.

Manuellement il est possible de s'appuyer sur le test du maximum de vraisemblance – likelihood ratio test – afin de tester si une ou plusieurs variables peuvent être exclues du modèle. Le test de Wald permet également de tester, si un coefficient est significativement différent de 0. Il est aussi possible de privilégier le pouvoir discriminant du modèle. Dans le cadre de notre étude, nous tenterons de déterminer les variables explicatives les plus significatives, apportant un score le plus satisfaisant possible, dans une optique préférentielle d'explication.

- Modèle à finalité explicative

Dans ce contexte, la mise en œuvre du modèle vise à confirmer ou infirmer une hypothèse portant sur une association entre un facteur X d'exposition et un événement Y. Nous tenterons ainsi, à travers la sélection des variables, d'apporter une interprétation cohérente et rationnelle du risque de faillite. Nous accepterons par conséquent, de supporter un score plus faible que les résultats obtenus avec la majeure partie des variables, afin de rester dans un contexte d'interprétation plutôt que de description.

- Modèle à finalité prédictive

Le principe, dans ce cas, est d'élaborer un instrument de prédiction de la faillite ; plus précisément, un outil permettant de classer correctement les entreprises, parmi celles encourant un risque de faillite et les autres. A partir des coefficients et des variables explicatives déterminés par la régression logistique, il doit être possible de calculer la probabilité pour une entreprise de faire faillite à horizon de un, deux, voire trois années. Dans le contexte de la présente étude, nous nous limiterons à l'établissement de la fonction score. Celle-ci a un caractère prédictif. Cependant, le test de prédictibilité constituera une extension du modèle et du présent travail.

4 Analyse statistique et principaux résultats

Nous examinerons d'abord les modalités utilisées pour constituer la base de travail (4.1), avant de présenter les résultats du travail statistique (4.2). Nous nous limiterons, pour ce

second point, aux résultats obtenus à l'issue de la mise en œuvre des différentes procédures (forward– backward stepwise, stet-by-step) et les plus satisfaisants au regard des objectifs que nous nous sommes fixés (cf. point 3.2.2).

4.1 Données et variables

La sélection des données à porté sur deux groupes : les entreprises saines et faillies d'une part et les variables du modèle, d'autre part.

4.1.1 Les entreprises

Les deux échantillons, entreprises saines et défaillantes âgées d'au moins trois ans, ont été extraits de la base de données Diane. Les types de sociétés retenus sont les plus communs, c'est-à-dire SA, SARL, SCA et SAS. Ils ont été constitués de la manière suivante :

- pour les entreprises défaillantes, nous avons procédé à un tirage aléatoire, à l'aide d'une table de nombres au hasard, de 470 entreprises sur les 1502 entreprises disponibles au sein de la base de données. Il s'agit d'entreprises ayant connu une défaillance au cours des 11 premiers mois de l'année 2002 ;
- pour les entreprises saines, nous avons tiré de la même manière, 470 entreprises parmi la population des entreprises saines de la base de données (plus de 210 000 entreprises).

De manière générale, nous avons éliminé des échantillons, les entreprises de grande taille (les 100 premières), de manière à éviter un effet taille qui aurait inévitablement joué sur les ratios. De plus, la défaillance est beaucoup plus rare et très spécifique dans les entreprises de ce type. De même, les entreprises de moins de trois ans ont été exclues, car elles comportent un risque naturel de défaillance particulièrement élevé. Ainsi, le facteur âge est-il relativisé, voire nettement amoindri. Ce facteur aurait notamment risqué de peser sur certaines grandeurs ou ratios, tels que la capitalisation, la croissance du BFR, le taux d'intérêt apparent... Nous n'avons pas non plus, procédé à un tri sur les secteurs : l'étude étant exploratoire, avec pour objectif de dégager des ratios ou des grandeurs « neutres », il nous a semblé pertinent d'éviter précisément d'introduire un effet « secteur ». Dans ce contexte, nous n'avons procédé à aucun appariement de données, considérant les échantillons indépendants.

De manière plus spécifique, après examen des données collectées, nous avons dû retirer de la base, les entreprises pour lesquelles certaines données étaient manquantes. L'échantillon définitif est constitué de 455 entreprises défaillantes et 455 entreprises saines soit un total de 910 entreprises. Pour toutes les entreprises retenues, nous avons récupéré l'ensemble des informations comptables brutes extraites de la liasse fiscale : à savoir, le bilan et le compte de résultat concernant les exercices 2001, 2000 et 1999.

4.1.2 Sélection des grandeurs comptables et des ratios

Le choix des variables indépendantes est un problème fondamental dans l'élaboration d'un modèle de prédiction de défaillance. Il n'existe que peu de travaux ou de constructions théoriques permettant concevoir une trame cohérente de ratios et de grandeurs comptables (cf.

F. Jones, 1987, pp. 134-136) et le choix de ces derniers est généralement établi de manière empirique. Ainsi, J. Boritz (1991) n'identifie pas moins de 65 ratios utilisés dans les différents modèles de prédiction. M. Hamer (1983) suggère même que la capacité prédictive des modèles est relativement indépendante des ratios choisis. A l'inverse G. Karels et A. Prakash (1987) plaident plutôt pour un choix extrêmement sélectif. Dans l'ensemble, il s'avère qu'aucun modèle dominant n'a émergé jusqu'à présent, même si celui d'Altman (1968), puis d'E. Altman, R. Hadelman et P. Narayanan (1977) restent des références.

Dans ce contexte, nous avons préféré retenir l'ensemble des grandeurs comptables figurant dans les états financiers, sans distinction ni élimination aucune d'entre elles. L'intérêt est d'éliminer toute part de subjectivité dans ce choix, étant entendu que certaines variables peuvent avoir des effets portant sur la faillite, sans que cela soit intuitivement entendu.

En ce qui concerne le choix des ratios, il existe de fait, des dizaines de ratios qui pour certains, se recoupent plus ou moins. Dans ce contexte, il est difficile de concevoir un tirage aléatoire parmi une population de ratios, qui ne peut ni être exhaustive par définition, ni toujours pertinente en raison de ses redondances. Nous avons donc choisi de retenir des ratios liés aux différentes dimensions de l'analyse financière : structure financière, rotation, rentabilité, activité. Nous avons également retenu certaines des variables déjà présentes dans d'autres modèles (Conan-Holder, Score de la Banque de France), afin de prendre en compte l'expérience acquise, avec les limites que cela comporte.

Les soldes proposés par la base de données Diane sont les suivants : FRNG : fonds de roulement net global, BFR ; BFR : besoin en fonds de roulement ; T : trésorerie et ETE : EBE – variation du BFR. Nous avons calculé les ratios suivants : Txint : intérêts et charges sur dettes financières ; CAR : capacité de remboursement ; Inca : intérêts et charges sur chiffre d'affaires (CA) ; Salva : salaires et charges sociales sur valeur ajoutée (VA) ; Intva : intérêts et charges sur VA ; Resca : résultat de l'exercice sur CA ; frgnca : FRNG sur CA ; bfrca : BFR sur CA ; immca : immobilisations sur CA ; rescp : résultat de l'exercice sur capitaux propres ; varca : variation relative du CA ; cpdet : Capitaux propres sur dettes ; imoact : immobilisations sur actif ; resact : résultat de l'exercice sur actif ; tresca : trésorerie nette sur actif ; caemp : CA par employé ; ebedet : EBE sur dettes ; detfiac : dettes financières sur actif ; fiscoac : dettes fiscales et sociales sur actif.

4.2 Principaux résultats

Ne sont présentés dans ce travail, que les résultats significatifs obtenus à l'aide du logiciel SPSS. Nous présentons, dans un premier temps, une synthèse des comparaisons de médianes entre les différentes valeurs, aux fins d'analyse descriptive. Dans un second temps, nous présentons les résultats de la régression logistique.

4.2.1 Comparaison des médianes des deux groupes

Dans une première étape nous nous sommes attachés à comparer les médianes des différentes variables utilisées : variables comptables, soldes et ratios. Nous avons utilisé le test de Mann-Whitney (Z) qui a l'avantage d'être un test non paramétrique et qui s'impose dans le cas de

données indépendantes et non appariées. Le détail des résultats est présenté dans le tableau suivant :

	Probabilité	Seuil de signification	Z
age	0,00	***	-4,230
ca	0,00	***	-5,943
va	0,66	ns	-0,437
res	0,00	***	-17,501
CAF	0,00	***	-15,694
Immob	0,78	ns	-0,284
Immobinc	0,13	ns	+1,525
Immobcor	0,15	***	-1,445
ImmoFin	0,00	***	-5,342
Actif Circulant	0,07	*	-1,835
Stocks	0,00	***	-4,769
Clients	0,03	**	-2,202
VMP	0,00	***	-8,753
Disponibilités	0,00	***	-9,368
Autres actifs circulants	0,00	***	-7,074
Comptes de régularisation Actif	0,00	***	+5,232
Total de l'actif	0,14	ns	-1,471
Capitaux propres	0,00	***	-12,105
Capital social	0,00	***	-3,061
réserves	0,00	***	+8,375
Subventions d'investissement	0,36	ns	-0,912
Provisions pour risques et charges	0,02	**	-2,401
Dettes	0,00	***	-8,382
Dettes financières	0,01	**	-2,592
SCB et CBC	0,00	***	+10,043
Fournisseurs	0,00	***	-7,312
Dettes fiscales et sociales	0,00	***	+6,464
Autres dettes	0,00	***	-4,196
Comptes de régularisation Passif	0,57	ns	-0,565
Achats	0,79	ns	-0,266
Achats de marchandises	0,00	***	-4,200
Achats d'approvisionnements	0,00	***	-4,701
Production de l'exercice	0,00	***	-6,754
Marge commerciale	0,00	***	-4,009
Consommations de l'exercice	0,00	***	-8,347
Achats	0,00	***	-7,884
VA	0,66	ns	-0,437
Salaires et charges sociales	0,00	***	+6,506
ITVA1	0,00	***	-3,463
Subventions d'exploitation	0,00	***	+4,372
EBE	0,00	***	-13,729
Autres produits	0,01	**	-2,688
DAP	0,01	ns	+2,685
Rexploitation	0,00	***	-13,978
Produits financiers	0,00	***	-4,446
Charges financières	0,00	***	+10,520
Intérêts et charges assimilées	0,00	***	+11,170
RCAI	0,00	***	-16,580
Produits exceptionnels	0,00	***	+5,422

Cexcep	0,00	***	+7,804
Part	0,00	***	-5,828
IS	0,00	***	-15,341
EBE	0,00	***	-13,729
RS	0,00	***	-5,329
AlBrut	0,64	ns	+0,467
ES	0,54	ns	+0,618
FRNG	0,00	***	-11,778
BFR	0,00	***	-4,518
T	0,00	***	-13,487
Amor	0,04	**	+2,068
CA	0,00	***	-5,485
Txint	0,00	***	+11,746
Inca	0,00	***	+11,346
CAR (capacité de remboursement)	0,00	***	-10,780
Salva	0,00	***	+14,166
Intva	0,00	***	+3,361
Resca	0,00	***	-18,241
frgnca	0,00	***	-13,015
bfrca	0,00	***	-4,458
immca	0,27	ns	-1,114
rescp	0,00	***	-3,232
varca	0,00	***	-3,269
cpdet	0,00	***	-15,837
imoact	0,52	ns	-0,643
ete	0,00	***	-7,292
resact	0,00	***	-15,795
tresca	0,00	***	-11,765
ebedet	0,00	***	-17,020
detfiac	0,02	**	+2,248
fiscoac	0,00	***	-6,88

Dans ce tableau, nous avons calculé la différence entre les médianes des entreprises défaillantes et celles des entreprises saines. Un U négatif indique une médiane plus forte pour le groupe des entreprises saines, comparativement à celles défaillantes. Le seuil de signification est décrit de la manière suivante :

- ns : différence non significative
- * différence significative au seuil de 10 %
- ** différence significative au seuil de 5 %
- *** différence significative au seuil de 1 %

Aux fins d'analyse, on peut distinguer trois types de grandeurs¹² : les valeurs bilancielle et résultats, les soldes et les ratios.

- Valeurs bilancielle et résultats

Globalement, les valeurs associées aux entreprises défaillantes sont plus faibles que les entreprises saines. Cela peut s'expliquer par le fait que la taille des premières est généralement plus petite (facteur de fragilité ?) que les secondes ; mais, également par le fait que certains résultats sont naturellement plus faibles eu égard à la situation de l'entreprise.

¹² Nous ne retiendrons que les écarts statistiquement significatifs

Malgré tout, certains écarts positifs méritent d'être examinés de manière plus approfondie.

- sur le plan bilanciel : comptes de régularisation actifs, réserves, SCB et CBC (découverts), dettes fiscales et sociales. S'agissant des premiers, on peut s'interroger sur d'éventuelles manipulations permettant d'améliorer le résultat. Les SCB et CBC, dettes fiscales et sociales élevés apparaissent en revanche, cohérents par rapport à la situation de l'entreprise. Quant aux réserves, le caractère positif peut paraître contre-intuitif au premier abord, mais peut s'expliquer du fait de la relative jeunesse de certaines des entreprises faillies, lesquelles n'ont pas distribué des montants de dividendes importants ;
- sur le plan du résultat : salaires et charges sociales, subventions d'exploitation, amortissements, charges financières, intérêts et charges assimilées, produits et charges exceptionnelles. Le montant élevé des amortissements peut s'expliquer de deux manières : soit, l'entreprise a surinvesti par rapport à ses capacités d'écoulement des produits ; soit elle a été défailante au début de son existence, comme le confirme l'âge moyen des entreprises faillies, inférieur à celui des entreprises saines. Pour le reste, on retrouve des résultats conformes à la situation économique dégradée de l'entreprise défailante. Les autres grandeurs n'attirent pas de remarques particulières : on ne sera guère surpris, par exemple, de constater des subventions d'exploitation plus élevées, ces dernières ayant dû être obtenues en dernier recours.
- Soldes et ratios

Les ratios font apparaître quelques valeurs positives également, ce qui peut s'expliquer au moins techniquement, du fait que les valeurs sont relatives et donc, non influencées par la taille. Les valeurs positives concernent toutes des mesures sensibles en situation de crise pour une entreprise (taux d'intérêt apparent, intérêts sur chiffre d'affaires, salaires sur valeur ajoutée, intérêts sur valeur ajoutée, dettes financières sur actif) et n'appellent pas de commentaires particuliers.

Dans l'ensemble, cette approche descriptive permet de valider globalement le choix des variables, les résultats apparaissant intuitivement cohérents.

4.2.2 La régression logistique

Nous avons dans un premier temps, régressé l'ensemble des variables en nous limitant à celles de l'année 2001, sur la variable expliquée défaillance, en sélectionnant les variables à l'aide de la méthode backward stepwise. Un nombre de 888 entreprises a finalement pu être retenu après correction des valeurs manquantes. Plusieurs modèles aux performances voisines en matière de prédiction ont été élaborés. Nous avons choisi de retenir le modèle le plus simple. Les résultats sont résumés dans le tableau 4-1 suivant :

Variable	Signe du coefficient	Tests
Résultat de l'exercice	négatif	***
Constante	positif	*
	Entreprise saines	Entreprises défailtantes
Entreprises bien classées par le modèle	252	416
Entreprises de l'échantillon	410	488

On peut, dans ces conditions et compte tenu de l'excellent résultat obtenu, s'interroger sur les raisons du mauvais classement de certaines entreprises, afin d'améliorer le modèle. Un examen rapide montre par exemple, que certaines d'entre elles classées comme saines ont en réalité bénéficié d'augmentations de capital en dernier recours. Ceci montre que le modèle est relativement robuste. Dans l'autre sens, entreprises saines mal classées, les limites tiennent essentiellement aux accidents imprévisibles (décès du chef d'entreprise, retournement de conjoncture brutal pour une entreprise fragile, entreprise dépendante d'un ou deux clients qui font brutalement défaut, etc.) qui n'ont pas le temps de se refléter dans les grandeurs comptables et les ratios.

4.2.3 Limites et portée du modèle

S'agissant des valeurs et ratios retenus par le modèle, leur interprétation ne peut se faire *qu'a posteriori*, sachant que la sélection repose sur des critères purement statistiques. Le poids des salaires, de la structure financière et ses conséquences en termes de charges financières s'avère globalement déterminant. Cela n'est guère étonnant, puisque ces facteurs sont généralement sources ou indicateurs de difficultés. Leur influence se reflète tout particulièrement dans l'importance qu'ils prennent au sein de la valeur ajoutée.

Notons cependant, la place prise par la trésorerie, qui confirme, s'il en est besoin, son caractère déterminant dans la cessation de paiement. Il est clair que le modèle fait ressortir des variables probablement corrélées pour certaines d'entre elles, mais à ce niveau, il tente moins d'apporter une explication que de prouver son efficacité. Au demeurant, il permet de progresser en mettant en évidence le caractère critique de certaines grandeurs.

Dans l'absolu, la mise en évidence de certaines grandeurs et ratios tels qu'ils apparaissent dans le modèle, doit amener le chercheur comme le praticien à mesurer leur importance dans la prédiction de défaillance. La méthode utilisée est éminemment critiquable par son caractère empirique, mais elle vise à répondre à une question simple : est-il possible de prévoir la défaillance d'une entreprise avec un degré de fiabilité élevé ? Le modèle répond positivement à cette question et il pourrait être utilisé pour orienter le praticien dans sa démarche de diagnostic. Il présente l'avantage, d'une part de procéder à une présélection des entreprises à risque ; d'autre part, de détecter les ratios sensibles. En revanche, le modèle ne permet pas de tester des hypothèses *a priori*, qui ressortiraient d'une théorie ou d'un modèle type de la défaillance.

5 Conclusion

Cette étude, relativement lourde par le nombre d'entreprises constituant nos échantillons, montre qu'il est possible d'obtenir d'excellents résultats à l'aide d'une régression logistique. Encore, devons-nous ajouter que nous nous sommes limité au calcul d'un score multisectoriel, qui apparaîtra vraisemblablement moins performant qu'un score sectoriel. Mais, dans ce contexte, l'objectif est moins de présenter une méthode et d'évaluer ses atouts que de réaliser une performance dans l'absolu.

L'étude pourrait également et vraisemblablement, être enrichie de variables qualitatives –ce que ne permet pas l'analyse discriminante– afin d'augmenter le score et surtout, prendre en compte certains événements par définition, non quantifiables. Ces données (tels que par exemple, le nombre d'incidents bancaires ou l'âge du dirigeant...) ne sont cependant pas toujours simples à obtenir et il faudrait envisager à cette fin, une collaboration plus étroite avec le monde de la banque ou les sociétés externes de notation.

Nous avons par ailleurs testé la fonction sur une centaine d'entreprises hors échantillons. Afin de ne pas alourdir la présente étude, nous nous contentons de signaler des résultats supérieurs à 80 % de bons classements. De fait, le caractère prédictif de notre modèle nécessite encore d'être précisé et affiné.

Bibliographie

Allison, Paul D., 1999, "Comparing logit and probit coefficients across groups", *Sociological Methods and Research*, 28(2): 186-208.

Altman E., « Financial Ratios, Discriminant Analysis and the Prediction of Corporate Bankruptcy, *The Journal of Finance*, September 1968, pp. 589-609.

Altman E., Haldeman R., et Narayanan P., « ZETA analysis. A new model to identify bankruptcy risk of corporations », *Journal of Banking and Finance* 1, June 1977, 29-54.

Bardos M., « Développements récents de la méthode des scores de la Banque de France », *Bulletin de la Banque de France* n° 90, Juin 2001a, pp. 73-92.

Bardos M., *Analyse discriminante, application au risque et scoring financier*, Dunod, 2001b.

Bardos M. et Zhu W., « Comparaison de l'analyse discriminante linéaire et réseaux de neurones, applications à la détection de défaillance des entreprises », *Revue de statistique appliquée*, XLV (4), 1997, pp. 65-92.

Boritz J., "The "going concern" assumption: accounting and auditing implications", *Research Report*, Canadian Institute of Chartered Accountants (CICA), CICA, Toronto, Canada, 1991.

Commission européenne, « Document de travail des services de la commission sur les exigences de fonds propres applicables aux établissements de crédit et aux entreprises d'investissement », *Note de couverture*, novembre 2002, 38 p.

Comité de Bâle, « Vue d'ensemble du nouvel accord de base sur les fonds propres », *Banque des règlements internationaux*, janvier 2001, 36 p.

Eisenbeis R., "Pitfalls in the Application of Discriminant Analysis in Business and Economics", *The journal of Finance*, June 1977, pp. 875-900.

Hamer M., "Failure prediction: sensitivity of classification accuracy to alternative statistical methods and variable sets", *Journal of Accounting and Public Policy* 2, 1983, pp. 289-307.

Jones F., "Current techniques in bankruptcy predicting", *Journal of Accounting Literature* n° 6, 1987, pp. 131-164.

Karels G., & Prakash A., "Multivariate normality and forecasting of business bankruptcy", *Journal of Business Finance Accounting*, Winter 1987, 573-593.

Neter J., Kutner M., Nachtsheim C. et Wasserman W., *Applied Linear Statistical Models*, McGraw-Hil, 1996, 1408 p.

de Polignac (J.-F), *La notation financière*, Revue Banque Edition, 2002, 128 p.

Theodossiou P., "Alternative Models for Assessing the Financial Condition of Business in Greece", *Journal of Business Finance & Accounting*, Vol. 18, n° 5, Oxford, Sep 1991, pp. 697-721.

Press S. J. et S. Wilson, "Choosing between logistic regression and discriminant analysis", *Journal of the American Statistical Association*, Vol. 73, 1978, 699-705.

Rieg C., « Les défaillances d'entreprises : moindre baisse en 2001 », *INSEE Première*, n° 866, septembre 2002, 4 p.

Sauvage F., « Les délais de paiement : observation, réflexion et action », *Revue d'économie financière*, n° 54, 2002.

Thomas A., *Econométrie des variables qualitatives*, Dunod, 2000, 179 p.

Zavgren, C. V., "The prediction of Corporate Failure. The State of the Art", *Journal of Accounting Literature*, Spring 1983, pp. 1-38.

Zavgren, C. V., "Assessing the Vulnerability to Failure of American Industrial Firms. A logistic Analysis", *Journal of Business Finance and Accounting*, Spring 1985, pp. 19-45.