

CREDIT SCORING

**UMA METODOLOGIA DE GESTÃO PARA A PREVENÇÃO E REDUÇÃO DO
CRÉDITO MALPARADO**

António Manuel Sarmento Batista

Tese submetida como requisito parcial para obtenção do grau de

Doutor em Gestão Empresarial Aplicada

Orientador:

Prof. Doutor Carlos Gonçalves, ISCTE Business School, Departamento de Finanças

Co-orientador:

Prof.Doutor J. Dias Curto, ISCTE Business School, Departamento Métodos Quantitativos

Junho, 2009

Agradecimentos

À UNICRE, S.A. pela disponibilidade pessoal da Administração e Corpo Directivo, ao facultarem a base de dados que foi utilizada nesta dissertação.

Aos Professores Carlos Gonçalves e José Dias Curto pelo apoio e orientação, ao longo do trabalho de investigação.

Ao corpo docente da ISCTE Business School, ao seu Presidente, Professor António Gomes Mota e ao Director do Programa de Doutoramento (DBA), Professor Luís Bernardino, pelos seus ensinamentos e sugestões.

À minha mulher e ao meu filho, pela paciência que manifestaram ao longo dos últimos 4 anos e aos quais dedico este trabalho.

RESUMO

O crescimento do *crédito malparado* ou *crédito de cobrança duvidosa* tem merecido das instituições financeiras uma atenção permanente na melhoria do controlo do risco de crédito.

Este controlo visa regular a concessão de crédito segundo práticas que minimizem a probabilidade de incumprimento.

Quando a gestão do risco de crédito adopta políticas de crédito mais liberais, a probabilidade de ocorrerem créditos de cobrança duvidosa aumenta.

Uma parte do crédito malparado converte-se em incobrável, provocando prejuízos avultados.

A constatação deste **problema** há muito que foi reconhecida e consagrada pelo Acordo de Basileia II (Anexo 1) que entre várias recomendações sugeriu aos Bancos formas mais rigorosas de controlar o risco de crédito.

Segundo o *European Payment Index* (Anexo 3) o risco de pagamento na Europa evidenciou em 2008 um agravamento dos incobráveis, situando-se em 2% do total do crédito concedido. De acordo com este estudo, “Portugal, Grécia e Chipre são os países onde se demora mais tempo a pagar” (EPI 2008, p.4, Anexo 3).

Para **mitigar este problema** têm sido propostas diversas práticas, entre elas a quantificação probabilística do incumprimento traduzida por uma pontuação de risco, cuja identificação na gíria do discurso financeiro se designa por *scoring* ou *credit scoring*.

Neste contexto, o **objectivo** deste estudo é identificar factores explicativos capazes de prever a probabilidade de um devedor ser no futuro um *Bom* ou *Mau* pagador e avaliar a robustez preditiva do modelo utilizado para este efeito.

O projecto de investigação incidiu sobre o **crédito ao consumo** tendo a identificação daqueles factores explicativos sido feita através da utilização de uma base de dados de 4000 utilizadores de cartões de crédito, cujos hábitos de pagamento se conhecem *a priori*.

A **metodologia de investigação empírica** seguida neste projecto consistiu na aplicação do modelo de *regressão logística binária* aos dados em análise, por ser especialmente adequado ao estudo em causa e devido à sua simplicidade. A identificação dos factores explicativos (atributos) mais relevantes foi realizada através do método iterativo *forward stepwise* (*Likelihood Ratio*) e que consiste em seleccionar entre as variáveis

independentes aquelas cuja capacidade preditiva do comportamento de *Bom* ou *Mau* pagador é estatisticamente significativa.

A presente tese está estruturada em cinco capítulos: o Capítulo 1 faz a introdução da investigação; o Capítulo 2 trata a Revisão da Literatura; o Capítulo 3 descreve o referencial metodológico; o Capítulo 4 apresenta os resultados da metodologia aplicada; e o Capítulo 5 fecha o estudo com conclusões, contribuições esperadas e sugestões.

Palavras-Chave: *Credit scoring*, crédito malparado, *logit*, *revolving credit*.

Códigos de Classificação JEL: G17, G21, G32 e C13.

ABSTRACT

The increasing of *bad debts* or *credits of doubtful collection* has deserved a constant attention from financial institutions in order to improve credit risk control.

This control aim to guide credit granting process in accordance with practices that can minimize the probability default (PD).

When credit risk management reduces the appraisal risk methods the probability to get more credits of doubtful collections increases.

Part of bad debts turns into loans loss provoking huge damages to lenders.

The observation of such problem was recognized by Basel II Accord (Attached 1) who among several recommendations, was suggested to Banks to be more accurate in credit granting process and its risk control.

According to *European Payment Index* (Attached 3) the non-payment risk in Europe shown in 2008 an increase of loans losses getting 2% of total credit granting. In that survey “Portugal, Greece and Cyprus are the countries where it (payment) take longest to be paid...” (EPI 2008, p.4, Attached 3).

The **mitigation of this problem** will apply on several practices among them the quantification of a probability default translated by a risk measure, whose identification among financial institutions is known by *scoring* or *credit scoring*.

In this particular context, the **aim** of this study is to identify explanatory factors which are able to predict the likelihood of a borrower to be in a near future a *Good* or *Bad* payer and to evaluate the predictive robustness of the model used in this application.

The research project was focused on **consumer credit** segment and the identification of above explanatory factors was made through 4000 credit card users data base, whose payment behavior is *a priori* known.

The **research methodology** followed in this project lay in the application of the *binary logistic regression model* once this is especially suitable to this study and also due to its simplicity. The identification of the explanatory factors (attributes) has been carried out by *forward stepwise (Likelihood Ratio)* iterative method. This consists in selecting among the independent variables the most powerful predictive attribute, adding afterwards the following attributes according to their predictive power until no more attributes under certain level of significance were found.

The study comprises five chapters: Chapter 1 introduces the subject of the research presenting a review of the work done; Chapter 2 shows the Literature Review presenting some researches using statistical methods on credit scoring methodology; Chapter 3 describes the state of the art of credit scoring processes; Chapter 4 presents the Results of the study and the applied methodology; Chapter 5 makes the Conclusions and Suggestions for further works.

The second part is divided into two chapters dealing with the empirical side: the fourth chapter reports the way how the data was collected, how this was analyzed and transformed in order to be integrated in the statistical model; the fifth chapter deals with the application of logistic regression algorithm in the *in-sample* set data and a *holdout* sample was used as a final test of model performance.

Key words: Credit scoring, credit of doubtful collection, legit, revolving credit.

Classification Codes: JEL: G17, G21, G32 and C13.

ÍNDICE

	Pág.
CAPÍTULO 1 – INTRODUÇÃO	7
1.1 ESTRUTURA DA TESE	7
1.2 PROBLEMÁTICA DO ESTUDO.....	9
1.2.1 - ALGUNS REFLEXOS DO PROBLEMA EM PORTUGAL: PRAZOS MÉDIOS DE RECEBIMENTO	12
1.2.2 – ALGUMAS ORIGENS DO PROBLEMA ENTRE OS “PARTICULARES”	13
1.2.3 – MITIGAÇÃO DO PROBLEMA	15
1.3 OBJECTIVO DO ESTUDO	15
1.4 METODOLOGIA DE INVESTIGAÇÃO.....	16
1.4.1 REGRESSÃO LOGÍSTICA	17
1.5 ENQUADRAMENTO EMPÍRICO	19
1.6 LIMITAÇÕES DO ESTUDO	20
CAPÍTULO 2 – ENQUADRAMENTO TEÓRICO: REVISÃO DA LITERATURA	22
CAPÍTULO 3 - REFERENCIAL METODOLÓGICO: <i>CREDIT SCORING</i>	27
3.1 INTRODUÇÃO.....	27
3.2 RESENHA HISTÓRICA DO <i>CREDIT SCORING</i>	29
3.2.1 RESENHA HISTÓRICA DOS CARTÕES DE CRÉDITO EM PORTUGAL	31
3.3 <i>SCORING</i> DE ATRIBUIÇÃO	32
3.3.1 CRÉDITO AO CONSUMO EM PORTUGAL: INICIATIVAS LEGISLATIVAS.....	33
3.3.2 <i>SCORING</i> DE ATRIBUIÇÃO E A NECESSIDADE DE SE QUANTIFICAR O RISCO	34
3.3.3 SELECÇÃO CORRECTA DA POPULAÇÃO.....	35
3.3.4 DEFINIÇÃO DE <i>BOAS</i> E <i>MÁS</i> CONTAS	37
3.3.5 TAXA DE ACEITAÇÃO	38
3.3.6 CÁLCULO DA PONTUAÇÃO NUMA TABELA DE <i>SCORING</i>	39
3.3.7 RELATÓRIOS	41
3.3.7.1 De monitorização.....	41
3.3.7.2 De estabilidade das populações.....	42
3.3.7.3 De validação.....	45
3.3.7.4 De análise de características.....	45
3.3.7.5 De incumprimento por score e por exposição	46
3.3.7.6 Relatório Dinâmico de Incumprimento	49
3.3.8 PREPARAÇÃO DA TABELA DE <i>SCORING</i>	50
3.3.8.1 Perfil de risco	50
3.3.8.2 Concepção da tabela de scoring	51
3.3.8.3 Cálculo da Graduação da Escala	52
3.3.8.4 Escolha da tabela de scoring	54
3.3.9 CAPACIDADE PREDITIVA DE UMA TABELA DE <i>SCORING</i>	59
3.3.9.1 -Estatística Kolmogorov-Smirnov (KS)	60
3.3.10 <i>OVERRIDES</i> – DECISÕES PREVALECENTES	64
3.3.10.1 <i>Overrides</i> com base na informação	64
3.3.10.2 <i>Overrides</i> com base nas políticas da instituição	65
3.3.10.3 <i>Overrides</i> com base na intuição do analista de crédito.....	66
3.3.11 MUDANÇAS NA PONTUAÇÃO DO <i>CUTOFF</i>	67

3.4	<i>SCORING</i> COMPORTAMENTAL	69
3.4.1	<i>BOAS</i> E <i>MÁS</i> CONTAS NO <i>REVOLVING CREDIT</i>	71
3.4.2	<i>SCORING</i> COMPORTAMENTAL NA PRÁTICA: SISTEMA DE CONTROLO ADAPTÁVEL	73
3.4.3	CONTROLO ADAPTÁVEL	74
3.4.4	FACTORES CIRCUNSTANCIAIS NA REVALIDAÇÃO DE CARTÕES DE CRÉDITO	75
3.4.5	MODIFICAÇÃO NOS LIMITES DE CRÉDITO	77
3.4.6	COBRANÇAS	78
3.4.6.1	Contas que ultrapassam o limite de crédito	80
3.4.6.2	Autorizações para pagamentos com cartões de crédito	80
3.4.6.3	Estratégia “Campeã” versus “Desafiadora”	81
3.4.6.4	Comentários finais sobre scoring comportamental	83
3.5	ALGUNS COMENTÁRIOS	84
CAPÍTULO 4 – RESULTADOS		85
4.1	RECOLHA, ANÁLISE E TRANSFORMAÇÃO DE DADOS	85
4.1.1	RECOLHA DE DADOS	85
4.1.2	ANÁLISE DE DADOS	88
4.1.3	TRANSFORMAÇÃO DE DADOS	97
4.1.4	CARACTERIZAÇÃO DAS VARIÁVEIS POR MEDIDAS DE ESTATÍSTICA DESCRITIVA	100
4.2	APLICAÇÃO DO MODELO LOGIT AOS DADOS AMOSTRAIS	103
4.2.1	APLICAÇÃO DO MODELO AOS DADOS IN-SAMPLE	104
4.2.2	AValiação DA QUALIDADE DO AJUSTAMENTO	105
4.2.3	EFEITOS MARGINAIS DAS VARIÁVEIS EXPLICATIVAS SOBRE A PROBABILIDADE DE UM CLIENTE SER <i>BOM</i> PAGADOR	109
4.2.4	TESTE À HETEROCEDASTICIDADE DOS ERROS	118
CAPÍTULO 5 – CONCLUSÕES, CONTRIBUIÇÕES ESPERADAS E SUGESTÕES		122
5.1	CONCLUSÕES DO ESTUDO EMPÍRICO	122
5.2	CONCLUSÕES SOBRE A METODOLOGIA	123
5.2.1	INTRODUÇÃO	123
5.2.2	PRINCIPAIS CONCLUSÕES	124
5.3	CONTRIBUIÇÕES ESPERADAS	125
5.3.1	PARA A TEORIA	125
5.3.2	PARA A GESTÃO	126
5.3.3	PARA AS POLÍTICAS PÚBLICAS	126
5.4	SUGESTÕES PARA FUTURAS INVESTIGAÇÕES	127
BIBLIOGRAFIA		129
ANEXOS		135
ANEXO 1 - Acordo de Basileia II (Breve resumo)		135
ANEXO 2 – Maximum Likelihood Estimates (MLE)		143
ANEXO 3 – European Payment Index 2008		144

LISTA DE TABELAS

	Pág.
CAPÍTULO 1	
Tabela nº 1.1 Créditos de cobrança duvidosa. Fonte: Boletim Estatístico de Março 2009. Banco de Portugal.....	14
CAPÍTULO 2	
Tabela nº 2.1 Precisão de classificação de vários estudos. Comparação entre diversos métodos.....	25
CAPÍTULO 3	
Tabela nº 3.1 Número de candidaturas aceites e recusadas. Taxa de aceitação.....	38
Tabela nº 3.2 Tabela de <i>scoring</i> (parcial). Adaptação de Naeem Siddiqi (2006,p.6).....	39
Tabela nº 3.3 Índice de estabilidade populacional. Adaptação de Lewis-An Introduction to <i>Credit Scoring</i> (1992, p.147).....	44
Tabela nº 3.4 Relatório de análise de características. Adaptação de Lewis (1992, p.148).....	45
Tabela nº 3.5 Comparação entre as características dos candidatos actuais com os da população original. Adaptação de Lewis (1992, p.148).....	46
Tabela nº 3.6 Contagem na amostra de desenvolvimento por <i>score</i>	47
Tabela nº 3.7 Quantidade de candidaturas aceites com antiguidade de 12 meses.....	47
Tabela nº 3.8 Número de contas que foram aceites e o número destas que se mantêm activas, comparando as contas Más actuais com as contas Más no momento da criação do sistema de <i>scoring</i>	48
Tabela nº 3.9 Taxa de incumprimento para cada intervalo de <i>score</i> . A taxa de incumprimento desce à medida que o <i>score</i> aumenta	49
Tabela nº 3.10 Matriz de confusão 1.....	56
Tabela nº 3.11 Significado das classificações da matriz de confusão.....	56
Tabela nº 3.12 Matriz de confusão 2.....	57
Tabela nº 3.13 Classificação prevista vs classificação actual.....	58
Tabela nº 3.14 Quatro medidas para determinar a má classificação: Taxa de acerto; Taxa de erro; Sensibilidade e Especificidade	58
Tabela nº 3.15 Positivos verdadeiros, Positivos Falsos, Negativos Verdadeiros e Negativos Falsos.....	58
Tabela nº 3.16 Taxa de acerto, Taxa de erro, Sensibilidade e Especificidade: Cálculos.....	59
Tabela nº 3.17 Dados da amostra que serviram de base à construção do Gráfico nº 3.2.....	62
Tabela nº 3.18 Matriz de <i>cutoff</i>	63
Tabela nº 3.19 Estratégia de revalidação de cartões de crédito. Adaptação de Lewis (1992, p.125).....	76
Tabela nº 3.20 Tabela de estratégia (parcial). Adaptado de Lewis (1992, p.127).....	78
Tabela nº 3.21 Estratégia de cobrança. Adaptado de Lewis (1992, p.128).....	79
CAPÍTULO 4	
Tabela nº 4.1 Lista de características dos utentes de cartões de crédito relativos à amostra utilizada no estudo.....	88
Tabela nº 4.2 Tipologias de variáveis explicativas.....	89
Tabela nº 4.3 Tabela cruzada <i>ci_co_estado</i> (código de identificação de estado da conta) e <i>d_co_estado</i> (descrição do estado da conta)	89
Tabela nº 4.4 Descrição das contas por Códigos de Identificação.....	90
Tabela nº 4.5 Tabela cruzada <i>d_co_class</i> e <i>ci_co_class</i>	90
Tabela nº 4.6 Tabela cruzada <i>delinq_60 dias</i> e <i>delinq_90 dias</i>	91
Tabela nº 4.7 Tabela de frequência por <i>Género</i>	91
Tabela nº 4.8 Quantidade de <i>Bons</i> e <i>Maus</i> pagadores por <i>Género</i>	91
Tabela nº 4.9 Estado civil por frequência e <i>Género</i> por <i>Código(1)</i>	92
Tabela nº 4.10 Estado civil por frequência e <i>Género</i> por <i>Código (2)</i>	93
Tabela nº 4.11 Frequências de <i>Bons</i> e <i>Maus</i> por intervalos de <i>score</i>	94
Tabela nº 4.12 Estatísticas descritivas da característica “idade”.....	96
Tabela nº 4.13 Frequências das diversas tipologias de habilitações literárias.....	97
Tabela nº 4.14 Frequências de variáveis categóricas por <i>Código</i>	98
Tabela nº 4.15 Frequências dos atributos por categorias de <i>Referência</i> e de <i>Resposta</i>	99
Tabela nº 4.16 Medidas de estatística univariada.....	101
Tabela nº 4.17 Medidas de estatística descritiva das variáveis independentes.....	102
Tabela nº 4.18 Catorze variáveis independentes inicialmente consideradas no modelo.....	103
Tabela nº 4.19 Variáveis explicativas que permaneceram no modelo depois de excluídas as variáveis cujos coeficientes estimados não se revelaram estatisticamente significativos.....	104
Tabela nº 4.20 Resultados do Teste de Vuong.....	106
Tabela nº 4.21 Resultados do modelo de regressão logística, mostrando-se a taxa de acerto geral de 90,84%.....	107
Tabela nº 4.22 Tabela de classificação final.....	108
Tabela nº 4.23 Medidas de classificação: Taxa de acerto, Taxa de erro; Sensibilidade, Especificidade. Cálculos.....	108

Tabela nº	4.24	Matriz de classificação e respectivos gráficos.....	108
Tabela nº	4.25	Tabela dos efeitos marginais.....	110
Tabela nº	4.26	Frequências de <i>Bons</i> e <i>Maus</i> na característica <i>HabilitDummy</i>	113
Tabela nº	4.27	Característica <i>Habilit</i> por categorias de <i>Referência</i> e de <i>Resposta</i>	113
Tabela nº	4.28	Frequências de Más e Boas contas da variável independente <i>ci_co_class</i>	114
Tabela nº	4.29	Frequências dos atributos da características <i>ci_co_class</i>	114
Tabela nº	4.30	Frequências de Más e Boas contas da variável independente <i>Estado Civil (Dummy)</i>	115
Tabela nº	4.31	Frequências dos atributos da característica <i>Estado Civil</i>	116
Tabela nº	4.32	Frequências dos atributos da característica <i>Género</i>	117
Tabela nº	4.33	<i>Output</i> do EVIEWS ilustrando o procedimento Huber-White para obtenção dos coeficientes da regressão logística	119
Tabela nº	4.34	Valores dos coeficientes B das variáveis presentes na equação da regressão logística.....	120
Tabela nº	4.35	Dados da Tabela de Classificação “ <i>in-sample</i> ”	121
Tabela nº	4.36	Dados da Tabela de Classificação “ <i>holdout sample</i> ”	122

LISTA DE GRÁFICOS

	Pág.
CAPÍTULO 3	
Gráfico nº 3.1	39
Gráfico nº 3.2	42
Gráfico nº 3.3	61
CAPÍTULO 4	
Gráfico nº 4.1	93
Gráfico nº 4.2	95
Gráfico nº 4.3	96
Gráfico nº 4.4	110
Gráfico nº 4.5	111
Gráfico nº 4.6	111
Gráfico nº 4.7	112
Gráfico nº 4.8	113
Gráfico nº 4.9	115
Gráfico nº 4.10	116
Gráfico nº 4.11	117
ANEXO 1	
Gráfico nº A1.1	137

CAPÍTULO 1 – INTRODUÇÃO

A presente investigação apresenta como problema central o crescimento do crédito malparado ou crédito de cobrança duvidosa, no último lustro, em Portugal.

Entende-se por crédito malparado o empréstimo que não foi solvido pelo devedor na data de vencimento e cujo recebimento é duvidoso. Este problema resulta de várias causas, uma das quais a deficiente avaliação do risco de crédito.

Para mitigar este problema propõe-se o *Credit Scoring*. Esta metodologia consiste em avaliar a capacidade de crédito de uma pessoa utilizando métodos estatísticos.

Com base no problema identificado e no método de mitigação proposto, constitui o objectivo deste estudo identificar factores caracterizadores de um *Bom* e de um *Mau* pagador, aplicando aquela metodologia a uma determinada base de dados, e medir, através dos resultados obtidos, a robustez preditiva do modelo utilizado.

1.1 ESTRUTURA DA TESE

A presente tese está estruturada em cinco capítulos. Os capítulos estão divididos em secções e as secções em subsecções.

Capítulo 1 – Introdução

A Secção 1 apresenta a estrutura do conteúdo.

A Secção 2 trata o *problema* do crescimento do crédito malparado, referenciando-se o *Acordo de Basileia II* e o *European Payment Index 2008* como instrumentos de análise que corroboram a problemática em estudo; indicam-se algumas das origens do crescimento do crédito malparado em Portugal, relativamente ao segmento *particulares*; e a forma que se propõe para mitigar o problema.

A Secção 3 estabelece o objectivo do estudo, com base na identificação do problema e na metodologia que o mitiga.

A Secção 4 trata a metodologia de investigação, mostrando na subsecção 1 o modelo estatístico utilizado.

A Secção 5 faz referência ao enquadramento empírico, focando os testes estatísticos realizados.

A Secção 6 reporta as limitações presentes na elaboração do estudo empírico, apontando razões de confidencialidade inerentes à instituição financeira que facultou os dados e às restrições na “descodificação” das ferramentas informáticas por ela utilizados.

A Secção 7 endossa para o 2º Capítulo o relato de outros estudos relacionados com *credit scoring* que utilizaram métodos diferentes e que se apresentam na Revisão da Literatura.

Capítulo 2 – Enquadramento teórico: Revisão da Literatura

O segundo capítulo faz a Revisão da Literatura, apresentando sumariamente alguns de outros métodos mais utilizados em *credit scoring*.

Capítulo 3 – Referencial metodológico: *Credit scoring*

A Secção 1 faz uma descrição da forma que se encontrou para avaliar a capacidade de crédito das pessoas por métodos probabilísticos, utilizando sistemas de pontuação que conseguem discriminar os *bons* e os *maus* pagadores; explica o significado de *scoring de atribuição* e de *scoring comportamental*.

A Secção 2 faz uma resenha histórica do *credit scoring*, relatando as evoluções verificadas nos últimos 40 anos, e na subsecção 1 descreve-se a história dos cartões de crédito em Portugal, através de um breve resumo.

A Secção 3 explana as fases de construção de uma *tabela de scoring*, dando exemplos, do *scoring de atribuição*, ou seja dos métodos utilizados na atribuição de crédito a pessoas que o solicitam pela primeira vez.

A Secção 4 expõe as técnicas utilizadas na avaliação do comportamento dos devedores face ao pagamento e os métodos utilizados na cobrança desses créditos:- é o conjunto de técnicas designadas por *scoring comportamental*.

A Secção 5 avança com alguns comentários e razões que explicam as dificuldades de implementação desta metodologia nas pequenas e médias empresas em Portugal.

Capítulo 4 – Resultados

A Secção 1 trata a recolha, análise e transformação dos dados amostrais, relatando a forma como foram analisados e transformados para poderem ser incorporados no modelo estatístico.

A Secção 2 descreve na subsecção 1 a aplicação do modelo de regressão logística aos dados de 3200 utentes de cartões de crédito, designados por *in-sample data*, obtendo-se os resultados apresentados pelas taxas de acerto, na classificação de *bons* e *maus* pagadores; e na subsecção 2 realiza-se a validação do modelo através da utilização de uma *hold-out sample* referente a 800 utilizadores de cartões de crédito. Os resultados obtidos confirmam a robustez preditiva na classificação de um *bom* e *mau* pagador.

Capítulo 5 – Conclusões, contribuições esperadas e sugestões

A Secção 1 apresenta as conclusões do estudo, face aos resultados obtidos.

A Secção 2 enumera as contribuições esperadas do estudo para a Teoria, para a Gestão e para as Políticas Públicas.

A Secção 3 oferece algumas sugestões para futuras investigações.

1.2 PROBLEMÁTICA DO ESTUDO

Segundo Popper (1994), “As ciências naturais, bem como as ciências sociais, começam sempre por *problemas*, pelo facto de algo nos causar *espanto*, como os filósofos gregos costumavam dizer”.

Segundo o mesmo filósofo, para a resolução destes problemas, “as ciências usam fundamentalmente o mesmo método que o senso comum emprega, o método de *tentativa e erro*. Para ser mais preciso trata-se do método que consiste em *experimentar* soluções para o nosso problema e depois pôr de parte as falsas considerando-as erróneas. Este método pressupõe que trabalhem com um grande número de soluções *experimentais*. É testada e eliminada uma solução após outra”.

Considera ainda Popper (op.cit. pág.17) que “no fundo, este procedimento parece ser o único que é lógico”, apresentando um modelo de aprendizagem por *tentativa e erro* constituído por três fases: 1) o problema, 2) as tentativas de solução; 3) a eliminação.

Não obstante Popper não se considerar um adepto da corrente filosófica do *positivista*, mas antes um defensor do *realismo metafísico* (op.cit.p.43), o filósofo e antropólogo social

Ernest Gellner (1959) defende que Popper encontra-se, claramente, mais próximo do *positivismo* do que a tradição metafísica ou dedutiva.

Segundo uma perspectiva científicista, a filosofia positivista resumia a ideia de “ver para prever” e “prever para controlar”, o que de certa forma corresponde ao processo evolutivo do *scoring comportamental* (3.4) que analisa o comportamento dos incumpridores, para dessa constatação empírica prever o incumprimento futuro baseado em atitudes comportamentais semelhantes de outros devedores, controlando desta forma o crédito malparado.

Constata-se pela analogia anterior, que Popper “o que tinha estabelecido para as ciências naturais no seu grande livro *A Lógica da Pesquisa Científica* também tinha de ser válido como forma de abordagem das ciências sociais” (ver Coleção Grandes Pensadores, Karl Popper, Vida Pensamento e Obra, p.48).

O problema identificado por constatação empírica revela-nos que o crédito malparado em Portugal, tem crescido no último lustro. Este contínuo crescimento impõe medidas de gestão que atenuem o problema. Entre essas medidas existem métodos estatísticos utilizados na avaliação do risco de crédito. Essa avaliação será tanto melhor quanto maior for a capacidade preditiva do modelo utilizado.

A robustez preditiva de diferentes modelos utilizados na avaliação do risco de crédito tem constituído o foco de muitas investigações, nomeadamente os trabalhos de Altman (1968), Martin (1977), Press e Wilson (1978), Srinivisan (1987b), Boyle (1992), Crook *et al.* (1992), Henley (1995), Hand *et al* (1996), Desai (1997), Yobas (2000), entre outros.

Nestas pesquisas utilizaram-se diferentes algoritmos, designadamente função *Z-score* proposta por Altman em 1966, função *Zeta*[®] proposta por Altman, Haldeman e Narayanan em 1977, entre outros métodos discriminantes e cujos resultados têm evidenciado que uns têm maior força de previsão que outros, quando aplicados em situações e contextos diferenciados.

As tecnologias da informação (TI), por sua vez, têm dado um enorme contributo ao desenvolvimento e à diversidade de sistemas de suporte à decisão de crédito.

Não obstante estas preciosas ajudas para avaliação do risco de crédito e de suporte à decisão na concessão de crédito, continua a aumentar o nível de crédito malparado, muitas vezes fruto de *fenómenos estruturais* que inibem a potencialidade técnica destes esforços.

As entidades que detêm créditos malparados são: o Estado, as instituições financeiras, as empresas e os particulares.

a) O crédito que o Estado detém sobre os seus devedores tem, basicamente, a sua origem em impostos não recebidos das famílias, das empresas e das instituições financeiras. O crédito malparado do Estado é sobretudo de devedores em situação de insolvência, cujos processos judiciais ainda não transitaram em julgado.

Considera-se para fins legais, que um devedor está numa situação de insolvência quando se encontre impossibilitado de cumprir as suas obrigações vencidas¹.

b) O crédito detido pela Banca é originado na sua maioria por empréstimos concedidos às empresas, a particulares, a outros bancos e ao Estado. As empresas em dificuldades financeiras reconhecem que o acesso ao crédito bancário é determinante na sua sobrevivência, evitando o incumprimento com este credor. O crédito malparado da Banca pode ter tratamentos distintos, desde a renegociação da dívida com os seus clientes, à reclamação dos créditos por via judicial, ou através de execução de garantias reais.

c) O crédito detido pelas Empresas tem, principalmente, origem nos fornecimentos a crédito aos seus clientes. Em caso de incumprimento nas datas de pagamento o crédito pode, eventualmente, ser suspenso pela empresa credora. Quando tal acontece, regra geral, os devedores não pagam as suas dívidas vencidas, o que na maioria dos casos “obrigam” as empresas a continuar os fornecimentos a crédito, na expectativa de recuperação dos créditos mais antigos.

d) Entre os *particulares* existe uma diversidade de empréstimos não solvidos, muitos deles resolvidos por via judicial.

O reconhecimento do crescimento do crédito malparado relativamente à Banca está em parte evidenciado empiricamente por recomendações internacionais, nomeadamente pelas directrizes emanadas do *Acordo de Basileia II* (Anexo 1), e por índices internacionais como por exemplo o *European Payment Index 2008* (Anexo 3).

Uma das conclusões da Comissão de Basileia de Supervisão Bancária (*Acordo de Basileia*) em Junho de 2004, foi a de os bancos terem que controlar o risco de forma mais rigorosa, evidenciando um melhor reconhecimento das técnicas de mitigação do risco, utilizando o *scoring comportamental* na avaliação dos clientes e de gerir melhor as suas bases de dados (*Pilar I*).

¹ DL n° 116/2008, de 04/07. §1, Art. 3°

Refere ainda o *Acordo (Pilar 3)*, que os bancos terão de divulgar mais informação sobre as fórmulas que utilizam para a gestão do risco do crédito, bem como implementar uma disciplina de mercado que vise a obtenção de práticas bancárias mais saudáveis e seguras.

Desde logo, vislumbra-se que a prevenção e redução do crédito malparado é uma das preocupações do *Acordo de Basileia II* ao reconhecer que os Bancos não têm controlado o risco da concessão de crédito tão eficazmente quão desejável, tendo esta recomendação como base a constatação de práticas bancárias pouco seguras.

1.2.1 - ALGUNS REFLEXOS DO PROBLEMA EM PORTUGAL: PRAZOS MÉDIOS DE RECEBIMENTO

O crédito malparado é a designação atribuída pelas instituições financeiras, não-financeiras e governamentais, às dívidas de clientes/utentes/contribuintes cuja cobrança se apresente duvidosa, quer estas dívidas estejam ou não em litígio.

O momento a partir do qual, um crédito assume aquela designação, corresponde ao momento em que se procede a registos contabilísticos, debitando-se a conta de “clientes de cobrança duvidosa”. Quando estes créditos passem a considerar-se *incobráveis* e no caso de não se encontrarem provisionados, serão, então, considerados como *custos e perdas extraordinárias*, debitando-se, contabilisticamente, a respectiva conta de resultados (POC, Fev.2009).

Os créditos de cobrança duvidosa têm como génese da sua existência os prazos de pagamento que, de um modo geral, excederam, há muito, as datas de vencimento, originando a designação de “malparado” e a execução dos critérios e procedimentos contabilísticos acima referidos.

Nesta matéria e segundo os relatórios do *European Payment Index 2008* (Anexo 3), Portugal, em 2008, conjuntamente com a Grécia e Chipre foram os países onde se demora mais tempo a pagar (Anexo 3, EPI 2008, p.4)

Os pagamentos tardios verificados em Portugal influenciam negativamente a imagem nacional face a outros países que evidenciam melhores desempenhos.

Este comportamento no pagamento tardio das dívidas gera dificuldades na consolidação da confiança.

A imagem da confiança promove a concorrência entre países, nomeadamente na captação de investimento estrangeiro. Neste pressuposto, o alargamento da comunidade a 27 países aporta maiores desafios de competitividade a Portugal.

Um desses reptos é a capacidade de se evidenciar um conjunto de indicadores macro-económicos e de políticas fiscais que permitam conquistar a confiança dos investidores nacionais e estrangeiros.

Neste contexto, tem constituído preocupação dos sucessivos governos a captação desse investimento como forma de reduzir o desemprego, aumentar a competitividade entre os pares e garantir um crescimento económico sustentado.

O indicador *prazo médio de recebimento* verificado em Portugal pode ser considerado pelos investidores, quer nacionais quer estrangeiros, como um ponto fraco do esmero económico nacional, podendo reduzir as vantagens competitivas nacionais face a outros países que revelem melhores desempenhos.

1.2.2 – ALGUMAS ORIGENS DO PROBLEMA ENTRE OS “PARTICULARES”

Entre os *fenómenos estruturais*, atrás referidos (pág.10), encontramos algumas das razões que substanciam a origem do crédito malparado em Portugal, nomeadamente razões de âmbito socio-económico.

O fenómeno social fortemente associado aos créditos de cobrança duvidosa, entre os *particulares* é o designado infortúnio 3D (*Desemprego, Doença e Divórcio*).

a) O desemprego está fortemente associado a ciclos económicos e tem constituído um dos maiores flagelos em todo o Mundo, prevendo-se que atinja 210 milhões de pessoas dos quais 57 milhões nos países da OCDE em 2010, segundo a Organização Internacional do Trabalho (OIT). Portugal, infelizmente, não é excepção.

A situação presente (2009) de desempregados em Portugal já ultrapassa o meio milhão de pessoas. Aos números do desemprego oficial do Instituto Nacional de Estatística (INE) (4º Trimestre 2008) devem ser adicionados os desempregados que não constam do inquérito trimestral realizado pelo INE, designados por *inactivos disponíveis*, isto é, pessoas que estão desempregadas mas que desejam trabalhar e as *sub-empregadas* que são na prática pessoas desempregadas, que trabalham menos de 15 horas semanais. Mantendo-se esta baixa no ciclo

económico haverá, necessariamente, um aumento das taxas de crédito malparado e uma retracção maior dos bancos na concessão de empréstimos à habitação e ao consumo.

b) A doença tem sido, a par com o desemprego, outra das razões que motivam o incumprimento e o incumprimento definitivo no pagamento de dívidas. A doença inibe parcial ou totalmente a capacidade para o trabalho, impedindo obter remunerações suficientes, capazes de garantir o pagamento dos compromissos assumidos.

c) O divórcio é outra das causas, normalmente citadas pelas instituições financeiras e pela DECO (Associação Portuguesa para a Defesa dos Consumidores), para o crescimento das taxas verificadas no crédito malparado.

O divórcio como elemento desestruturante das famílias, cria de um modo geral maiores dificuldades financeiras a cada um dos ex-cônjuges, quer pela necessidade de liquidarem compromissos comuns, quer pela necessidade de contraírem novos empréstimos.

Entre os *créditos de cobrança duvidosa* no segmento *particulares* destacam-se os de maior peso: o *crédito à habitação* e o *crédito ao consumo*.

Habitação			
	Empréstimo	Cobrança Duvidosa	Cob.Duvid.(%)
Dez-04	70.835.000.000	1.072.000.000	1,51%
Dez-05	79.237.000.000	1.177.000.000	1,49%
Dez-06	91.591.000.000	1.139.000.000	1,24%
Dez-07	100.585.000.000	1.264.000.000	1,26%
Dez-08	104.466.000.000	1.570.000.000	1,50%
Consumo			
	Empréstimo	Cobrança Duvidosa	Cob.Duvid.(%)
Dez-04	9.059.000.000	454.000.000	5,01%
Dez-05	9.406.000.000	292.000.000	3,10%
Dez-06	11.379.000.000	369.000.000	3,24%
Dez-07	13.790.000.000	505.000.000	3,66%
Dez-08	15.452.000.000	759.000.000	4,91%
Outros fins			
	Empréstimo	Cobrança Duvidosa	Cob.Duvid.(%)
Dez-04	10.518.000.000	456.000.000	4,34%
Dez-05	11.157.000.000	517.000.000	4,63%
Dez-06	12.007.000.000	490.000.000	4,08%
Dez-07	12.902.000.000	438.000.000	3,39%
Dez-08	12.656.000.000	548.000.000	4,33%
Total			
	Empréstimo	Cobrança Duvidosa	Cob.Duvid.(%)
Dez-04	90.412.000.000	1.982.000.000	2,19%
Dez-05	99.800.000.000	1.986.000.000	1,99%
Dez-06	114.977.000.000	1.998.000.000	1,74%
Dez-07	127.277.000.000	2.207.000.000	1,73%
Dez-08	132.574.000.000	2.877.000.000	2,17%

Tabela nº 1.1 Créditos de cobrança duvidosa Fonte: Boletim Estatístico de Março 2009 Banco de Portugal

1.2.3 – MITIGAÇÃO DO PROBLEMA

A mitigação do problema do crescimento do crédito malparado pode recorrer a diversas “terapias”. Neste estudo, optou-se por uma metodologia capaz de detectar atempadamente situações de potencial incumprimento em pagamentos futuros, através de *processos* que consigam identificar factores que explicam e que prevêem tais comportamentos.

Aqueles *processos*, como métodos preventivos capazes de reduzir e de evitar o incumprimento, não estão suficientemente divulgados e disseminados no tecido empresarial das pequenas e médias empresas nacionais e estrangeiras.

Este facto tem particular incidência na qualidade da gestão do risco de crédito, levando as instituições financeiras e não-financeiras a reagir ao incumprimento dos seus devedores num momento em que as probabilidades de recebimento são já muito reduzidas ou mesmo nulas.

Neste sentido, quer seja na concessão de crédito à habitação, crédito ao consumo, crédito bancário às empresas, quer ainda no crédito entre empresas, o *problema* é rigorosamente o mesmo, ou seja, verifica-se a necessidade de se identificar com antecedência necessária situações de potencial incumprimento.

1.3 OBJECTIVO DO ESTUDO

Sendo o crescimento do crédito malparado o *problema* identificado e a metodologia *Credit Scoring* o seu mitigativo, pretende-se com a presente tese:

- identificar factores explicativos capazes de prever a probabilidade de um devedor ser no futuro um *Bom* ou *Mau* pagador;
- avaliar a robustez preditiva do modelo estatístico, aplicado em situações de concessão de crédito rotativo (*revolving credit*²).

Nesse sentido, é nosso propósito:

1- Dar a conhecer a metodologia capaz de mitigar o problema:

- a) referenciando através da Revisão da Literatura (Capítulo 2) os principais estudos realizados sobre *Credit Scoring*;

² Crédito concedido ao consumidor, dando-lhe a opção de contrair empréstimos até um determinado limite de crédito, podendo amortizar total ou parcialmente a dívida, mediante o pagamento de um juro sobre o remanescente da dívida, no período estipulado.

- b) contribuindo para o entendimento e aplicação daquela metodologia em empresas que a pretendam implantar (Capítulo 3).
- 2- Analisar experimentalmente a capacidade preditiva do modelo estatístico, através da utilização instrumental de uma base de dados de utilizadores de cartões de crédito (Capítulo 4 - Resultados).

1.4 METODOLOGIA DE INVESTIGAÇÃO

Segundo Madeira (2009), a *metodologia* “ é uma disciplina normativa que tem por objecto o estudo sistemático e lógico dos princípios que dirigem qualquer pesquisa científica, desde os pressupostos básicos, até às técnicas de investigação”.

Considera a mesma investigadora que “a metodologia, mais do que uma descrição formal de técnicas e métodos a serem utilizados na pesquisa científica, indica a opção que o pesquisador fez para resolver determinada situação, ou problema (que pode(m) ser teórico(s) ou prático(s)) relacionado(s) com o seu objecto de investigação o qual tem de ser, obrigatoriamente, desenvolvido dentro de um quadro científico, enquadrado/enquadrável no paradigma(s) ou teoria(s) vigentes”.

Na metodologia de investigação seguida, descrevem-se *métodos* diferentes que foram utilizados no *credit scoring*, entendendo a mesma investigadora que “ O método (methodos) é um procedimento científico, reflexivamente ordenado, constituído por instrumentos básicos, aos quais se aplica, de forma adequada, a reflexão/conjectura e a experimentação.

O método tem por objectivo orientar todo o percurso da pesquisa, de modo a alcançar os objectivos preestabelecidos no projecto de pesquisa”.

Da revisão da literatura (Capítulo 2) ressaltam os *modelos* matemáticos que representam uma conceptualização econométrica aplicada aos dados empíricos recolhidos pelos investigadores nas respectivas investigações sobre *credit scoring*.

Ainda segundo Madeira (op.cit.), “Modelo é uma representação conceptual, ou física, de um processo, ou de um sistema, ou, ainda, de um fenómeno ou de um objecto”.

Configurado o significado da linguagem utilizada, descreve-se no parágrafo seguinte o *modelo* de regressão logística.

1.4.1 REGRESSÃO LOGÍSTICA

Através da revisão da literatura, constatámos que muitos investigadores estudaram o tema do *credit scoring* segundo métodos diferentes, ao longo dos últimos anos.

Da literatura revista seleccionámos o modelo de *regressão logística* por ser especialmente adaptável aos casos em que existe uma variável dependente binária ou dicotómica.

O primeiro estudo foi realizado por Ohlson (1980). Wiginton (1980) foi um dos primeiros investigadores a publicar os resultados sobre *credit scoring* utilizando esta técnica.

A *regressão logística* também foi aplicada por Zavgren e Friedman (1988), Aziz e Lawson (1989), Persons (1999), Wilson, Summers e Hope (2000), Eklund, Larsen e Bernhardsen (2001), Westgaard e Wijst (2001), Hayden (2002), Platt e Platt (2002), Dong (2007), Mavri *et al.* (2008).

Não obstante existirem outros modelos alternativos, nomeadamente a *análise discriminante*, *regressão linear*, *árvores de classificação*, *redes neuronais artificiais*, *algoritmos genéticos*, *programação linear*, entre outros, iremos aplicar a *regressão logística* devido sobretudo à sua simplicidade e adaptabilidade ao presente estudo.

A *regressão logística* comparativamente com a *análise discriminante* tem a vantagem de não ter de atender aos pressupostos rígidos desta última (ver Kaltofen, Möllenbeck e Stein(2004), Ewert e Szczesny (2002), Jagtiani *et al.* (2000), Maddala (1983), Ohlson (1980), Press e Wilson (1978), Martin (1977)).

A *regressão linear* é algumas vezes utilizada para estimar modelos de *scoring*, embora seja a *regressão logística*, regra geral, preferida por ser especialmente adaptável aos casos em que existe uma variável dependente binária.

Um dos problemas da utilização da *regressão linear* é o facto de poder produzir valores estimados para a probabilidade maiores que um e menores que zero, o que é estatisticamente incorrecto.

O modelo *logit*³ evita tal situação porque se baseia na função de distribuição logística estandardizada, garantindo que os valores estimados permaneçam necessariamente entre zero e um.

A aplicação do modelo de regressão logística ao presente estudo mostra-se particularmente apropriada, porquanto a variável dependente assume os valores 0 e 1, cujo significado se convencionou designar por *Mau* e *Bom* desempenho da conta, respectivamente.

Neste sentido, considerou-se uma variável dependente binária que assume o valor 1 quando o cliente é *Bom* pagador e 0 quando tal não acontece. A probabilidade de ser *Bom* pagador vai ser estimada a partir do modelo *logit*:

$$p(Y_i = 1) = \frac{1}{1+e^{-z_i}} + \varepsilon_i, \quad (1.1)$$

em que:

$$Z_i = \beta_0 + \beta_1 x_{1j} + \dots + \beta_k x_{kj} \quad (1.2)$$

Sendo:

β_k os parâmetros do modelo

x_{kj} as variáveis que representam os factores explicativos da probabilidade de cada utente ser *Bom* pagador.

ε_i o erro.

Os parâmetros do modelo foram estimados pelo método da máxima verosimilhança e a equação estimada permite relacionar a probabilidade de um cliente ser *Bom* pagador com os atributos relevantes considerados.

Para seleccionar de entre as 21 variáveis explicativas originais (número de variáveis identificadas na base de dados facultada pela instituição financeira e que serviu de suporte ao

³ O termo *logit* foi introduzido pelo estatístico americano Joseph Berkson (1899–1982), por analogia do termo *probit* cujo modelo foi desenvolvido pelo biólogo americano Chester Ittner Bliss in 1934.

estudo empírico), aquelas que são mais relevantes para estimar a probabilidade de um cliente ser *Bom* pagador, recorreremos ao método *forward stepwise*.

Este método baseia-se no poder explicativo incremental que cada uma das variáveis explicativas a introduzir no modelo tem sobre a variável dependente reflectido no incremento da função de verosimilhança.

O método consiste em iniciar o modelo de regressão sem incluir qualquer uma das variáveis explicativas, introduzindo a cada iteração as variáveis mais importantes e excluindo as menos importantes, até à conclusão do processo de selecção.

1.5 ENQUADRAMENTO EMPÍRICO

O estudo tem como moldura empírica uma série de testes estatísticos que, de acordo com a base de dados utilizada, visam identificar, dentro da amostra utilizada, as variáveis mais determinantes na classificação de um utente de cartão de crédito ser um *Bom* ou *Mau* pagador.

A parte instrumental desta investigação foi feita através da aplicação do modelo de regressão logística aos dados de 4000 utentes de cartões de crédito, cujo comportamento de pagamento se conhece *a priori*.

O conhecimento do comportamento de pagamento daqueles utilizadores permitirá classificar futuros utentes, que revelem similitude comportamental.

Os dados recolhidos foram analisados, identificando-se 21 factores que caracterizam aqueles utilizadores de cartões de crédito. Estes factores foram agrupados em 3 tipos (qualitativos, quantitativos e datas).

Depois de os dados terem sido analisados e de forma a serem considerados no modelo estatístico, procedeu-se à transformação das variáveis qualitativas em variáveis numéricas fictícias (variáveis *dummy*) seguindo o critério de classificação proposto por Anderson (2007, pág.359).

Em seguida, aplicou-se o modelo de regressão logística aos dados seleccionados.

1.6 LIMITAÇÕES DO ESTUDO

O contacto com instituições financeiras, capazes de facultar elementos que permitissem aplicar a metodologia preconizada a dados reais, foi muito difícil e na maioria dos casos de todo impossível.

A necessidade de obter dados tratados segundo critérios definidos pelo autor foi uma das principais razões apresentadas para o insucesso deste desiderato.

A simples constatação do crescimento do crédito malparado verificado em Portugal, no último lustro, é facilmente observável, quer por dados do INE quer pelos relatórios do BdP. Contudo o objectivo do presente estudo visa identificar factores comportamentais e demográficos capazes de prever a probabilidade de cumprimento e/ou incumprimento de entidades devedoras perante os seus credores e avaliar, através de uma taxa de acerto de *Bons* e *Maus* pagadores, a robustez preditiva do modelo estatístico aplicado a situações de crédito rotativo.

Não obstante as dificuldades encontradas em diversas entidades financeiras, conseguiu-se obter junto de prestigiada instituição emissora de cartões de crédito, ao fim de um certo tempo, o material que viabilizou a elaboração da parte empírica do presente projecto de investigação.

A análise quantitativa, do estudo que se apresenta, foi condicionada à base de dados obtida junto daquela entidade financeira. Por certo que existiriam outros elementos que gostaríamos de incluir neste estudo, nomeadamente a análise aos documentos originais dos candidatos a crédito, aos relatórios das agências de informação de crédito, informações do Banco de Portugal e todo o histórico dos 4000 clientes, mas compreendemos que as instituições financeiras regem-se por políticas de confidencialidade e por restrições impostas por aquelas políticas que as impedem de estar tão disponíveis para a divulgação desses dados, quanto a dimensão desta investigação ambicionaria.

Por outro lado, a metodologia de *credit scoring* subjacente aos processos de avaliação do risco de crédito, que sustenta a funcionalidade desses programas informáticos, constitui um direito de propriedade intelectual resultante do *know-how* dos fabricantes daqueles sistemas de *scoring*, salvaguardado por marcas registadas protegidas por lei, e cujos conteúdos não estão acessíveis, constituindo verdadeiras *black boxes* de difícil penetração e interpretação, mesmo para as instituições financeiras utilizadoras daqueles sistemas.

Constituindo as limitações referidas uma restrição à presente investigação é também um sinal de oportunidade para investigações futuras poderem desenvolver projectos nacionais e internacionais para a construção de novos sistemas de *credit scoring*.

O benefício da sua utilização em empresas de pequena e média dimensão contribuiria, significativamente, para a prevenção e redução do crédito malparado.

Não obstante esta limitação, o estudo desenvolve-se através de um processo que pode ser replicado em função de outras bases de dados de outras instituições financeiras ou não-financeiras.

CAPÍTULO 2 – ENQUADRAMENTO TEÓRICO: REVISÃO DA LITERATURA

A necessidade de estimar a probabilidade de incumprimento no pagamento de uma dívida conduziu os especialistas em *credit scoring* ao aperfeiçoamento de técnicas estatísticas capazes de discriminar entre *Bons* e *Maus* pagadores.

A mesma necessidade tem-se verificado em conseguir prever a continuidade de empresas no mercado, separando as *Boas* das *Más* empresas, através da identificação de determinadas características que permitam prever a probabilidade de umas se manterem e de outras falirem.

A literatura sobre estas matérias já não é recente, distando mais de quarenta anos o estudo realizado por Beaver (1966), que tem sido considerado como a investigação pioneira no desenvolvimento deste tipo de previsão.

Actualmente conta-se com uma série de trabalhos de investigação que versam esta temática, nomeadamente Jones (1987), Dimitras, Zanakis e Zopounidis (1996), Altman e Saunders (1998), Balcaen e Ooghe (2004) e Altman e Hotchkiss (2006), Dong (2007), Mavri *et al.* (2008).

Alguns dos estudos paramétricos de *credit scoring* frequentemente citados na literatura especializada, contam com os contributos de Beaver (1966), Altman (1968), Ohlson (1980) e Shumway (2001).

Beaver (1966) utilizou a *análise discriminante univariada*, demonstrando que os rácios financeiros podem ser usados para prever a insolvência das empresas. A partir de aqui, os estudos sobre insolvência foram, sucessivamente, melhorados e refinados.

Altman (1968) introduziu a *análise discriminante multivariada*, modelo que ficou conhecido por *Z-score*, tendo-lhe permitido identificar num conjunto de 66 empresas aquelas que manifestavam forte tendência para a insolvência.

Mais tarde, Altman, Haldeman e Narayanan (1977) desenvolveram um novo modelo que designaram por *Zeta*[®]. Os modelos *Z-score* e *Zeta*[®] foram ainda referenciados em investigações mais recentes, nomeadamente por Holmen (1988), Shumway (2001), Ooghe e Balcaen (2002), Chava e Jarrow (2004).

No culminar da década de 1970 imperavam os modelos suportados na *análise discriminante multivariada*.

Contudo, foram identificados alguns problemas nesta técnica estatística que assumia a presunção de uma distribuição normal multivariada das variáveis consideradas.

Eisenbeis (1978) apontou alguns problemas na utilização da análise discriminante multivariada, designadamente a distribuição das variáveis; a igualdade *versus* desigualdade das dispersões dos grupos; o papel do peso das variáveis individuais; problemas derivados da redução do número de variáveis; problemas na definição dos grupos (a análise discriminante assumia que os grupos alvo de investigação eram discretos e identificáveis); uso inapropriado de probabilidades *ex-ante* na classificação de grupos; problemas de classificação na estimativa das taxas de erro, no acesso ao desempenho do modelo.

Da revisão da literatura (Fair & Isaac, 2006) ressalta que o objectivo na análise discriminante tem geralmente duas opções: - Segmentar ou separar indivíduos em dois ou mais grupos previamente definidos; e classificar um novo indivíduo num desses grupos.

Nas décadas de 1940 e 1950 vários pesquisadores sobressairam-se pelas suas contribuições pioneiras, nomeadamente, McCulloch e Pitts (1943) que introduziram a ideia de *redes neuronais artificiais (RNA)* como máquinas computacionais; Hebb (1949) postulou a primeira regra de aprendizagem auto-organizada; e Rosenblatt (1958) propôs o *perceptron* como o primeiro modelo para aprendizagem supervisionada. Só alguns anos depois Makowski (1985) e Coffman (1986) a aplicaram ao *credit scoring* inspirados nos trabalhos realizados sobre inteligência artificial.

Uma outra estatística utilizada para classificar e discriminar grupos completamente diferente das referidas até ao momento é designada por *árvores de decisão*, também denominada por *algoritmos de partição repetitiva (recursive partitioning algorithms - RPA)*. A literatura sobre *árvores de decisão* oferece uma larga escolha destes algoritmos, os quais diferem em termos de desempenho, condições e campos de aplicação (Hadidi, 2003; Loh e Shih, 1997; Quinlan, 1993 e 1986; Biggs, de Ville e Suen, 1991; Breiman et al., 1984; Kass, 1980).

Safavian e Landgrebe (1991) utilizaram a mesma estatística para classificação de problemas, embora com nomes diferentes (CHAID⁴ e C5), se bem que os seus métodos fossem idênticos.

De entre outros métodos utilizados no *credit scoring*, o *algoritmo genético* é um procedimento que serve para procurar, sistematicamente, no seio de uma população, soluções potenciais para a resolução de um problema.

Não obstante a proficuidade de modelos estatísticos desenvolvidos nos últimos quarenta anos, outros métodos (não-estatísticos) trilharam um caminho semelhante.

Até 1980 os únicos trabalhos conhecidos eram baseados em análise estatística, mas Freed e Glover (1981a), (1981b) reconheceram na *programação linear* uma forma mais eficiente em discriminar dois grupos quando estes não são linearmente separáveis, utilizando, para tal, objectivos que minimizassem quer a soma dos erros absolutos, quer o erro máximo.

Uma vantagem da *programação linear* sobre os métodos estatísticos, no *credit scoring*, é a facilidade em incluir o enviesamento no desenvolvimento de uma *tabela de scoring*.

Entre a literatura especializada deparámo-nos com alguns investigadores que defendem que as técnicas tradicionais classificam os candidatos a crédito de forma mais correcta do que as técnicas evolucionárias. Outros investigadores, porém, defendem o contrário.

Por exemplo, Desai *et al.* (1996) quando utilizaram dados de três associações de crédito detectaram que quando classificavam empréstimos aceites em *Bons* e *Maus*, as *redes neuronais* classificavam correctamente uma grande percentagem de ambos, na totalidade das amostras.

Mas quando os *modelos genéricos* eram introduzidos no estudo comparativo, as *redes neuronais* eram superiores, apenas na predição de *Maus*.

King *et al.* (1994) compararam um grande número de algoritmos incluindo *análise discriminante linear*, *redes neuronais* e *árvores de decisão* (mas não *algoritmos genéticos*) e encontraram que a *análise discriminante linear* prevê pior do que vários tipos de *árvores de decisão*, mas melhor do que as *redes neuronais*.

Por outro lado, Desai *et al.* (1997) aplicaram a mesma base de dados que em 1996 para uma classificação de 3 grupos (*Bons*, *Fracos* e *Maus*) e incluíram os *algoritmos*

⁴ Chi-squared Automatic Interaction Detector

genéticos no estudo comparativo, e detectaram que a *regressão logística* era superior aos outros métodos, excepto para a classificação dos *fracos*, onde as *redes neuronais* evidenciaram maior capacidade preditiva.

Ao classificarem a amostra total, revelaram que o desempenho da *análise discriminante linear* era quase idêntica às *redes neuronais* e ligeiramente melhor do que os *algoritmos genéticos*.

Os métodos acima, resumidamente, descritos para desenvolvimento de ferramentas aplicáveis ao *credit scoring* têm sido objecto de estudos comparativos realizados, nomeadamente, por Srinivasan (1987b), Boyle (1992), Henley (1995), Yobas (1997) e Desai (1997).

Thomas *et al.* (2002, p.86) e Anderson (2007 p.185) transcrevem a mesma compilação comparativa dos estudos realizados sobre a precisão de classificação para os diferentes métodos:

Investigador	Regressão Linear	Regressão Logística	Árvores de Classificação	Programação Linear	Redes Neuronais	Algoritmos Genéticos
Srinivasan (1987b)	87,5	89,3	93,2	86,1	-	-
Boyle (1992)	77,5	-	75,0	74,7	-	-
Henley (1995)	43,4	43,3	43,8	-	-	-
Yobas (1997)	68,4	-	62,3	-	62,0	64,5
Desai (1997)	66,5	67,3	-	-	66,4	-

Tabela nº2.1 Precisão de classificação de vários estudos - Comparação entre diversos métodos

Da tabela nº2.1 podemos observar que os testes realizados por Srinivasan (1987b), o modelo de regressão logística apresentou o segundo melhor resultado na taxa de acerto ou taxa de precisão de classificação, enquanto os testes de Henley (1995) a regressão logística mostrou resultados idênticos aos métodos da regressão linear e às árvores de classificação, que foram aplicados à mesma base de dados.

O estudo comparativo realizado por Desai (1997) mostra que a regressão logística apresentou os melhores resultados, comparativamente com a regressão linear e as redes neuronais.

O *credit scoring* para além da regressão logística acolhe nos seus modelos de classificação e reconhecimento de padrões, métodos paramétricos e não-paramétricos cujos resultados não permitem concluir que exista um modelo óptimo, uma vez que cada estudo difere em termos de estrutura, disponibilidade e qualidade dos dados obtidos.

O esforço realizado por investigadores, no sentido de encontrar qual das técnicas produz melhores resultados, ainda não foi definitivo.

Contudo, a metodologia do *credit scoring* não pode ser reduzida à utilização de um determinado método estatístico.

A metodologia abarca todo o *state of the art* que consagra o desenvolvimento de elevados conceitos técnicos utilizados na avaliação de pessoas que se candidatam ao crédito pela primeira vez (*application scoring*), como também na avaliação de condutas de utilização do cartão de crédito e respectivos comportamentos de pagamento (*behavioural scoring*) ao *Sistema de Controlo Adaptável* que proporciona as ferramentas necessárias para lidar com a complexidade e com a mudança de comportamentos.

Desenvolvem-se no Capítulo 3 alguns aspectos desta metodologia.

CAPÍTULO 3 - REFERENCIAL METODOLÓGICO: CREDIT SCORING

3.1 INTRODUÇÃO

O empréstimo de dinheiro é uma das práticas mais antigas do Mundo. Quem empresta dinheiro acredita (v. *credere*, lat.) na pessoa a quem emprestou e tem a esperança que esse dinheiro/bem venha a ser-lhe devolvido, numa data posterior.

Este sentimento de esperança fundamenta-se numa probabilidade (grande) de recuperar o dinheiro/bem emprestado mais a obtenção de um benefício adicional (juro), não descartando, contudo, a hipótese de uma probabilidade (pequena) de o dinheiro/bem não ser recuperado.

Esta possibilidade de incumprimento é o risco (risco de crédito) que se pode incorrer quando se pretende obter uma contrapartida monetária.

Esta contrapartida (juro) será maior ou menor em função da maior ou menor probabilidade de incumprimento (preço do risco de crédito).

Um dos instrumentos que se passou a utilizar de um modo predominante, ao longo do século passado, para avaliar a capacidade de cumprimento de quem recorre ao crédito, baseia-se na quantificação probabilística traduzida por uma pontuação.

Citando (Lewis, 1992, p.1):

“...a aplicação do *scoring* à avaliação do risco de crédito traduz-se num processo através do qual as informações obtidas sobre um candidato a crédito ou um cliente são convertidas em números, que depois de combinados entre si (normalmente adicionados), produzem uma pontuação (*score*)”.

O resultado desta pontuação pode ajudar, simplificar, a decisão do analista de crédito relativamente à concessão ou não do crédito solicitado, e a monitorizar o cumprimento dos pagamentos dos créditos concedidos de uma maneira eficiente, consistente e controlada.

As informações que o candidato disponibiliza aquando do preenchimento de uma abertura de conta a crédito, ou de uma proposta de adesão à obtenção de crédito são, de um modo geral, muito semelhantes, quer nas instituições financeiras quer nas não-financeiras.

Ainda segundo Lewis (1992), além da sua identificação pessoal, as informações, com maior relevância na atribuição de pontos são: o rendimento mensal, o número de anos no actual emprego, a idade, o estado civil, as responsabilidades mensais, o número de filhos, o tipo de habitação (própria ou arrendada), escolaridade, número de anos no endereço actual, entre outras.

Através deste processo dá-se uma pontuação a cada candidato a crédito, segundo tabelas de pontuação (*tabelas de scoring* ou *scorecards*).

A pontuação conseguida por um candidato a crédito é depois comparada com uma referência, designada por “ponto de corte” (*cutoff score*). Se essa pontuação estiver junto do *cutoff*, ou seja dentro de um certo intervalo na vizinhança do *cutoff*, torna-se necessária a intervenção do analista de crédito sendo, depois dessa análise, concedido ou recusado o crédito.

Segundo Anderson (2007, p.460) este processo designa-se por *referrals* podendo o analista seguir ou não a indicação dada pelo sistema de pontuação.

O número de indivíduos que diariamente se candidata a crédito junto das instituições financeiras, obrigou a que a análise da informação e a tomada de decisão se processassem num reduzido espaço de tempo.

Esta limitação conduziu à progressiva substituição da avaliação e julgamento pessoal do analista de crédito por recursos computacionais. Estes meios, vulgarmente designados por *sistemas de gestão da informação*, acolhem, nas suas arquitecturas, os processos de análise, decisão e monitorização do crédito.

Segundo Cortes (2005, p.4), a gestão da informação é alimentada por bases de dados, armazenadas segundo determinados critérios, tais como regras de normalização, construção de índices, acessos e outros critérios que tornam a utilização das bases de dados mais adequada e favorável aos utilizadores.

Genericamente designados por programas informáticos, ou *soluções* informáticas de apoio à decisão, estes sistemas estão munidos de módulos de processamento de dados e estão disponíveis no mercado segundo marcas registadas.

Após a admissão de um candidato a crédito, pelo processo acima descrito, o mesmo passa a ser monitorizado através de registos históricos do seu comportamento, ou na base de

outros critérios, tais como, pela pontualidade dos pagamentos nas datas de vencimento, ou pela observância dos limites de crédito que lhe foram atribuídos.

A pontuação deste sistema (*score*) poderá ser alterada, quer reduzindo, quer ampliando os limites de crédito em vigor, dependendo da respectiva conduta ou comportamento de cada indivíduo. Este comportamento permite ainda determinar qual a estratégia de cobranças mais adequada ao perfil de cada cliente em causa.

Denomina-se por ***scoring de atribuição*** ou de ***aceitação*** (*application scoring*) ao processo em que se concede crédito pela primeira vez a um candidato, e por ***scoring comportamental*** (*behavioural scoring*) ao processo de acompanhamento, vigilância e tomada de decisão, no segundo caso.

Sabendo-se que a experiência obtida sobre o comportamento dos clientes num passado recente, não será muito diferente do seu comportamento num futuro próximo, consagra-se neste pressuposto o método que permite avaliar o risco de novos candidatos a crédito, com base na experiência obtida em clientes, cujas *características* evidenciam *atributos* idênticos.

3.2 RESENHA HISTÓRICA DO CREDIT SCORING

As décadas de 1930 e 1940 são aquelas em que a literatura estatística consagra, como referencial, os trabalhos seminais de *scoring*, pela discriminação entre grupos de indivíduos ou de dados.

Entre os trabalhos mais citados como pioneiros da *análise discriminante linear* é a experiência de Fisher (1936) que realizou num conjunto de 150 amostras da flor “*iris*” (*setosa, versicolor e virginica*), 50 observações de cada uma das espécies citadas. Essas observações consistiram em registar o comprimento e largura das sépalas e das pétalas de cada uma das três espécies.

Este conjunto de dados permitiu a Fisher desenvolver uma nova técnica de taxinomia, tendo por base a *função linear discriminante*.

Com esta descoberta, Fisher conseguiu prever a que espécie pertenceria uma determinada espécie pelas *características* que exibia. Nesta experiência, a *função discriminante* traduziu a combinação linear de variáveis às quais estava associada determinada *ponderação* ou *peso*.

A previsão do grupo a que pertenceria determinada espécie resultaria da maximização do quociente entre a dispersão verificada nas flores da mesma espécie e a dispersão entre as flores das três espécies. Quanto maior fosse aquele quociente, maior seria a discriminação ou separação entre os grupos.

A partir deste momento outros estudos se seguiram, como nos relata Johnson (2002) que refere que o início do conceito do *credit scoring* é atribuído a Durand (1941) que teria recorrido a métodos estatísticos, nomeadamente o teste do *Chi*-quadrado, identificando variáveis que conseguiam distinguir, satisfatoriamente, os *Bons* e os *Maus* empréstimos.

Neste estudo, Durand examinou cerca de 7200 relatórios sobre *Bons* e *Maus* empréstimos a prestações concedidos por 37 empresas e desenvolveu um “*Índice de Eficiência*”, mostrando como uma variável era capaz de diferenciar os *Bons* riscos dos *Maus*. Depois, utilizou uma *função discriminante* para desenvolver modelos de *credit scoring*, cujas utilizações não se destinavam à avaliação de clientes das instituições financeiras, mas sim aos clientes do comércio retalhista.

Nesta altura vivia-se o auge da Segunda Guerra Mundial cujos imperativos ditados pelas dificuldades derivadas do recrutamento militar, levou um executivo da Spiegel Inc., Henry Wells a construir um sistema de *credit scoring*, que foi utilizado durante o período em que decorreu o serviço militar dos seus analistas de crédito.

Este sistema visava facilitar as tarefas que passaram a ser executadas por pessoal com menos experiência. Este trabalho consubstanciado por sólidas técnicas estatísticas constituiu a exceção ao infrutífero esforço desenvolvido até então.

Durante a década de 1950 foram desenvolvidas diversas metodologias de *scoring*, mas foi com William R. Fair e Earl J. Isaac ao fundarem em 1956 a empresa *Fair, Isaac and Company* que de facto se deu o início à implantação desta metodologia, impulsionando significativamente a indústria do crédito.

Estavam lançadas as pistas nas quais caminhariam novos desenvolvimentos, atingindo uma fase de rápida expansão a partir de 1970, tanto nos Estados Unidos como na Europa.

Verificou-se nesta altura que em muitas instituições o crédito ao consumo assumiu a modalidade de um crédito rotativo limitado por um determinado valor (limite de crédito) e concedido por um período indefinido, substituindo, assim, as formas tradicionais dos empréstimos a prestações.

Estava desenhado um novo modelo de empréstimo designado por *revolving credit* aplicado pela banca e por outras instituições financeiras, na maioria dos casos materializado através de um *cartão de crédito* que seria usado como meio de pagamento.

O crédito concedido era mensalmente amortizado, dando lugar à possibilidade do devedor constituir novos débitos, ao longo do mês, até ao limite de crédito estabelecido, sem necessidade de apresentar novas informações e dados pessoais.

O limite de crédito podia ser modificado em função do seu comportamento relativo ao cumprimento nas datas de vencimento e de outras informações produzidas por *scoring*.

Com esta mudança na metodologia adoptada pelas instituições de crédito, deu-se início aos actuais *cartões de crédito*, nomeadamente Carte Blanche[®], Master Charge[®] (mais tarde o Master Card[®]) e BankAmericard[®] (mais tarde Visa[®]).

A rápida vulgarização e disseminação dos *cartões de crédito* substituiu as formas tradicionais de análise de crédito por métodos de análise estatística, entre outros métodos analíticos que se tornaram disponíveis através do acelerado desenvolvimento ocorrido em mecanismos computacionais. Estes recursos tornaram possível a monitorização e o controlo de crédito por processos de “robotização” industrial.

3.2.1 RESENHA HISTÓRICA DOS CARTÕES DE CRÉDITO EM PORTUGAL

Portugal não foi excepção às mudanças que ocorriam nos Estados Unidos da América e restante Europa. O primeiro diploma do corpo legislativo relacionado com a actividade dos cartões de pagamento data de 16 de Dezembro de 1970, publicando-se a Portaria nº 644/70 que regularia a actividade das instituições de crédito que pretendessem emitir *cartões de crédito*.

Contudo, só três anos mais tarde uma nova Portaria definiu com maior exactidão e abrangência a regulamentação da actividade de emissão de *cartões de crédito*. É a Portaria 360/73, de 23 de Maio que revoga o diploma legislativo anterior. Um despacho do Secretário de Estado do Tesouro, de 27 de Fevereiro de 1974, autorizou a constituição da *Unicre - Cartão Internacional de Crédito, S.A.R.L.* tendo como accionistas os Bancos Totta & Açores, Borges e Irmão, Espírito Santo & Comercial de Lisboa, Fonsecas e Burnay, Nacional Ultramarino e Português do Atlântico e cuja escritura de constituição é feita uma semana antes da data histórica que sinaliza um novo marco na História de Portugal.

A Unicre tinha por objectivo social: *a concessão de crédito mediante a emissão de cartões individuais de identificação, bem como a celebração de todos os contratos e prestação de serviços, para isso necessários, e ainda a celebração de acordos de intercâmbio com organizações congéneres estrangeiras e nacionais.*

A Unicre tornou-se, assim, na primeira associação interbancária portuguesa emissora de cartões de crédito a ter o acesso a uma rede comercial que passava a aceitar o cartão Unibanco, como meio de pagamento. A partir de Março de 1975, ocorreu a nacionalização de bancos, das principais indústrias e dos meios de comunicação.

Nesta altura, a utilização do cartão de crédito *Master Charge*[®] foi proibida no estrangeiro por Despacho Ministerial, com o argumento de restrições cambiais e substituído o seu grafismo com base nas cores nacionais.

Mais tarde, e na sequência do estudo realizado por um grupo de trabalho de iniciativa governamental, foi readmitida a continuidade da utilização do cartão Sottomayor, já com a imagem *VISA*[®] e da Unicre em ligação à *MasterCard*[®].

Só em 1982 para as empresas, com o Despacho Normativo 77/82 e em 1986 para os particulares, foi retomada a possibilidade de os Portugueses usarem os seus cartões de crédito no estrangeiro.

3.3 SCORING DE ATRIBUIÇÃO

A indústria do crédito foi evoluindo à medida que a sociedade ia adquirindo novos hábitos de consumo e exigindo respostas às novas necessidades.

A constatação empírica dos fenómenos resultantes do “*Dinheiro de Plástico*” não ocorreram espontaneamente, embora as suas causas remotas sejam historicamente conhecidas.

O momento a partir do qual podemos verificar enormes mudanças na sociedade em todo o Mundo e o crescendo do crédito ao consumo é demarcado pelo fim da Segunda Guerra Mundial.

O crédito ao consumo é estimulado nos EUA de acordo com um programa de recuperação económica, após a grande depressão da crise de 1929, destacando-se a política económica do Presidente Franklin Roosevelt como principal colaborador do “*New Deal*”⁵.

A metodologia com base numa pontuação, traduz uma “escala de confiança” no consumidor o que tem levado alguns autores a explicar o significado subjacente à expressão *Crédito ao Consumo*. Esta expressão, no momento do seu surgimento, envolvia os intervenientes, os meios, as condições na obtenção do crédito, o fim a que se destinava e os juros inerentes à operação.

Porém a expressão *Crédito ao Consumo* tem hoje um significado mais amplo devendo incluir o conjunto de todas as entidades que participam nesta indústria, incluindo o Estado como entidade reguladora.

Citando Lewis (1992, p.1), em que a expressão “Crédito ao consumo é largamente entendido com o significado de muitas formas de comércio sob as quais um indivíduo obtém dinheiro ou bens ou serviços na condição de devolver o dinheiro ou de pagar os bens ou serviços, mediante um juro em data ou datas futuras específicas”.

Actualmente este entendimento pode reduzir o alcance do significado que a expressão *crédito ao consumo* realmente abarca.

A referida expressão envolve a indústria que opera no circuito do empréstimo de dinheiro, sejam bancos, sociedades financeiras de aquisição a crédito, sociedades para-bancárias e a própria legislação que regula a actividade.

3.3.1 CRÉDITO AO CONSUMO EM PORTUGAL: INICIATIVAS LEGISLATIVAS

Em Portugal, a primeira iniciativa legislativa sobre a criação das Sociedades Financeiras de Aquisição a Crédito (SFAC) data de 1989 com a publicação do Decreto-Lei n.º 49/89, de 22 de Fevereiro.

Este diploma descrevia no seu preâmbulo a necessidade de estimular o consumo como forma de aumentar a procura interna, promovendo o crédito através daquelas sociedades.

⁵ O *New Deal* foi o nome dado à série de programas implementados nos Estados Unidos entre 1933 e 1937, sob o governo do Presidente Franklin Delano Roosevelt, com o objetivo de recuperar e reformar a economia norte-americana.

Surgem, assim, no espaço financeiro português, entidades legalmente constituídas que permitiam financiar a aquisição a crédito de bens e serviços actuando como dinamizadoras de extensas áreas, potencializando a sua utilidade em termos económicos e sociais.

O Decreto-Lei nº 298/92, de 31 de Dezembro veio remodelar profundamente o sistema financeiro português no qual é definido o Regime Geral das Instituições de Crédito e Sociedades Financeiras.

Este diploma regulava o regime da sua constituição, as regras sobre a sua administração e fiscalização, bem como a supervisão a que estavam sujeitas por parte do Banco de Portugal.

Mais tarde, o Decreto-Lei nº 206/95, de 14 de Agosto veio revogar o Decreto-Lei n.º 49/89, de 22 de Fevereiro estipulando no seu artigo 2º al. a) que as SFAC podem *financiar a aquisição ou o fornecimento de bens ou serviços determinados, através da concessão de crédito directo ao adquirente ou ao fornecedor respectivos ou através de prestação de garantias.*

Constata-se, assim, todo o esforço legislativo no sentido de adaptar uma nova economia às práticas correntes em países mais desenvolvidos, com propósitos e objectivos diversos, nomeadamente no risco derivado da concessão de crédito.

3.3.2 SCORING DE ATRIBUIÇÃO E A NECESSIDADE DE SE QUANTIFICAR O RISCO

A concessão de crédito está implícita e inerentemente associada à ideia do risco, uma vez que ela pressupõe o seu recebimento numa data futura. A avaliação da probabilidade do incumprimento de pagamento quantificará o risco assumido.

A quantificação do risco constitui o núcleo do desenvolvimento das técnicas de *credit scoring*.

Em termos de probabilidades de incumprimento, na concessão de crédito, o pressuposto fundamental é que o futuro próximo seja semelhante ao passado recente.

Seja a avaliação do risco feita por processos tradicionais de julgamento humano, seja com base no *scoring*, as previsões futuras baseiam-se no conhecimento passado. Ambos os métodos comparam os candidatos a crédito de hoje com a experiência obtida com os candidatos precedentes.

No método de avaliação pessoal, o analista de crédito pondera o candidato com base na sua experiência anterior. Se a candidatura parecer-lhe semelhante com outra que obteve um parecer favorável no passado, então considerará a nova candidatura, segundo os mesmos critérios.

O mesmo princípio é adoptado pelo *scoring*. Cada uma das novas candidaturas é comparada com a informação disponível sobre candidaturas anteriores, traduzidas numa tabela de pontuação (*tabela de scoring*).

3.3.3 SELECÇÃO CORRECTA DA POPULAÇÃO

Para um sistema de *scoring* poder inserir cada cliente no seu grupo de integração é necessário seleccionar a população correcta, isto é, aquela que conterà toda a informação histórica necessária para o desenvolvimento das tabelas de *scoring*.

A construção de uma *tabela de scoring*, estatisticamente válida, depende da frequência de ocorrências de muitos dados acerca de contas *Boas* e *Más*.

A dimensão da amostra varia em função do tipo de crédito concedido (crédito ao consumo, crédito à habitação, crédito automóvel, etc.). O número de clientes que compõem cada carteira pode variar desde alguns milhares de contas até alguns milhões, sendo por isso necessária a utilização de dimensões de amostras diferentes em função de cada tipo de carteira de crédito.

Segundo Lewis (1992, p.31) não existe um número mágico para quantificar a “melhor” dimensão de uma amostra de crédito ao consumo, tendo-lhe a experiência demonstrado que se poderá obter um resultado robusto e eficaz através de uma amostra de 1500 contas *Boas* e 1500 contas *Más*.

Do referido pressuposto, e de acordo com o mesmo autor, em que o futuro próximo será algo semelhante a um passado recente, a recolha de uma amostra de 1500 contas *Boas* e 1500 contas *Más* nos últimos 12 a 24 meses poderá oferecer maior robustez e eficácia a uma *tabela de scoring*, do que uma outra cujo horizonte temporal fosse de um período anterior de 3, 4 ou mais anos.

As instituições financeiras, nas quais se obtiverem as amostras, devem ser estáveis, isto é, terem permanecido e operado no mesmo tipo de actividade creditícia, durante o período de tempo em análise.

Só assim as amostras recolhidas serão estáveis e homogéneas. Se, pelo contrário, durante o último ano, essas instituições tiverem alterado a sua estratégia no mercado onde operam, adoptando novas políticas expansionistas ou alargando a sua intervenção a outros segmentos de mercado, não servidos anteriormente, poder-se-á esperar que a natureza de contas *Boas e Más* apresentarão um maior conjunto de atributos do que aqueles que se obteriam se a população servida não tivesse sido alterada.

A homogeneidade da amostra é também muito importante para o nível de qualidade final da *tabela de scoring*. Esta homogeneidade refere-se ao tipo de produto que se oferece aos clientes durante o período de tempo em estudo.

Uma amostra extraída de uma população que utiliza uma mistura de produtos de crédito é menos satisfatória, como base de desenvolvimento de uma *tabela de scoring*, do que uma amostra retirada de uma população que utiliza só um produto de crédito.

Uma população estável e homogénea, se bem que seja muito atractiva de um ponto de vista estatístico, para a finalidade que desejamos, nem sempre é possível obtê-la na prática.

Se uma população tiver sido muito volátil ou se se tiver verificado falta de homogeneidade, devido à variedade de produtos de crédito oferecidos, dever-se-á prestar atenção à selecção de apenas um produto a fim de limitar a população em estudo.

Deste modo, quanto mais estável e homogénea a população for, melhor será o sistema de *scoring* de aí resultante.

Através da informação histórica serão classificados os *Bons* e os *Maus* clientes segundo critérios baseados no comportamento ao longo do tempo.

Com aqueles critérios perfeitamente parametrizados, torna-se possível desenvolver um programa informático que vá seleccionando os clientes de acordo com os critérios definidos, através de uma pesquisa ao ficheiro da facturação.

De um modo geral, qualquer registo informático sobre os clientes pode fornecer a informação histórica necessária, com mais de dois e três anos.

A selecção correcta da população passa inevitavelmente por uma definição dos critérios que caracterizam um *Bom* e um *Mau* cliente.

Em teoria, um *Bom* cliente é aquele que uma empresa ou instituição gosta de ter e um *Mau* cliente será aquele que não se deseja ter.

Estas definições apesar de verdadeiras necessitam de ser suficientemente concisas, de forma que as conclusões tiradas sobre as mesmas não suscitem quaisquer dúvidas a quem as analisa.

Uma condição óbvia para o desenvolvimento de um sistema de *scoring* é a de que a informação deve estar disponível.

Um potencial utilizador de um *sistema de scoring* deve ser capaz de identificar uma amostra com 1500 contas *Boas* e 1500 contas *Más*, devendo igualmente de ser capaz de localizar e reunir as candidaturas originais para aquelas 3000 contas juntamente com os relatórios de agências de informação de crédito e, eventualmente, uma consulta à base de dados da Central de Responsabilidades de Crédito do Banco de Portugal.

Qualquer empresa que conceda crédito e que esteja a considerar o desenvolvimento de um sistema de *credit scoring* deverá desde logo guardar toda a informação da candidatura ao crédito, de modo a que, quando chegar a altura de seguir com um processo de crédito, os dados estejam disponíveis.

3.3.4 DEFINIÇÃO DE *BOAS* E *MÁS* CONTAS

As contas *Boas* e *Más* devem ser definidas por critérios que sejam suficientemente exactos de modo a que todos os observadores cheguem às mesmas conclusões acerca de cada conta.

Este princípio aponta para que as contas devam estar definidas em termos do seu modo de desempenho.

De acordo com dados reais obtidos junto de fonte confidencial, uma conta classificada como *Boa* numa operação de crédito rotativo, é a de um cliente cujos registos mostrem ter:

Pelo menos 1 conta activa nos últimos 10 meses;

No máximo de 1 atraso nos últimos 12 meses;

No máximo de 1 devolução nos últimos 12 meses;

Classes de rfm de rendibilidade e revolving 4 e 5;

Um saldo médio das contas nos últimos 3 meses ≥ 1.200 €;

Contas em análise sem incumprimento ≥ 60 dias nos últimos 24 meses;

Uma facturação ≥ 500 € nos últimos 3 meses.

A condição de ter pelo menos uma conta activa nos últimos dez meses e a condição de possuir um saldo médio nos últimos três meses superior ou igual a 1200 € ainda restringe mais os candidatos admissíveis a esta categoria, retirando também aqueles cuja actividade é demasiado baixa para ser significativa ou cujo envolvimento financeiro é mínimo, não atingindo o critério de *Boa* conta.

Segundo a mesma fonte, uma conta *Má* é um pouco mais difícil de circunscrever, embora as seguintes definições sejam adequadas:

Contas que estejam em incumprimento há mais de 4 meses, ou

Incumprimento por três vezes durante 60 dias, nos últimos 12 meses;

Insolvência verificada enquanto a conta estiver aberta.

Com critérios deste tipo é possível conceber um programa informático capaz de examinar minuciosamente um ficheiro contabilístico e identificar todos os outros clientes que se qualificam em cada uma das categorias.

3.3.5 TAXA DE ACEITAÇÃO

Um dos indicadores que se reveste de particular importância para o desenvolvimento de um sistema de *scoring* é a *taxa de aceitação*.

Este indicador é construído com base na percentagem anual de candidaturas aceites do total de propostas recebidas, como se ilustra nos dados reais de fonte confidencial exibidos na Tabela nº 3.1.

A *taxa de aceitação* nem sempre está imediatamente disponível e pode necessitar de alguma prospecção na base de dados para a encontrar.

Muitas empresas registam a *taxa de aceitação* conservando registos correntes da quantidade de contas aceites e recusadas.

Dados reais de fonte confidencial:

	Aceites	Recusados	Total de propostas	Taxa de aceitação
2004	14 745	7 872	22 617	65,2%
2005	21 131	9 136	30 267	69,8%
2006	19 805	14 835	34 640	57,2%
2007	10 817	8 458	19 275	56,1%

Tabela nº 3.1- Número de candidaturas aceites e recusadas. Taxa de aceitação




Gráfico nº3.1: Evolução das candidaturas aceites e recusadas no período de 2004 a 2007

3.3.6 CÁLCULO DA PONTUAÇÃO NUMA TABELA DE *SCORING*

Após a identificação das *características* e respectivos *atributos* e estes eventualmente agrupados em classes, passa-se à fase seguinte.

A nova etapa consiste na preparação de uma *tabela de pontos* designada por *tabela de scoring* ou *scorecard*. Exemplo hipotético:

<i>Características</i>	<i>Atributos</i>	<i>Pontos</i>
Idade	18-23	60
Idade	24-25	75
Idade	26-28	80
Idade	29-34	85
Idade	35-46	95
Idade	47-51	100
Idade	+51	60
Rendimento	Até 500 €	70
Rendimento	De 501 a 1500 €	75
Rendimento	De 1501 a 2500 €	80
Rendimento	+2500 €	90

Tabela nº 3.2 Tabela de scoring (parcial). Adaptação de Naeem Siddiqi (2006, p.6)

Esta tabela mostra o número de pontos que foram atribuídos a cada *atributo*. Segundo este critério, todos os candidatos a crédito que possuam aquele *atributo* terão, obviamente, o mesmo número de pontos. A soma dos pontos de todos os *atributos* traduzirá a pontuação final, designada por *credit score* ou simplesmente por *score*.

A identificação dos *atributos* mais relevantes e as respectivas pontuações dependerão da experiência obtida e de métodos estatísticos iterativos que conduzam à pontuação mais adequada a cada um dos casos.

O *risco de crédito* avaliado por uma pontuação, como em outros modelos preditivos, é um método que serve para avaliar o nível de risco, quando se comparam os candidatos a crédito com os clientes já existentes.

Porém, o sistema de *scoring* não identifica os *Bons* e os *Maus* candidatos numa base de avaliação individual, mas fornece a *probabilidade* de um candidato com um determinado *score* ser *Bom* ou *Mau*.

Estas probabilidades conjuntamente com outras considerações relativas à própria actividade, tais como *taxas de aprovação*, *lucro*, *esforço de cobranças* e *perdas*, são depois utilizadas como referências para o processo de decisão.

Na sua forma mais simples uma *tabela de scoring* consiste num grupo de *características*, estatisticamente determinadas que prevêm a separação das contas *Boas* das *Más*. As *características* de um *tabela de scoring* podem ser seleccionadas a partir de qualquer fonte de dados disponível no momento da candidatura à obtenção de crédito.

Exemplos das fontes de tais *características* são: *demográficas* (idade, género, agregado familiar, rendimento, ocupação, habilitações literárias, nacionalidade, etc); *relações com terceiras entidades* (há quanto tempo tem conta no banco, número de produtos bancários que detém, nomeadamente: - cartões de crédito, cartões de débito, crédito à habitação, crédito individual, *leasing*, seguros de casa, de carro e de saúde, depósitos a prazo, contas poupança, Plano de Poupança Reforma); informações do Banco de Portugal; relatórios de agências de informação comercial; registos públicos; e outras informações que possam ser disponibilizadas para o referido efeito.

A cada *atributo* é designado um número de pontos baseado em análises estatísticas, tomando em consideração vários factores, tais como a robustez preditiva das *características* e correlação entre as *características*.

A pontuação total do candidato é a soma das pontuações de cada *atributo* presente na tabela de *scoring*. Esta é a parte mais visível de um sistema de *scoring*, contudo existe um conjunto de relatórios (3.3.7) que elucidarão com mais detalhe como o sistema de *scoring* deve funcionar.

3.3.7 RELATÓRIOS

Segundo Lewis (1992, p.104) “*o bom funcionamento de um sistema de scoring advém do conhecimento que se possui sobre a sua capacidade de discriminação entre as Boas e as Más candidaturas a crédito*”.

Sabendo-se que o tipo de populações muda ao longo dos tempos, é necessário avaliar continuamente a fiabilidade do sistema de *scoring* de forma a actualizá-lo com as novas tendências manifestadas pelas permanentes evoluções/involuções das populações.

Estas actualizações são feitas com base em *relatórios*, entre os quais, os mais comuns são os:

3.3.7.1 De monitorização

Estes relatórios visam assegurar ao analista de crédito que a pontuação e os dados introduzidos estão correctos.

De acordo com o relato do mesmo autor, no momento da introdução de dados são cometidos muitos erros devendo estas anomalias ser detectadas o mais rapidamente possível.

Esta verificação denomina-se por *monitorização* do sistema de *scoring* e consiste em reintroduzir os dados no sistema e compará-los com os resultados originais.

Existem casos em que mais de 50% das candidaturas foram pontuadas incorrectamente após um novo sistema de *scoring* ter entrado em funcionamento.

Se a monitorização for feita numa base regular e contínua poder-se-ão esperar descidas rápidas e significativas na *taxa de erro*.

Um dos erros mais comuns cometidos pelos construtores de tabelas de pontuação com pouca prática é o de ignorarem ou prestarem pouca atenção aos atributos da característica do “*Cargo ou função que desempenha*”.

As pontuações dadas aos *cargos ou funções* que um candidato desempenha tendem por natureza a ser incompletas, dada a sua diversidade e significado de certas funções. Sempre que surge uma candidatura com uma designação de cargo ou função não conhecidas até ao momento é, invariavelmente, “*enviada*” para “*Outros cargos*” ou “*Outras funções*”.

Quando tal acontece é necessário fazer uma contagem do número de “*outros cargos e outras funções*” comparando com o número observado nas estatísticas originais e concluir se é necessário considerar como um *novo cargo* certas *ocupações* não consideradas, na construção do sistema anterior.

3.3.7.2 De estabilidade das populações

Uma questão que deve estar sempre em aberto, na construção de tabelas de *scoring*, é saber se a população das candidaturas recentes é muito diferente da *população* original, isto é, da população que serviu de base à construção da tabela de *scoring* em utilização. Se a população das actuais candidaturas for muito diferente da população original, o sistema de *scoring* torna-se menos eficiente.

Para esta ineficiência concorrem muitos factores que explicam as mudanças verificadas na nova população de ingresso. Alguns desses factores estão relacionados com estratégias de angariação de novos clientes, nomeadamente em novas áreas geográficas ou em subpopulações até então desconhecidas, como por exemplo, *Associações profissionais* ou *Associações de Estudantes* de determinados estabelecimentos de ensino.

Estas diferenças são tanto mais notórias quanto maior for a longevidade da carteira de clientes e a manutenção do *statu quo* que a caracteriza. Uma outra fonte de variação da *população* são as mudanças na Economia em geral.

Se a Economia sofrer de processos de recessão ou de expansão, o número de indivíduos que procura crédito muda em ambos os sentidos. O *relatório de estabilidade das populações* compara os *scores* encontrados na população actual com as da população sobre a qual foi construído o sistema de *scoring*.

Quanto mais próximo estiverem estes dois conjuntos de *scores* mais próxima estará a nova população da original.

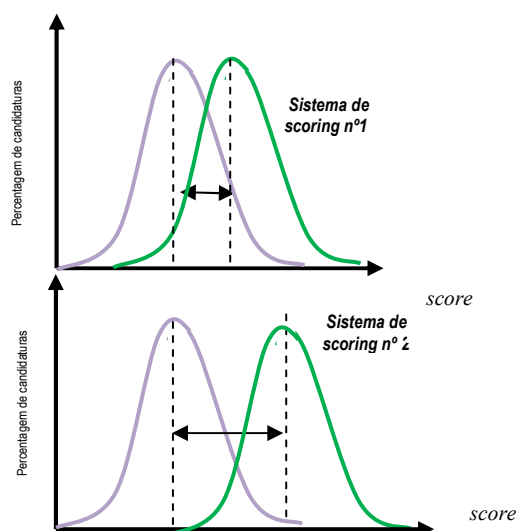


Gráfico.nº3.2: Comparação do poder discriminante entre dois sistemas de scoring

Quando o sistema de *scoring* está a ser desenvolvido tem-se como objectivo que a média da distribuição das contas *Boas* esteja o mais afastada possível da média da distribuição das contas *Más*. A medida de robustez do sistema de *scoring* é dada pelo *afastamento* entre as médias das respectivas distribuições.

Este afastamento também é designado na literatura estatística por *Divergência*.

No caso em que se pretende testar a proximidade da *população actual* relativamente à *população original* procura-se o inverso, isto é, que ambas as distribuições estejam tão próximas uma da outra, quanto possível. Neste caso, quanto mais próximas estiverem as duas curvas maior será o grau de confiança que se pode esperar do sistema.

- *Algumas conclusões sobre a estabilidade das populações*

Do exposto, verifica-se que é necessário examinar o desempenho dos sistemas de *scoring* bastando para isso estar atento às contas que estão em carteira há tempo suficiente para mostrar o desempenho das *Boas* e das *Más*.

Salientou-se também a importância de garantir que a população dos actuais candidatos deva ser semelhante à população sobre a qual o sistema de *scoring* foi desenvolvido, uma vez que é necessário manter a similitude entre as populações para que o sistema funcione satisfatoriamente.

Se no desenvolvimento do sistema tivesse ocorrido diferenças entre as populações que não se esperavam, tal situação alertaria o analista de crédito, em tempo devido, para possíveis problemas futuros.

Uma avaliação eficiente da população actual *versus* população sobre a qual o sistema de *scoring* foi construído, pode ser feita comparando a distribuição dos *scores* dos candidatos actuais com aqueles que foram considerados no desenvolvimento estatístico.

Segundo Lewis (1992, p.146), Siddiqi (2006, p.137) e Anderson (2007, p.194) o grau de similitude entre as duas distribuições pode ser determinado pelo cálculo do *Índice de Estabilidade da População*⁶ de acordo com a seguinte fórmula:

$$\text{Índice de Estabilidade da População} = \sum_{j=1}^n \left\{ \left(\frac{c_j}{C} - \frac{d_j}{D} \right) \times \left[\ln \left(\frac{c_j}{C} \div \frac{d_j}{D} \right) \right] \right\} \quad (3.1)$$

⁶ O Índice de Estabilidade da População (IEP) mede as mudanças na distribuição do *score* nos candidatos actuais comparada com a amostra de desenvolvimento, ou com outra base de medida. A detecção de qualquer eventual alteração pode servir de alerta à eficácia do modelo naquela população.

Onde:

c_j é o número dos candidatos actuais no j -ésimo de um total de n intervalos;

C é o total dos candidatos actuais;

d_j é o número de membros na amostra de desenvolvimento no j -ésimo intervalo;

D é o número total da amostra de desenvolvimento.

A Tabela nº 3.3 ilustra um exemplo do cálculo do *Índice de Estabilidade da População*:

Intervalos de	Desenvolvimento		Actual		A		B		A x B
	Nº de candidatos	$\frac{d_j}{D}$	Nº de candidatos	$\frac{c_j}{C}$	$\frac{c_i}{C} - \frac{d_i}{D}$	$\frac{c_i}{C} + \frac{d_i}{D}$	$\ln\left(\frac{c_i}{C} + \frac{d_i}{D}\right)$		
<i>Score</i>			c_j						
<160	1100	0,110	587	0,090	-0,020	0,818	-0,201	0,004	
160-179	1200	0,120	653	0,100	-0,020	0,834	-0,182	0,004	
180-189	700	0,070	424	0,065	-0,005	0,928	-0,075	0,000	
190-199	800	0,080	542	0,083	0,003	1,038	0,037	0,000	
200-209	900	0,090	613	0,094	0,004	1,044	0,043	0,000	
210-219	950	0,095	587	0,090	-0,005	0,947	-0,055	0,000	
220-229	1000	0,100	979	0,150	0,050	1,500	0,405	0,020	
230-249	1500	0,150	1241	0,190	0,040	1,268	0,237	0,010	
>=250	1850	0,185	901	0,138	-0,047	0,746	-0,293	0,014	
Total	10000		6527				<i>Índice de estabilidade</i>	0,052	

Tabela nº 3.3: Índice de Estabilidade Populacional (Adaptação de Edward M. Lewis- *An Introduction to Credit Scoring* (1992), pág. 147).

Este índice mede a separação de duas distribuições de *scores*. As distribuições ao representarem as contas *Boas* e *Más* mostram ser desejável que se obtenha um índice elevado (no caso da *Divergência*) que traduza uma forte capacidade para diferenciar os dois grupos de contas.

Ao medir-se a *Estabilidade* de duas populações (a dos *candidatos* e a dos de *referência*) o menor índice possível indicará que a população de entrada é estável e que se verifica uma similitude comportamental, no fluxo dos candidatos.

3.3.7.3 De validação

À medida que o tempo avança, o sistema de *scoring* deve ser validado. O procedimento que foi utilizado no momento do seu desenvolvimento pode já não estar em uso e ter sido substituído, por novos procedimentos. Quando tal acontece perdem-se as referências das candidaturas que foram recusadas, contudo, as candidaturas aceites podem ser ordenadas por *score*. Se esta ordenação mostrar que quanto mais alto for o *score* maiores serão os valores dos *odds* é razoável concluir que o sistema permanece eficaz.

3.3.7.4 De análise de características

Este relatório compara para cada *característica* as percentagens dos candidatos actuais com as percentagens dos candidatos no momento em que o *scorecard* foi construído.

Ilustra-se um exemplo de relatório que pode ser produzido, verificando-se neste caso que se registaram alterações nas populações, em alguns casos bastante significativas.

Exemplo ilustrativo:

Cargo ou função (Ocupação profissional)	% da População Original (1)	% da População actual (2)	Diferença 3=2-1
Reformado	10	20	10
Comercial	20	30	10
Técnico	35	10	-25
Serviços	15	20	5
Financeiro	10	10	0
Outros	5	5	0
Em “branco”	5	5	0

Tabela nº3.4 – Relatório de análise de características. Adaptação de Lewis (1992, p.148)

Pelas razões acima expostas, torna-se necessário, de vez em quando, comparar as características do fluxo dos candidatos actuais com os da população original.

Continuação do exemplo ilustrativo:

Cargo ou função (Ocupação profissional)	% da População Original (1)	% da População actual (2)	Diferença 3=2-1	Pontos (4)	Diferença x Pontos 5=3 x 4
Reformado	10	20	10	40	400
Comercial	20	30	10	35	350
Técnico	35	10	-25	30	-750
Serviços	15	20	5	25	125
Financeiro	10	10	0	25	0
Outros	5	5	0	30	0
Em “branco”	5	5	0	25	0
				Total	125

Tabela nº 3.5 – Comparação entre as características dos candidatos actuais com os da população original.

Adaptação de Lewis (1992, p.148)

Da Tabela nº 3.5 o valor final de 125 significa que se poderá esperar um *score* médio da população actual ser 1,25 pontos acima da média do *score* da população original.

O relatório de *análise de características* tem valor por si próprio, mas torna-se ainda mais útil sempre que a *estabilidade da população* mostrar que a *população actual* é significativamente diferente da *original* e sempre que o analista de crédito pretenda saber onde residem as diferenças entre as populações.

3.3.7.5 De incumprimento por score e por exposição

A proposição básica feita por um sistema de *credit scoring* é estabelecer que os *scores* altos estão associados aos *odds* altos, enquanto os *scores* baixos estão associados aos *odds* baixos. O sistema de *scoring* é, formalmente, válido, se se puder mostrar através de uma tabela como a Tabela nº 3.9, na qual se pode verificar que a *taxa de incumprimento* diminui, à medida que o *score* aumenta, sendo possível distinguir, até certo ponto, entre contas *Boas* e *Más*.

Contudo, também é importante saber como a capacidade de discriminação evidenciada pela tabela de *scoring* actual se compara com a capacidade de discriminação da tabela de *scoring*, no momento em que o sistema de *scoring* foi construído. Esta comparação pode ser efectuada através de duas tabelas. A primeira é a tabela que mostra o número de contas *Boas* e

Más, a partir da amostra de desenvolvimento, em cada grupo de intervalos de *score*, ordenados por ordem crescente.

A Tabela nº 3.6 exhibe, através de um exemplo hipotético, uma possível distribuição de clientes *Bons* e *Maus* no momento em que a tabela de *scoring* foi desenvolvida.

<i>Score</i>	Qt.Bons	Qt.Maus	%Maus
Abaixo 170	138	28	16,9%
170-179	76	7	8,4%
180-189	85	6	6,6%
190-199	94	5	5,1%
200-209	90	4	4,3%
210-219	92	3	3,2%
220-229	93	3	3,1%
230-239	89	2	2,2%
240-249	88	1	1,1%
250-259	90	1	1,1%
260-289	95	1	1,0%
+289	110	1	0,9%

Tabela nº 3.6- Contagem na amostra de desenvolvimento, por *score*

A Tabela 3.7 é semelhante à Tabela 3.6, mas mostra o número actual de contas *Boas* e *Más* pontuadas na carteira de clientes com antiguidade de 12 meses. O modo mais fácil de obter esta tabela é conceber um programa informático que utilize como *input* o ficheiro mestre da facturação.

<i>Score</i>	Qt.Bons	Qt.Maus	%Maus Actuais	%Maus Desenvolv.
Abaixo 200	106	12	10,2%	10,5%
200-209	2690	120	4,3%	4,3%
210-219	2787	92	3,2%	3,2%
220-229	2714	88	3,1%	3,1%
230-239	2571	58	2,2%	2,2%
240-249	2295	25	1,1%	1,1%
250-259	1768	20	1,1%	1,1%
260-289	1291	13	1,0%	1,0%
+289	320	3	0,9%	0,9%

Tabela nº 3.7- Quantidade de candidaturas aceites com antiguidade de 12 meses

Note-se que na Tabela 3.7, todas as contagens abaixo de 200 pontos estão agrupadas, visto que são basicamente *derrogações*.

A mesma Tabela nº 3.7 inclui, na coluna do lado direito, a percentagem de *Maus* a partir da Tabela nº 3.6 para comparação. Neste caso, os dois grupos de números para percentagem de *Maus* são quase coincidentes, demonstrando a eficácia contínua do sistema de *scoring*.

Pode-se obter uma tabela mais informativa, exibindo não apenas as contas *Más* (de acordo com a definição de *Má*, utilizada no desenvolvimento do sistema de *scoring*) mas mostrando também contas com um grau de incumprimento menor.

Numa carteira de contas de crédito *revolving* tal como num cartão de crédito vulgar, também é útil mostrar o número de contas que foram *aceites* e o número destas que se mantêm *activas*. Este tipo de tabela (Exemplo hipotético, Tab.nº 3.8) oferece-nos uma imagem mais compreensível do estado da carteira de clientes do que as tabelas que referem apenas as contas *Más*.

Score	Aceites	Contas não	Contas activas	Contas activas em incumprimento	Vencidas+30 dias		Vencidas + 60 dias		Más actuais		Más Desenv.
		activas	Boas		Qt.	%	Qt.	%	Qt.	%	%
<200	2250	755	1.340	155	84	54,2%	55	35,5%	16	10,3%	10,5%
200-209	82650	27.561	52.745	2344	1627	69,4%	617	26,3%	100	4,3%	4,3%
210-219	105820	35.276	68.321	2223	1606	72,2%	545	24,5%	72	3,2%	3,2%
220-229	90800	30.270	58.710	1820	1378	75,7%	386	21,2%	56	3,1%	3,1%
230-239	107870	35.959	70.363	1548	1251	80,8%	261	16,9%	36	2,3%	2,2%
240-249	155500	51.827	102.545	1128	928	82,3%	186	16,5%	14	1,2%	1,1%
250-259	104360	34.785	68.818	757	660	87,2%	89	11,8%	8	1,1%	1,1%
260-279	71350	23.781	47.098	471	414	87,9%	52	11,0%	5	1,1%	1,0%
279	17999	6.003	11.889	107	93	86,9%	13	12,1%	1	0,9%	0,9%

Tabela nº 3.8- Número de contas que foram aceites e o número destas que se mantêm activas, comparando as contas *Más* actuais com as contas *Más* no momento da criação do sistema de *scoring*.

Se as populações de candidatos e clientes forem razoavelmente estáveis, o desempenho geral de um sistema de *scoring* pode ser avaliado através de um relatório que mostre o *incumprimento* de uma carteira de clientes por *score*.

Na forma mais simples, este relatório consiste numa tabela que mostra a taxa de incumprimento para cada intervalo de *score* desde o menor até ao maior, como se ilustra na Tabela 3.9:

Exemplo hipotético:

Intervalos de score	Taxa incumprimento
Abaixo de 170	36,5
170-179	16,2
180-189	16,0
190-199	10,4
200-204	9,0
205-209	8,5
210-214	6,7
215-219	6,6
220-224	6,5
225-229	6,4
230-239	3,5
240 e superiores	2,1

Tabela nº 3.9- Taxa de incumprimento para cada intervalo de *score*.
A taxa de incumprimento desce à medida que o *score* aumenta

Para que este relatório tenha utilidade deve-se tomar em consideração apenas as contas que tenham a mesma antiguidade e, portanto, todas elas terem tido a mesma *exposição* à possibilidade de se tornarem de cobrança duvidosa.

3.3.7.6 Relatório Dinâmico de Incumprimento

Um relatório importante que pode ser produzido para seguir o trilho das contas que apresentam problemas idênticos é o *Relatório Dinâmico de Incumprimento*. Este relatório mostra o estado de incumprimento de grupos de contas que tenham estado em cobrança por iguais períodos de tempo.

Isto permite à Gestão comparar contas que tenham estado em cobrança durante um determinado período de tempo, digamos seis meses, ou durante qualquer outro período que se deseje seleccionar.

O período em que uma conta está em cobrança denomina-se *tempo de exposição*, uma vez que é o tempo em que a conta está exposta à possibilidade de se tornar um crédito de cobrança duvidosa.

3.3.8 PREPARAÇÃO DA TABELA DE *SCORING*

A análise das *características* iniciais que evidenciaram maior robustez preditiva devem ser consideradas para a construção do modelo final. Numa fase preliminar da tabela de *scoring* várias técnicas de modelação preditiva podem ser utilizadas para seleccionar aquele conjunto de *características*.

Algumas das técnicas estatísticas mais utilizadas pelas entidades emissoras de cartões de crédito, são a *regressão logística*, as *árvores de decisão* e as *redes neuronais*.

Em geral, a tabela de *scoring* final produzida nesta fase deverá conter entre 8 a 15 *características*, (Siddiqi, 2006). Procede-se deste modo para garantir a estabilidade da tabela de *scoring* na eventualidade do perfil de uma ou duas características tiverem de ser alteradas.

As tabelas de *scoring* com poucas *características* revelam, de um modo geral, uma grande debilidade ao factor tempo, porque são susceptíveis de perda da capacidade de discriminação às menores variações verificadas no perfil dos candidatos e clientes existentes.

Independentemente da técnica de modelação utilizada, este processo deverá produzir uma *tabela de scoring* consistente com as melhores combinações encontradas entre as *características*, tomando-se em linha de conta algumas situações especiais, nomeadamente: *correlação* entre *características*; robustez preditiva final da tabela de *scoring*; interpretação das *características* pelo pessoal do departamento de adjudicação; facilidade de implementação; e transparência da metodologia para com os requisitos legais.

3.3.8.1 Perfil de risco

Segundo Siddiqi (2006, p.88) as tabelas de *scoring* podem ser concebidas em função da sua aplicação posterior. Em termos da sua funcionalidade as tabelas de *scoring* deverão ser desenvolvidas para replicar o critério decisório de um analista de crédito.

Um profissional experiente nunca observará apenas quatro ou cinco *características* de uma proposta de adesão ou incidirá a sua atenção em apenas alguns dos registos históricos de um cliente para tomar uma decisão. Observará, muito provavelmente, um conjunto de *informações-chave* de forma a identificar um *perfil de risco*.

Sendo assim, perguntar-se-á porque razões as tabelas de *scoring*, incluem, somente, quatro ou cinco *características*? A resposta parece ser óbvia:- O objectivo do processo de

desenvolvimento de um *tabela de scoring* é a construção de um *perfil de risco* que seja compreensível, sobre um determinado cliente e, simultaneamente, eficiente.

Este entendimento basilar não só contribui para a feitura de *tabelas de scoring* com maior capacidade preditiva, como também as tornará mais estáveis e menos vulneráveis a quaisquer mudanças que possam ocorrer numa área específica.

Um *perfil de risco* deverá incluir *características* que representem tantas tipologias de dados diferentes, quanto possível. Por exemplo, considerando uma *tabela de scoring* na actividade dos *cartões de crédito* esta deverá incluir dados demográficos tais como idade, tipo de residência, zona ou região onde mora, tempo no actual emprego, algumas informações de outras fontes que identifiquem o seu património, designadamente através do Registo Predial, Registo Automóvel ou sobre outros bens que detenha; comportamento na assiduidade dos pagamentos; eventuais registos públicos; capacidade financeira e outras informações relevantes que, circunstancialmente, constem no seu cadastro.

O conceito de *perfil de risco* também ajudará na monitorização subsequente da tabela de *scoring* e torná-la-á mais relevante e valiosa.

Segundo informação de fonte confidencial, a maioria dos analistas desejariam obter relatórios mensais sobre a “estabilidade do sistema” ou “estabilidade da população” para confirmar a validade da tabela de *scoring* em uso tanto nas candidaturas de adesão como nas contas existentes.

O que na verdade estes relatórios, efectivamente, produzem são apenas as mudanças verificadas na população, tal como estão definidas pelas *características* da tabela de *scoring*.

Uma *tabela de scoring* amplamente fundamentada no *perfil de risco* seria mais realística pela captação constante das mudanças verificadas na população do que aquelas que indicam artificialmente a mudança ou a estabilidade das respectivas populações.

Construir um *tabela de scoring* baseado no *perfil de risco* não é, em teoria, diferente de qualquer outro modelo preditivo, residindo apenas a diferença no método de selecção do conjunto das *variáveis* finais.

3.3.8.2 Concepção da tabela de scoring

A construção de uma *tabela de scoring* em que se considere no modelo de regressão todas as *características* poderá produzir resultados que não sejam ideais em termos

operativos. Apesar de qualquer construtor de tabelas de *scoring* depositar confiança no modelo que desenvolveu, face às ferramentas estatísticas utilizadas, há contudo alguns objectivos empresariais que também necessitam de ser considerados aquando do desenvolvimento da tabela de *scoring*.

O primeiro objectivo é escolher o melhor conjunto de *características* e construir o *perfil de risco* mais consonante com as políticas da instituição. Idealmente, o *perfil de risco* deverá ser construído usando tantos dados independentes quanto possível, como por exemplo, os demográficos, financeiros, informações comerciais e bancárias, tendências no comportamento de pagamentos, etc.

O processo de desenvolvimento deverá contemplar regras estatísticas tais como *correlação* e *colinearidade* e outros factores que afectem, negativamente, a fiabilidade do próprio modelo.

A *tabela de scoring* desenvolvida deve ser coerente com a estrutura de suporte à decisão da organização. Se o modelo for o único critério de arbítrio, torna-se ainda mais concernente a necessidade de se criar um *perfil de risco* compatível com as políticas de crédito em vigor.

Se a instituição de crédito estiver a utilizar um sistema informático de suporte à decisão, então as características a incluir na tabela de *scoring* devem estar em sintonia com outras políticas e regras vigentes.

O construtor da tabela de *scoring* tem diversos métodos pelos quais pode influenciar o desempenho final do *scorecard*. Aqueles métodos consistem em sobrevalorizar algumas *características*, manipulando a *regressão* no sentido de maximizar as probabilidades de algumas delas poderem entrar no modelo final.

A *regressão* utiliza várias combinações de características em diferentes fases e com diferentes níveis de significância, obtendo-se assim uma robustez preditiva ainda maior. Estas *tabelas de scoring* são posteriormente avaliadas por critérios do próprio negócio e pela combinação de *características* e de medidas estatísticas utilizadas na fiabilidade do modelo.

3.3.8.3 Cálculo da Graduação da Escala

O modelo de *regressão logística* permite obter uma pontuação (*score*) quantificando os valores das variáveis explicativas X_i através da multiplicação por um coeficiente numérico β usando a equação:

$$\text{logit}(p_i) = \text{Score} = \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_n X_n \quad (3.2)$$

Este *score* está graduado numa escala logaritmica de base neperiana que não é de fácil interpretação. Para se ultrapassar esta dificuldade transforma-se o *score* numa escala linear. Para se obter esta escala multiplica-se o *score* por um *factor* igual ao *número de pontos* que se pretende atribuir à graduação da escala, dividido por $\ln(2)$ ⁷.

Admitamos como exemplo que pretendemos graduar a escala de forma a que de 20 em 20 pontos os *odds* dupliquem. Neste caso, teríamos de efectuar o seguinte cálculo:

$$\underbrace{(\beta_1 X_1 + \beta_2 X_2 + \dots + \beta_n X_n)}_{\text{Score}} \times \left(\frac{20}{\ln(2)} \right) \quad (3.3)$$

Contudo e no presente contexto pretende-se relacionar os *Odds* e os *Scores*, de modo a que os *Odds* dupliquem a cada 20 pontos o que nos conduz à seguinte transformação linear:

$$\text{Score} = \text{“Offset”} + \text{Factor} \times \ln(\text{odds}) \quad (3.4)$$

Quando a tabela de *scoring* está a ser desenvolvida usando *odds* específicos num determinado *score* e “*pontos para duplicar os odds*” (*pdo*) específicos, o *factor* e o “*offset*” podem ser facilmente calculados utilizando o seguinte sistema de equações:

$$\begin{cases} \text{Score} = \text{Offset} + \text{Factor} \times \ln(\text{odds}) \\ \text{Score} + \text{pdo} = \text{Offset} + \text{Factor} \times \ln(2 \times \text{odds}) \end{cases} \quad (3.5)$$

Resolvendo o sistema de equações acima para determinar os *pdo*, obtemos:

$$\begin{cases} \text{Score} = \text{Offset} + \text{Factor} \times \ln(\text{odds}) \\ \text{Score} = \text{Offset} + \text{Factor} \times \ln(2 \times \text{odds}) - \text{pdo} \end{cases} \quad (3.6)$$

Ou seja:

$$\text{Offset} + \text{Factor} \times \ln(\text{odds}) = \text{Offset} + \text{Factor} \times \ln(2 \times \text{odds}) - \text{pdo}$$

$$\text{Factor} \times \ln(\text{odds}) = \text{Factor} \times \ln(2 \times \text{odds}) - \text{pdo}$$

$$\text{pdo} = \text{Factor} \times \ln(2 \times \text{odds}) - \text{Factor} \times \ln(\text{odds})$$

⁷ Ver Gerard Scallan, Building Better Scoring Cards (Austin, TX: Austin Logistics, 1999), 1013

$$pdo = Factor \times [\ln(2 \times odds) - \ln(odds)]$$

$$pdo = Factor \times (\ln(2) + \ln(odds) - \ln(odds))$$

$$pdo = Factor \times \ln(2)$$

$$Factor = \frac{pdo}{\ln(2)} \quad (3.7)$$

$$\text{De (1): } Offset = Score - [Factor \times \ln(odds)] \quad (3.8)$$

Por exemplo, se a escala de um *tabela de scoring* estivesse a ser graduada, em que o utilizador pretendesse *odds* a 50:1 aos 600 pontos de *score* e se quisesse que os *odds* duplicassem de 20 em 20 pontos (i.e. $pdo=20$), o *Factor* e *Offset* seriam:

$$Factor = \frac{pdo}{\ln(2)} = \frac{20}{\ln(2)} = \frac{20}{0,69315} = 28,8539$$

$$Offset = 600 - [28,8539 \times \ln(50)] = 600 - (28,8539 \times 3,91202)$$

$$= 600 - 112,87712 = 487,12288$$

$$Score = Offset + Factor \times \ln(odds) \quad (3.9)$$

$$Score = 487,12288 + 28,8539 \times \ln(odds)$$

Como esperado o *Score* obtido para as condições impostas seria:

$$Score = 487,12288 + 28,8539 \times \ln(50)$$

$$Score = 487,12288 + 28,8539 \times 3,91202$$

$$Score = 487,12288 + 112,87712$$

$$Score = 600 \text{ pontos}$$

A mesma fórmula pode ser utilizada para *tabelas de scoring* de graduação que tripliquem ou quadripliquem os *odds*. Contudo “pontos para duplicar os *odds*” (*pdo*) é a graduação normalmente utilizada na área de avaliação do risco de crédito.

3.3.8.4 Escolha da tabela de scoring

A maior parte dos construtores de *tabelas de scoring* produzem para um determinado cliente dois ou três modelos diferentes com o objectivo de se escolher aquele que apresenta melhor qualidade. Essa qualidade nem sempre é consensual, obrigando à realização de testes estatísticos que garantam a melhor eficácia possível, face aos objectivos pretendidos.

A dúvida que se coloca a um construtor é saber se a aplicação das tabelas de *scoring* estarão a pontuar bem, isto é, a classificar devidamente os solicitantes de crédito como *Bons* ou como *Maus*.

Aquelas tabelas de pontuação sendo construídas para prever a *probabilidade* de um caso ser *Bom* ou *Mau*, mais não são que instrumentos de previsão utilizados para diferenciar (ou discriminar) entre os casos *Bons* e os *Maus*.

Para o efeito utilizam-se estatísticas específicas que testam aquela capacidade discriminante. Contudo, essa discriminação na análise de risco de concessão de crédito não é 100% eficaz, porque existirá sempre a possibilidade de um *Bom* candidato ser classificado como *Mau* e vice-versa.

Os analistas de crédito são os que melhor confirmam esta realidade, admitindo um nível mínimo de *taxa de aceitação de Maus* (baseada numa pontuação) tendo como referência o ponto de corte que serve de fronteira entre *Bons* e *Maus* (*cutoff*).

Os candidatos que por informações negativas, situações de incumprimento ou aqueles que prestaram informações falsas sobre a sua candidatura, pontuam abaixo do *cutoff* e por isso são recusados.

A tabela de *scoring* final será aquela que oferecer melhores indicações sobre a *minimização* do nível de *Más* classificações. Para comparar a qualidade de diferentes *tabelas de scoring* existem várias medidas utilizadas na aferição do nível de *Más* classificações.

Estas medidas comparam o número de *Bons* e *Maus verdadeiros* (ou seja a actual classificação de cada cliente) com o número de *Bons* e *Maus previstos* pela classificação da tabela de *scoring* relativamente a um determinado *cutoff*.

Isto é, haverá um certo número de casos efectivamente *Bons* que teriam sido provavelmente classificados pela tabela de *scoring* como *Maus* e vice-versa. Aqui, *Bons* e *Maus* referem-se aos casos acima e abaixo do *cutoff* em referência.

Convencionando-se que as *classificações previstas* pelo critério do *cutoff* da tabela de pontuação seriam designadas por ***b*** para os *Bons* e ***m*** para os *Maus*.

De modo idêntico, convencionou-se a letra maiúscula **B** para os *Bons* e a letra **M** para os *Maus* que corresponde às *classificações actuais* ou as *classificações observadas* para cada cliente. Convencionados os significados de cada letra constrói-se as medidas de *má classificação*, a partir de uma *matriz de confusão*, como se ilustra a seguir:

		Classif. Prevista (scorecard)	
		bom	mau
Actual Classif. clientes	Bom	Bb	Bm
	Mau	Mb	Mm

Tabela nº 3.10 – Matriz de Confusão 1

Os elementos da matriz são constituídos pela combinação de uma tabela 2 X 2.

Resta-nos interpretar o significado de cada um deles:

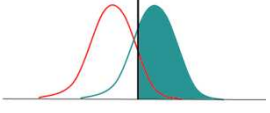
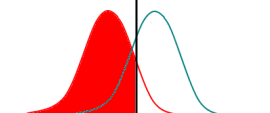
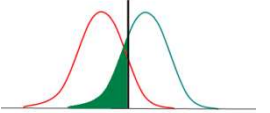
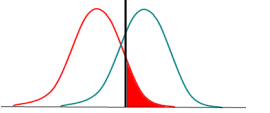
Bb	Significa que a tabela de <i>scoring</i> previu ser uma Boa conta e observou ser uma Boa conta. Designaremos este caso como Positivo Verdadeiro .	 PV
Mm	Significa que a tabela de <i>scoring</i> previu ser uma Má conta e observou ser uma Má conta. Designaremos este caso como Negativo Verdadeiro .	 NV
Bm	Significa que a tabela de <i>scoring</i> previu ser uma Má conta e verificou-se ser uma Boa conta. Designaremos este caso como Negativo Falso .	 NF
Mb	Significa que a tabela de <i>scoring</i> previu ser uma Boa conta e verificou-se ser uma Má conta. Designaremos este caso como Positivo Falso .	 PF

Tabela nº 3.11 – Significado das classificações da Matriz de Confusão

Resumindo na seguinte Matriz de Confusão:

		Classif. Prevista <i>scorecard</i>	
		bom	mau
Classif. Actual	Bom	PV	NF
	Mau	PF	NV

Tabela nº 3.12- Matriz de Confusão 2

Esta matriz permite de uma maneira muito simples avaliar a capacidade preditiva de uma *tabela de scoring* calculando-se a percentagem de contas que foram correctamente classificadas.

A percentagem correctamente classificada é calculada a partir desta matriz para:

- 1) Escolher uma determinada pontuação para o *cutoff*;
- 2) Marcar todas as contas abaixo do *cutoff* como sendo probabilisticamente *Más*, e aquelas acima do *cutoff* como sendo probabilisticamente *Boas*;
- 3) Fazer uma tabulação cruzada entre as *Boas* e *Más* contas previstas pelo *scorecard* e as *Boas* e *Más* contas classificadas por observação;
- 4) Determinar a percentagem de contas que se situam dentro de cada célula;
- 5) Calcular os vários rácios que possam resultar do modelo.

Os casos correctamente classificados são os *Positivos Verdadeiros* e *Negativos Verdadeiros*.

Os casos que não foram correctamente classificados serão designados por *Negativos Falsos* (Erro do tipo I) e *Positivos Falsos* (Erro do tipo II).

Do estudo empírico apresentado no Capítulos 4 retirámos os dados abaixo referidos (Tabela nº 3.13), como exemplo ilustrativo:

Classificação Prevista pelo Scorecard

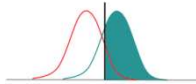
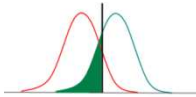
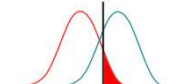
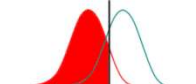
		Bom 1600 50,0%	Mau 1600 50,0%
Classificação Actual	Bom	Positivo verdadeiro 1474 	Negativo falso 167 
	Mau	Positivo falso 126 	Negativo verdadeiro 1433 

Tabela nº 3.13 Classificação prevista vs Classificação actual

Uma *tabela de scoring* de qualidade elevada seria aquela que maximizasse os casos “verdadeiros” e minimizasse os casos “falsos”. Para este efeito, utilizou-se quatro medidas para determinar a má classificação: a Taxa de acerto, Taxa de Erro, Sensibilidade e Especificidade da tabela de *scoring*.

Taxa de acerto:	_____	_____
Taxa de erro:	_____	_____
Sensibilidade:	_____	_____
Especificidade:	_____	_____

Tabela nº 3.14- Quatro medidas para determinar a má classificação: Taxa de acerto, Taxa de Erro, Sensibilidade e Especificidade

Positivos verdadeiros (<i>Bons</i> Verdadeiros)	→	Aceitação de <i>Bons</i>
Positivos Falsos (<i>Bons</i> Falsos)	→	Aceitação de <i>Maus</i>
Negativos Verdadeiros (<i>Maus</i> Verdadeiros)	→	Recusa <i>Maus</i>
Negativos Falsos (<i>Maus</i> Falsos)	→	Recusa <i>Bons</i>

Tabela nº 3.15- Positivos verdadeiros, Positivos falsos, Negativos verdadeiros e Negativos falsos

Taxa de acerto:	$\frac{\text{Positivos e Negativos Verdadeiros}}{\text{Casos Totais}}$	$= \frac{1474 + 1433}{1474 + 126 + 1433 + 167} = \frac{2907}{3200} = 90,84\%$
Taxa de erro:	$\frac{\text{Negativos e Positivos Falsos}}{\text{Casos Totais}}$	$= \frac{167 + 126}{1498 + 126 + 1439 + 167} = \frac{293}{3200} = 9,16\%$
Sensibilidade:	$\frac{\text{Positivos Verdadeiros}}{\text{Positivos reais totais}}$	$= \frac{1474}{1474 + 126} = 92,13\%$
Especificidade:	$\frac{\text{Negativos Verdadeiros}}{\text{Negativos reais totais}}$	$= \frac{1433}{1433 + 167} = 89,56\%$

Tabela nº 3.16- Taxa de acerto, Taxa de erro, Sensibilidade, Especificidade: Cálculos.

Com base nas *quatro medidas* acima referidas uma instituição financeira poderá decidir, por exemplo, maximizar a recusa de *Maus*. Nestes casos, em que as tabelas de *scoring* são construídas para reduzir perdas provocadas por *Más* classificações, a empresa escolheria a tabela de *scoring* que maximizasse a *especificidade*.

No caso em que a empresa pretenda aumentar a sua quota de mercado e admita aprovar alguns *Maus*, pode minimizar a recusa de *Bons*, escolhendo a tabela de *scoring* que maximiza a *sensibilidade*. Aqui as estatísticas são utilizadas no contexto dos objectivos empresariais e com os quais a tabela de *scoring* terá de ser concordante. Esta aferição dos instrumentos de gestão às políticas empresariais constitui só por si, um grande objectivo para o desenvolvimento das organizações.

3.3.9 CAPACIDADE PREDITIVA DE UMA TABELA DE SCORING

A grande maioria dos resultados estatísticos obtidos a partir de bases de dados na área do risco de crédito é utilizada para fins comparativos e para minimização dos problemas de *má classificação* de contas.

A robustez predictiva das tabelas de *scoring* são o resultado da aplicação destas estatísticas responsáveis pela capacidade do desempenho alcançado.

Em alguns casos as tabelas de *scoring* utilizadas no passado ou as que estão em uso são comparadas com outras novas tabelas de construção mais recente. As variações nunca são tão bruscas que determinem a inutilidade total de um sistema de *scoring* de um dia para o outro.

Por outro lado, não se recomendam várias alterações em simultâneo sem se confirmar, previamente, o efeito produzido em todo o sistema por cada uma dessas alterações. Modificações nas estratégias de marketing, nos perfis da clientela e em outros dados, tornarão

inútil a comparação de tabelas de *scoring* produzidas nestas condições com quaisquer outras ainda vigentes.

As tabelas de *scoring* devem ser desenvolvidas no pressuposto de concentrar os melhores indicadores relativamente aos dados em presença. Algumas empresas utilizam tanto a nova tabela de *scoring* como a já existente para pontuar um grupo de contas até verificar qual das duas é a melhor.

Se a tabela de *scoring* actual não for estável este exercício é completamente irrelevante, porque a instabilidade de uma delas poderá em certos casos coincidir com a pontuação da outra, como divergir totalmente.

Se uma tabela de *scoring* for tão instável que impossibilite qualquer comparação poderá significar que, provavelmente, nunca o teria sido antes e os seus pontos fracos só se verificaram muito mais tarde.

3.3.9.1 *Estatística Kolmogorov-Smirnov (KS)*

Este método estatístico mede a distância vertical máxima entre as distribuições das frequências acumuladas de *Bons* e *Maus*.

O ponto fraco deste método reside no facto da separação entre as duas distribuições ser feita no ponto de maior afastamento das suas curvas, o que pode não coincidir com o *cutoff* recomendado.

Se o *cutoff* pretendido da tabela de *scoring* estiver colocado mais para a direita ou mais para a esquerda, este método pode não garantir uma boa indicação de comparação. Nestes casos, poderá ser preferível comparar a distância no *cutoff* pretendido, visto que é nesse ponto onde se exige a separação máxima.




Gráfico nº3.3- Estatística Kolmogorov-Smirnov. Distância vertical máxima entre as distribuições das frequências acumuladas de *Bons e Maus*.

O Gráfico nº3.3 foi obtido segundo os dados da amostra que serviram de base à presente investigação, os quais se transcrevem na Tabela nº3.17.

	Bons	Maus	%Bons nos Bons	%Maus nos Maus	% Bons no Total	% Maus no Total	%Bons no Total Acum.	% Maus no Total Acum.	%Bons+%Maus no Total	Afastamento
4-300	1	1	0,05%	0,05%	0,05%	0,05%	0,05%	0,05%	0,10%	0,00%
301-305	0	1	0,00%	0,05%	0,00%	0,05%	0,05%	0,10%	0,05%	0,05%
306-310	0	2	0,00%	0,10%	0,00%	0,10%	0,05%	0,20%	0,10%	0,15%
311-315	0	6	0,00%	0,30%	0,00%	0,30%	0,05%	0,50%	0,30%	0,45%
316-320	0	3	0,00%	0,15%	0,00%	0,15%	0,05%	0,65%	0,15%	0,60%
321-325	0	9	0,00%	0,45%	0,00%	0,45%	0,05%	1,10%	0,45%	1,05%
326-330	0	13	0,00%	0,65%	0,00%	0,65%	0,05%	1,75%	0,65%	1,70%
331-335	0	11	0,00%	0,55%	0,00%	0,55%	0,05%	2,30%	0,55%	2,25%
336-340	0	24	0,00%	1,20%	0,00%	1,20%	0,05%	3,50%	1,20%	3,45%
341-345	0	12	0,00%	0,60%	0,00%	0,60%	0,05%	4,10%	0,60%	4,05%
346-350	0	5	0,00%	0,25%	0,00%	0,25%	0,05%	4,35%	0,25%	4,30%
351-355	0	5	0,00%	0,25%	0,00%	0,25%	0,05%	4,60%	0,25%	4,55%
356-362	0	3	0,00%	0,15%	0,00%	0,15%	0,05%	4,75%	0,15%	4,70%
363-599	0	35	0,00%	1,75%	0,00%	1,75%	0,05%	6,50%	1,75%	6,45%
600-605	0	1	0,00%	0,05%	0,00%	0,05%	0,05%	6,55%	0,05%	6,50%
606-610	0	33	0,00%	1,65%	0,00%	1,65%	0,05%	8,20%	1,65%	8,15%
611-615	0	17	0,00%	0,85%	0,00%	0,85%	0,05%	9,05%	0,85%	9,00%
616-620	0	36	0,00%	1,80%	0,00%	1,80%	0,05%	10,85%	1,80%	10,80%
621-625	0	53	0,00%	2,65%	0,00%	2,65%	0,05%	13,50%	2,65%	13,45%
626-630	0	101	0,00%	5,05%	0,00%	5,05%	0,05%	18,55%	5,05%	18,50%
631-635	0	31	0,00%	1,55%	0,00%	1,55%	0,05%	20,10%	1,55%	20,05%
636-640	0	54	0,00%	2,70%	0,00%	2,70%	0,05%	22,80%	2,70%	22,75%
641-645	0	32	0,00%	1,60%	0,00%	1,60%	0,05%	24,40%	1,60%	24,35%
646-650	0	76	0,00%	3,80%	0,00%	3,80%	0,05%	28,20%	3,80%	28,15%
651-655	0	69	0,00%	3,45%	0,00%	3,45%	0,05%	31,65%	3,45%	31,60%
656-660	0	76	0,00%	3,80%	0,00%	3,80%	0,05%	35,45%	3,80%	35,40%
661-665	0	94	0,00%	4,70%	0,00%	4,70%	0,05%	40,15%	4,70%	40,10%
666-670	0	94	0,00%	4,70%	0,00%	4,70%	0,05%	44,85%	4,70%	44,80%
671-675	3	87	0,15%	4,35%	0,15%	4,35%	0,20%	49,20%	4,50%	49,00%
676-680	5	95	0,25%	4,75%	0,25%	4,75%	0,45%	53,95%	5,00%	53,50%
681-685	8	100	0,40%	5,00%	0,40%	5,00%	0,85%	58,95%	5,40%	58,10%
686-690	9	130	0,45%	6,50%	0,45%	6,50%	1,30%	65,45%	6,95%	64,15%
691-695	21	130	1,05%	6,50%	1,05%	6,50%	2,35%	71,95%	7,55%	69,60%
696-700	82	115	4,10%	5,75%	4,10%	5,75%	6,45%	77,70%	9,85%	71,25%
701-705	20	68	1,00%	3,40%	1,00%	3,40%	7,45%	81,10%	4,40%	73,65%
706-710	93	79	4,65%	3,95%	4,65%	3,95%	12,10%	85,05%	8,60%	72,95%
711-715	62	81	3,10%	4,05%	3,10%	4,05%	15,20%	89,10%	7,15%	73,90%
716-720	401	64	20,05%	3,20%	20,05%	3,20%	35,25%	92,30%	23,25%	57,05%
721-725	47	34	2,35%	1,70%	2,35%	1,70%	37,60%	94,00%	4,05%	56,40%
726-730	708	63	35,40%	3,15%	35,40%	3,15%	73,00%	97,15%	38,55%	24,15%
731-735	128	17	6,40%	0,85%	6,40%	0,85%	79,40%	98,00%	7,25%	18,60%
736-740	218	23	10,90%	1,15%	10,90%	1,15%	90,30%	99,15%	12,05%	8,85%
741-745	113	12	5,65%	0,60%	5,65%	0,60%	95,95%	99,75%	6,25%	3,80%
746-750	56	3	2,80%	0,15%	2,80%	0,15%	82,20%	98,15%	2,95%	15,95%
751-755	3	0	0,15%	0,00%	0,15%	0,00%	82,35%	98,15%	0,15%	15,80%
756-760	22	2	1,10%	0,10%	1,10%	0,10%	83,45%	98,25%	1,20%	14,80%
	2000	2000	100,00%	100,00%	100,00%	100,00%				

Tabela nº3.17- Dados da amostra que serviram de base à construção do Gráfico nº 3.3

A distância vertical máxima observada foi de 73,9% de *afastamento* entre as curvas de distribuição acumulada de *Maus* e *Bons* e que corresponde à diferença entre as percentagens de 89,1% e 15,2% respectivamente.

Se fosse assumido que seria este o ponto onde o *cutoff* se posicionaria, ou seja no ponto médio do intervalo das pontuações 711-715 sacrificar-se-iam 15,2% de clientes *Bons* para se rejeitar 89,1% dos *Maus*.

	Cutoff	
	Recusa	Aceita
<i>Maus</i>	89,1 %	10,9 %
<i>Bons</i>	15,2 %	84,8 %

Tabela nº 3.18- Matriz de *cutoff*

Contudo, estas regras não obedecem exclusivamente a uma lógica estatística, mas também a estratégias empresariais definidas nas respectivas políticas internas.

Se bem que no exemplo apresentado o *cutoff* poderia ser colocado em pontuações inferiores, dever-se-ia comparar neste caso, a tabela de *scoring* com outras mais antigas ou se indagasse nas políticas da empresa as razões que a levaram a abdicar de 15,2 % de *Bons* clientes como salvaguarda da não aceitação (recusa) de 89,1% de *Maus*.

Em teoria, o posicionamento desta fronteira poderá parecer simples. Se o lucro e prejuízo proveniente das *Boas* e *Más* contas forem conhecidos então é simples calcular o lucro referente à percentagem de *Boas* contas que é necessário para cobrir os custos provocados pelas *Más* contas.

Nesta perspectiva, o quociente entre a percentagem das *Boas* contas e a percentagem das *Más* contas define a probabilidade (*odds*) na qual o ganho incremental é igual à perda incremental e o *score* associado àquele *odds*, será o *cutoff* recomendado.

Contudo, na prática não é tão simples assim porque o verdadeiro lucro de uma *Boa* conta e o verdadeiro prejuízo de uma *Má* conta são muito difíceis de determinar. Uma das razões subjacentes a esta dificuldade prende-se com a política comercial adoptada, com a concorrência do mercado, com alterações nas políticas internas de crédito, com a legislação existente em última análise.

Isto obriga a ligeiras deslocações do *cutoff*, ora para a esquerda ora para a direita, em função de todas as condicionantes referidas. Isto não significa, porém, que sejam feitas alterações bruscas por vezes sem o necessário *Bom* senso, prudência e equilíbrio que aquele ponto crítico exige.

A experiência aconselha que o *cutoff* inicial de um sistema de *scoring* seja próximo ou mesmo igual àquele que se verificava anteriormente, ou seja, próximo da *taxa de aceitação* constatada nos últimos dois a três anos.

3.3.10 OVERRIDES – DECISÕES PREVALECENTES

Vários autores referiram nas suas obras a importância das decisões tomadas por analistas de crédito, que contrariam as orientações dadas pelo sistema de *scoring* (Lewis, (1992, p. 89); Mays, (2001, p.293); Thomas, (2002, p.144); Siddiqi, (2006, p.158); Anderson, (2007, p.82).

Entre o testemunho daqueles investigadores destacam-se práticas e entendimentos sobre as decisões que prevalecem sobre as orientações do sistema de *scoring* e das quais se destacam algumas dessas evidências e entendimentos.

O *cutoff score* estabelece a regra em que as contas pontuadas à sua direita são aceites e à sua esquerda são recusadas. Quaisquer decisões tomadas na concessão de crédito que não sigam o critério definido por aquela fronteira designam-se por *overrides*.

Override traduz, assim, uma tomada de decisão que é contrária às recomendações do sistema de *scoring*. Isto é, não se concedem empréstimos a um cliente, embora o *score* se situe acima do ponto de *cutoff* ou concedem-se empréstimos àqueles cujo *score* se posicione abaixo do *cutoff*.

Estas situações podem ocorrer porque a instituição financeira tem mais informação do que aquela que está contida na tabela de *scoring* ou porque a política da empresa assim o determina, ou ainda por terem sido devidas a uma avaliação subjectiva do analista de crédito. Deste modo, existem três tipos de *overrides*: 1) Com base na informação; 2) Com base nas políticas da instituição de crédito; e 3) Com base na intuição do analista de crédito.

3.3.10.1 Overrides com base na informação

O analista de crédito que esteja na posse de informação ocasional ou outra, que não tenha sido considerada no processo de avaliação, pode prevalecer a sua decisão sobre a recomendação ditada pelo sistema de *scoring*.

Os *overrides* com base em informações que contrariem o critério do sistema de *scoring* são raros. É pouco vulgar um analista de crédito reconhecer a identidade da pessoa cuja

candidatura tem em apreciação e ter também informação específica sobre aquele candidato. Apesar de serem muito raras, estas situações poderão ocorrer.

Neste sentido, o departamento de crédito deverá estar alertado para levar em linha de conta tais eventualidades. Em quaisquer das situações, e segundo os autores citados em 3.3.10, o analista de crédito deverá fazer sempre um registo escrito dos factos que justificaram a decisão tomada.

Nos casos em que se aceitarem candidaturas com *scores* inferiores ao *cutoff*, os registos podem ser analisados mais tarde e constatar se a decisão tomada pelo analista de crédito esteve certa.

3.3.10.2 *Overrides com base nas políticas da instituição*

Este tipo de decisões ocorre quando a Administração estabelece regras especiais para determinadas candidaturas.

De um modo geral, os *overrides* baseados nas políticas institucionais actuam no sentido de se aceitarem candidaturas que tenham sido recusadas quando estas tiveram apenas como suporte a informação dada pelo *score*.

Se uma empresa decide estimular um determinado grupo-alvo de potenciais clientes, pode conceder àquele grupo específico, por exemplo 10 pontos adicionais, durante um certo período promocional. Por exemplo, se a Administração admitir que os estudantes de uma determinada universidade poderão trazer, num futuro próximo, bons resultados para a instituição, aceitarão aqueles estudantes, mesmo que naquele momento o seu *score* não o permitisse.

Trata-se de uma estratégia de fidelização de clientes cujo estatuto peculiar futuro é do interesse da instituição de crédito.

Os *overrides* baseados nas políticas institucionais são frequentes quando se concede crédito a candidatos que não atinjam o *score* suficiente. Contudo, poderão ser *Bons* clientes em outras instituições financeiras.

Este é o caso mais comum que se verifica na Banca nacional com a atribuição de cartões de crédito a clientes que já possuam uma conta de depósito à ordem, ou outro produto de interesse para a instituição bancária.

Contudo, as prevalências decisórias não deverão ser automáticas mas sim enquadradas em políticas escritas, devidamente explícitas, e não num recurso que possa ser aplicado subjectivamente por qualquer analista de crédito.

As relações que as pessoas mantêm com os seus Bancos devem ser objecto de cuidados especiais. Um indivíduo pode ter uma conta pessoal com um pequeno saldo e ser o gerente ou administrador de uma empresa que detém uma conta naquele Banco movimentando quantias muito elevadas.

Não é prudente considerar a recusa de um cartão de crédito pessoal a um indivíduo, nesta situação, apesar do seu saldo ser muito pequeno e não possuir quaisquer outros produtos. O bom senso, manda nestes casos conceder-lhe um cartão de crédito mesmo que o seu *score* se situe abaixo do *cutoff*.

Outros exemplos poderão ser dados sobre *overrides* com base em políticas institucionais. É o caso da Administração da instituição de crédito decidir conceder cartões de crédito a todos os quadros de determinada empresa que o solicitem, mesmo que nem todos os quadros se elejam para a sua obtenção.

Existem múltiplas estratégias que antecipam a possibilidade de se tomarem decisões contrárias às recomendações do sistema de *scoring*. O importante a reter é o facto de se evitar que estas decisões sejam subjectivas e tomadas sem o fundamento necessário.

3.3.10.3 Overrides com base na intuição do analista de crédito

Este tipo de decisões é o mais comum e o menos justificado. Verifica-se quando um analista de crédito inverte a decisão recomendada pelo *score*, por outras razões além das baseadas nas políticas institucionais ou em informações avulsas. Esta inversão é normalmente feita para recusar uma solicitação de crédito.

Por razões que por vezes o próprio analista não sabe explicar, considera que a candidatura é “fraca”, dizendo-lhe a experiência que será imprudente conceder crédito àquele candidato.

O caso contrário também é possível, considerando uma candidatura “forte” apesar de traduzir um *score* abaixo do *cutoff*.

Em ambos os casos o analista quase sempre não consegue explicar a sua decisão, a não ser invocar a sua convicção, suportada na sua experiência. De facto, o analista diz que a sua

experiência aplicada àquele caso particular traduziu-se numa decisão mais acertada que a recomendação do sistema de *scoring* implantado na organização.

Também por razões que não conseguem explicar, a maioria dos gestores de crédito permitem, de uma forma muito liberal aos seus analistas, tomar decisões contrárias às recomendações do sistema de *scoring*, com base nas suas intuições e convicções.

Alguns gestores de crédito dão liberdade e autoridade aos seus analistas para ultrapassarem os limites padronizados, dentro de certos intervalos de pontuação, ou seja concedem a liberdade de aumentar ou reduzir entre 5 a 10 pontos o valor do *cutoff*.

É na vizinhança do *cutoff* que o sistema de *scoring* é mais crítico e valioso. A dificuldade da decisão não estará por certo em conceder crédito a quem se situe 100 pontos acima ou recusar o crédito a quem estiver 100 pontos abaixo do *cutoff*. É na vizinhança deste ponto que o sistema de *scoring* demonstra a sua eficácia.

A permissão para tomar decisões contrárias às estabelecidas são por vezes justificadas pelos próprios analistas que reclamam que a sua experiência profissional em nada valeria se a sua contribuição pessoal na redução do risco não pudesse ser manifestada.

Estes analistas desejam ser vistos como úteis e, desta forma, protegerem as suas posições, isto é, o facto de terem de aceitar todas as recomendações de um sistema automático de *scoring* poderia, eventualmente, questionar a necessidade da sua existência.

Em muitos casos a prevalência da decisão por intuição é permitida, mais para manter a moral daquele pessoal, do que trazer uma melhor consistência ao sistema de pontuação.

A forma de contornar esta delicada situação é a redefinição do papel do analista, atribuindo-lhe a tarefa de verificar e validar as suas próprias decisões que contrariaram o sistema. Deste modo, o analista confrontará o que é suposto o sistema fazer e o que a sua experiência ditou na decisão que tomou.

3.3.11 MUDANÇAS NA PONTUAÇÃO DO CUTOFF

Segundo Lewis (1992, p.113), após a instalação do sistema qualquer analista de crédito ou utilizador do sistema de *scoring* deverá estar preparado para ajustar o *cutoff* ao verificar que a *taxa de recusa* é muito diferente das previsões iniciais.

Ainda segundo o relato daquele autor (ibidem), durante o desenvolvimento do sistema os dados podem revelar que um *score* de *cutoff* aos 200 pontos origina 40% de recusas, podendo este número ser escolhido como o *cutoff* inicial.

Após um mês, ou depois de um número significativo de candidaturas ter entrado, verifica-se por exemplo, que a *taxa de recusa* é apenas de 35% ou que aumentou para 45%. Se a distribuição de *scores* for idêntica à amostra original, atinge-se a *taxa de recusa* pretendida, através de uma ligeira alteração no *cutoff*.

Ainda de acordo com Lewis (ibidem) não é necessário fazer muitos ajustes no *score* do *cutoff* para se obter o resultado desejado. Nestas condições, é necessário examinar o *cutoff* depois do sistema de *scoring* ter estado em funcionamento durante uns meses e ter havido tempo suficiente para que se tivessem manifestado alterações nas condições sociais e económicas com influência directa ou indirecta no funcionamento da instituição de crédito.

Um gestor de crédito que deseje reduzir o risco deve neste caso aumentar o *cutoff* pela quantidade de pontos que a estatística sugere. Alternativamente, um outro gestor de crédito que pretenda aceitar um risco maior deve, obviamente, aceitar uma redução do *cutoff*.

De vez em quando, um gestor de crédito modifica o *score* do *cutoff* para conseguir uma finalidade específica. Por exemplo, pode decidir atrair um determinado grupo-alvo de futuros clientes, tais como estudantes das universidades ou atingir grupos específicos de indivíduos que ainda não tenham manifestado particular interesse nas ofertas da instituição de crédito.

Em tais casos, o gestor de crédito pode escolher um *cutoff* diferente do estabelecido para angariar clientes num mercado específico, reconhecendo-se contudo, que há sempre um custo associado quando se adoptam estas estratégias.

Quem concede crédito *não* deve alterar o seu *score* de *cutoff* como reacção à mudança das condições externas sem uma análise cuidadosa. Não é inédito as instituições de crédito considerarem a alteração dos seus *scores* de *cutoff* quando a economia sofre uma reviravolta inesperada.

Nestes casos, a direcção de crédito teria considerado que devia “apertar o cinto” subindo o *cutoff*, evitando assim alguns prejuízos. Nesta atitude existem dois erros:

- O primeiro erro consiste numa alteração no *cutoff* que por muito drástica que seja só afectará os novos candidatos, nada fazendo para melhorar a qualidade das contas actuais.

Qualquer alteração no *cutoff* não se reflectirá na qualidade da população global de clientes até que as contas abertas, de acordo com o novo modelo de *cutoff* constituam uma percentagem significativa de toda a população, o que pode demorar muito tempo a acontecer.

- O segundo erro manifesta-se ao alterar (principalmente em subir) o *cutoff* perante a evidência de uma crise económica, o que não é necessariamente verdade que isso tenha algum efeito sobre a população de clientes.

O impulso em fazer subir o *cutoff* baseia-se na ideia de que o risco medido pelo sistema de *scoring* assim o aconselha, devido à mudança verificada na economia. Esta ideia não parece ser correcta porque quando acontece uma crise económica as pessoas não abrem subitamente contas de crédito no pressuposto de não as conseguirem pagar.

A economia demonstra que quando surge uma crise, o volume de candidaturas baixa, pois as pessoas tomam mais precauções perante a incerteza.

O *score* de *cutoff* nunca deverá ser alterado no pressuposto de constituir um curativo para um suposto mau funcionamento do sistema de *scoring*. Nenhuma alteração no *cutoff* irá melhorar um sistema de *scoring* “mal concebido”; o que é necessário fazer, num caso destes, é desenvolver um sistema de *scoring* completamente novo.

3.4 SCORING COMPORTAMENTAL

De acordo com informações de natureza confidencial obtidas junto de instituição financeira, e das práticas da FICO (Fair & Isaac, Co)⁸ os indivíduos aceites pelas instituições financeiras como utilizadores de cartões de crédito passam, a partir desse momento, a ser analisados e monitorizados pelo seu comportamento.

O comportamento do indivíduo é definido em termos de volume de compras e da pontualidade dos respectivos pagamentos, passando a designar-se por *Scoring Comportamental* as pontuações dadas àquelas características.

Esta metodologia foi implantada pela primeira vez pela firma Fair, Isaac and Company no final da década de 1960.

A metodologia aplicada ao desenvolvimento de um sistema de *scoring comportamental* é quase a mesma que é utilizada na produção de um sistema de *scoring de atribuição*, mas o

⁸ <http://www.fundinguniverse.com/company-histories/Fair-Isaac-and-Company-Company-History.html>

modo como os dados são preparados para utilização é bastante diferente. A diferença reside no facto das contas a ser utilizadas em *scoring* comportamental encontrarem-se, obviamente, entre aquelas que já têm um histórico, enquanto as contas aceites no *scoring* de atribuição não terem quaisquer registos anteriores.

Tal como no caso de uma tabela de *scoring de atribuição* é necessário obter-se um conjunto de contas *Boas* e *Más*. Neste caso, as contas a serem utilizadas encontram-se, obviamente, entre aquelas que já têm um histórico.

Ao efectuar-se uma análise ao ficheiro mestre da instituição financeira, consegue-se identificar um conjunto de contas que satisfaz a definição de *Más* e outro que satisfaz a definição de *Boas*. Tal como no caso do *scoring de atribuição* as definições de *Bons* e *Maus* devem ser objectivas, de tal modo que se possa fazer um programa informático capaz de as identificar.

O objectivo é determinar a partir dos dados conhecidos num certo período de tempo, qual é o risco de um indivíduo entrar em incumprimento num período posterior.

Ao contrário de um sistema de *scoring de atribuição*, a tabela de *scoring comportamental* pode ser aplicada com periodicidade mensal, como fazendo parte do ciclo normal de facturação durante o qual cada conta é examinada, possibilitando detectar quaisquer alterações na posição de risco.

O procedimento descrito permite desenvolver um sistema de *scoring comportamental* desde que a informação contida no ficheiro mestre do sistema de facturação seja suficiente, o que nem sempre acontece, tornando-se impossível seguir aquele procedimento.

Uma prática mais comum é começar por planear um formato de ficheiro mestre que contenha o tipo de informação que é necessário à feitura de tal sistema.

Em muitos casos, uma instituição financeira sabendo que adoptará mais cedo ou mais tarde o *scoring comportamental* começa por obter os ficheiros adequados com grande antecedência, tornando a construção da tabela de *scoring* muito mais rápida do que teria sido no caso de ter de esperar pela criação da amostra.

Assim que um ficheiro mestre é planeado e instalado os dados começam a acumularem-se. Quando estiverem disponíveis dados suficientes (normalmente colectados em um período que vai de 6 a 24 meses), é declarado o “*momento zero*” e o tempo começa a contar a partir desse momento.

Mais ou menos seis meses mais tarde, (*período de observação*) é possível identificar algumas contas como *Boas* e outras como *Más*. Se houver bastantes contas de cada, o sistema de *scoring* pode ser construído com base nos dados do ficheiro mestre.

Segundo Alan Jost (1998) quando se constrói um modelo de *scoring* um analista utiliza dados históricos para cada indivíduo, na amostra de desenvolvimento. No caso mais simples, selecciona-se um ponto no tempo ou “*ponto de observação*” decorridos 6 meses até 2 anos.

A informação conhecida acerca do indivíduo nesse ponto é usada para prever o desempenho futuro. Porque o ponto de observação está no passado, o desempenho “futuro” chamado “*período de saída*” é utilizado para se avaliar a eficácia do modelo de *scoring*.

O *período de construção histórica* é utilizado para desenvolver as variáveis de previsão no modelo de *score*. Uma vez construído um modelo de crédito as contas são pontuadas “hoje”, isto é, na data em que foi solicitado o crédito.

Nas áreas do *revolving credit*, os *scores* construídos para avaliar novas contas chamam-se *scores de aplicação* ou de *atribuição* e os que são construídos para prever o tipo de desempenho futuro das contas existentes são designados por *scores* de comportamento (*behaviour scoring*), como aliás já referido anteriormente.

São utilizadas diversas abordagens na construção da amostra em que será baseado o sistema de *scoring*. Uma delas é utilizar todo o portefólio de contas e construir o sistema sobre contas que se mostraram ser *Boas* no “*momento zero*” mas que foram divididas entre *Boas* e *Más* no “*período de observação*”.

Outra abordagem é utilizar apenas o subconjunto das contas antigas que, no “*momento zero*”, tenham atingido o primeiro nível de incumprimento. Nalguns casos, aquele nível poderá ser de cinco dias de atraso, noutros trinta dias ou mais.

Embora o sistema de *scoring comportamental* esteja construído deste modo, o resultado final é uma tabela de pontuação que pode ser implantada no sistema de facturação que calculará o risco desta se tornar numa conta *Má* num futuro próximo.

3.4.1 BOAS E MÁS CONTAS NO REVOLVING CREDIT

Segundo relato confidencial de instituição financeira, uma *Boa* conta nas operações de *revolving credit* pode ser caracterizada através dos registos da facturação e de outros ficheiros da empresa nos quais se evidenciem alguns elementos que permitam classificá-la como tal.

A título de exemplo hipotético: - a conta estar aberta há mais de 18 meses; ter tido 6 meses de actividade nos últimos 10 meses; ter efectuado movimentos no mínimo de 100 € em pelo menos 3 meses, nos últimos 18 meses; não ter registos de atraso de pagamento de 30 dias nos últimos 18 meses, entre outras condições que tivessem sido estabelecidas para a definição de uma *Boa* conta.

Uma *Má* conta é mais difícil de descrever porque apesar de não ser abonatório o atraso no pagamento são estas contas as mais taxadas em juros, pela mora, e portanto mais rentáveis por um lado, mas com maior risco por outro.

Segundo Siddiqi (2006, p.38) a definição de uma *Má* conta assenta em diversas considerações, tais como:

a) A definição deve estar de acordo com os objectivos da organização e com a finalidade para a qual o *scorecard* foi construído, isto é com base em variáveis quantitativas, nomeadamente aquelas que definam os montantes da dívida; o número de dias de atraso; o tempo ao fim do qual uma dívida deve ser cancelada (*write-off*).

b) A definição deve ser facilmente interpretável e explicitada por parâmetros quantitativos, como por exemplo “sempre que a dívida atinja 90 dias de atraso”, “sempre que se verifique 30 dias de atraso por três vezes em um ano”;

Ainda segundo o mesmo autor, as empresas podem classificar uma conta como *Má* com base em critérios contabilísticos ou de acordo com as políticas de crédito adoptadas.

Uma conta classificada como *Má* pode ser rentável para a instituição financeira se oferecer pouco risco. É o caso dos clientes que pagam sempre com atrasos consideráveis, devido a negligência ou esquecimento das datas de vencimento das obrigações.

Com critérios e definições acima referidos é possível desenvolver programas informáticos para perscrutar o ficheiro da facturação e identificar todas as contas que se integrem em cada um dos grupos.

Contudo, é necessário ter em atenção que estas definições deverão ser coerentes com os objectivos organizacionais da empresa ou seja as *políticas de crédito deverão ser estabelecidas em função dos objectivos da empresa definindo as regras ...que garantam a prossecução daqueles objectivos* (Batista, 2004, p.67).

Em alguns casos é conveniente possuir definições coerentes entre as várias tabelas de *scoring* utilizados na empresa. Este preceito possibilita decisões mais uniformes, coerentes e

objectivas, especialmente em empresas com diferentes unidades estratégicas de negócio nas quais são utilizados diferentes *tabelas de scoring*.

Associadas às definições de *Má conta* devem existir escalas graduadas com pontuação consistente reduzindo os custos de treino e de programação na reformulação das tabelas de *scoring*.

O *Acordo de Basileia II* é um bom exemplo destes pressupostos considerando “*Más*” todas as contas bancárias com atrasos superiores a 90 dias, tomando uma posição pragmática ao definir os diferentes segmentos de actividade económica como “*agrupamentos de risco homogéneo*”.

Esta segmentação pode ser executada por técnicas de agrupamento estatístico (*clustering*) que identificam grupos que sejam semelhantes entre si.

Na maioria das empresas portuguesas as definições *Más/Boas contas* não se encontram escritas nas políticas de crédito, quando estas existem, classificando como *Má conta*, apenas pela informação dada pelo *mapa de antiguidade de saldos*, cujo horizonte temporal de relato raramente excede 6 meses.

3.4.2 SCORING COMPORTAMENTAL NA PRÁTICA: SISTEMA DE CONTROLO ADAPTÁVEL

O *scoring comportamental* é útil em muitas áreas de decisão relacionadas com uma operação de crédito.

Pode ser utilizado conjuntamente com uma estrutura mais complexa denominada *Sistema de Controlo Adaptável* que lhe confere maior precisão, nomeadamente, sobre as estratégias de cobrança aconselhadas, à definição de limites de crédito, à suspensão do cartão de crédito, entre outras estratégias que a experiência consagrou.

O *Sistema de Controlo Adaptável* tornou-se, assim, capaz de diferenciar minuciosamente entre as diversas contas, aquelas que permitem à Gestão de Crédito aplicar as suas estratégias em função dos diferentes grupos de risco, com uma grande precisão.

3.4.3 CONTROLO ADAPTÁVEL

Enquanto o *scoring comportamental* é, por si só, uma ferramenta poderosa, torna-se ainda mais poderosa quando faz parte de um sistema que pode examinar estratégias alternativas de controlo de crédito, nomeadamente as estratégias de cobranças, as quais podem ser adaptadas a várias situações. Um sistema assim construído, procura continuamente o melhor conjunto de estratégias na concessão e recuperação do crédito concedido.

O *credit scoring*, tanto para avaliação de candidaturas (*scoring* de atribuição) como para avaliação do comportamento de pagamento dos clientes já existentes (*scoring* comportamental), pode constituir uma componente-chave na determinação da política de crédito.

Logo que estabelecida a política de crédito em termos objectivos, pode desenhar-se um programa informático capaz de implementar todas as componentes da política que não exijam intervenção humana. Assim que uma estratégia tenha sido adoptada é pertinente questionar se será a melhor para atingir um determinado objectivo.

Sem a existência de um sistema que possibilite a aplicação de várias estratégias, em operações quotidianas de concessão de crédito, torna-se extremamente difícil aplicar duas estratégias concorrentes para se descobrir qual é a melhor.

O *Sistema de Controlo Adaptável* torna possível a avaliação de estratégias alternativas de crédito, permitindo que duas (ou mais) estratégias de crédito funcionem em simultâneo em qualquer área de decisão de crédito. O SCA também possibilita que os desempenhos de cada estratégia sejam quantificados, permitindo a comparação entre eles.

O programa informático desenhado para este fim deverá ser programado para implantar novas estratégias e retirar ou modificar as antigas sem necessidade de intervenção dos serviços de processamento de dados da empresa.

O Gestor de Cobranças converterá os objectivos de desempenho para uma estratégia que relacionará as condições das contas em incumprimento (o grau de incumprimento actual, os saldos por liquidar, o incumprimento observado anteriormente, e outros factos conhecidos) com diversas acções que o departamento de cobranças possa empreender.

As acções possíveis incluem (além de não se fazer nada) o envio de cópias de extractos da conta, cartas de cobrança, telefonemas, visitas, acção litigiosa, anulação/redução da dívida e a venda da conta a uma firma de cobranças.

O fluxo de acontecimentos começa com o comportamento dos próprios *clientes*. A *base de dados* de clientes recebe informação de e sobre os clientes sob a forma de notas de encomenda, pagamentos e transacções não monetárias, como alterações de morada, pedidos de alterações de limite, respostas a telefonemas, etc.

A *base de dados* fornece a informação necessária para preparar as facturas do cliente bem como os dados a partir dos quais se preparam os relatórios. Duma maneira geral, existem duas categorias de relatórios: *financeiros* e *operacionais*.

Os *relatórios financeiros* nas cobranças mostram de formas diversas os montantes vencidos por intervalos de tempo e as quantias cobradas. Estes relatórios deverão ser enviados para outros departamentos da empresa incluindo o próprio Gestor de Cobranças.

Os *relatórios operacionais* relatam as diversas acções efectuadas em diferentes grupos de contas.

A *base de dados* é a fonte de informação para o departamento de cobranças no que concerne às contas em incumprimento, uma vez que é nos registos da facturação que se encontram as contas mais antigas e agrupadas no *Mapa de Antiguidade de Saldos*.

A estratégia de cobrança será aplicada a cada uma das contas em incumprimento e é especificada a acção adequada a cada uma delas.

A partir de aqui empreende-se a acção especificada, quer seja automaticamente (se a acção exigida for o envio de uma cópia do extracto ou uma carta de cobrança) quer seja pessoalmente, através de instruções passadas a um elemento da equipa de cobranças.

A informação resultante destas acções será acrescentada à base de dados de clientes, dando origem à produção de relatórios.

3.4.4 FACTORES CIRCUNSTANCIAIS NA REVALIDAÇÃO DE CARTÕES DE CRÉDITO

A revalidação dos cartões de crédito passa pela análise de factores circunstanciais que determinam uma nova emissão.

Os cartões são geralmente válidos por um certo período de tempo, normalmente, um ano, mas muitas vezes são válidos por dois ou três anos.

Segundo informação de fonte confidencial, alguns dos factores circunstanciais que se consideram determinantes para se efectuar uma nova emissão do cartão de crédito são: a actividade da conta; a sua antiguidade; o tipo de saldos que a conta tem apresentado; e a história de incumprimento, se esta existir.

O *score comportamental*, quando disponível, torna-se um factor adicional para se chegar à decisão de nova emissão.

A Tabela nº 3.19 mostra um tipo de estratégia relativamente simples para a revalidação de um cartão de crédito, que pode ser utilizada quando se possui um sistema de *scoring comportamental*.

Exemplo ilustrativo:

Nível de incumprimento	Actividade da conta		Score Comportamental	Revalidação cartão crédito Meses
	Ciclos de Incumprimento actuais	Meses desde última actividade		
0	0-12	0-1	Abaixo 320	18
			321-399	24
			400 ou mais	36
1	13 ou mais	2 ou mais	Abaixo 320	12
			321 ou mais	18
		na	0	
	0-12	0-1	Abaixo 320	12
			321 ou mais	18
		2 ou mais	Abaixo 320	0
2	13 ou mais	na	na	0
		na	na	0
		na	na	0

Tabela nº 3.19- Estratégia de Revalidação de cartões de crédito. Adaptação de Lewis (1992) “An Introduction to *credit scoring* (pág. 125)
na-Não aplicável

A estratégia apresentada combina o nível de incumprimento com a actividade da conta, do nível mais elevado de incumprimento no passado e do *score comportamental*. Contudo, visto que estas estratégias estão automatizadas no programa informático o tempo de processamento não sofre nenhuma carga apreciável.

O sistema examina todas as contas em cada ciclo de facturação e todos os factores em presença, melhorando-se em muito o desempenho global da carteira de clientes.

3.4.5 MODIFICAÇÃO NOS LIMITES DE CRÉDITO

Segundo Lewis (1992, p. 126) a alteração do limite de crédito pode ter um efeito surpreendente no desempenho global de uma operação de crédito. Quanto mais elevados forem os limites de crédito, sem aumentar o risco, maior a probabilidade da operação ser lucrativa.

Neste pressuposto, a instituição deve proporcionar a cada cliente, através do seu departamento de crédito, um limite que o encoraje a utilizar o crédito e, simultaneamente, mantê-lo como cliente de baixo risco de incumprimento.

No momento em que se aceita uma nova conta atribui-se um determinado limite de crédito.

O limite inicial pode contemplar uma das seguintes situações: conceder o mesmo montante de crédito a todas as contas aceites; ou fixar um limite diferente para os diferentes grupos de candidatos. Estes critérios variam entre as instituições de crédito.

A política de crédito pode considerar diversos factores, tais como; os bens do candidato; as suas responsabilidades; o tipo de emprego; e quaisquer outros itens que se julguem ser importantes.

Começando logo nos primeiros meses de vida de uma conta, e face ao seu comportamento, o gestor de crédito poderá recomendar a alteração do limite de crédito.

A direcção de crédito pode construir uma tabela de estratégia do tipo que está ilustrado (parcialmente) na Tabela nº 3.20.

A estratégia completa incluiria toda a gama de outros factores caracterizadores daquela conta específica.

A estratégia preconizada na mesma Tabela nº 3.20 pode ser feita de modo mais simples ou mais complexo, dependendo dos objectivos da direcção de crédito.

Deve-se começar com uma estratégia relativamente simples, medindo-se os seus resultados e depois verificar se as alterações melhoram o desempenho global.

Na última coluna da Tabela nº 3.20 introduziu-se um *código de acção* em vez de descrever a respectiva *acção*, visto que esta a ser empreendida pode depender de vários factores.

Ciclos de Delinquência actuais		Meses desde a última actividade	Meses em carteira	Score comportamental	Código de acção
0	0	0-5	1-12	<128	0
				128-200	1
				201+	2
			13 ou mais	<128	0
				128+	2
				na	0
1-2	0-5	6 ou mais	na	<200	0
			na	200+	1
			na	na	0
			na	na	0
			na	na	0
			na	na	0
1	0	0-5	1-12	<128	0
				128+	1
				13+	<128
			13 ou mais	<128	0
				128+	1
				na	0

Tabela nº 3.20 - Tabela de Estratégia (parcial). Adaptado de “An Introduction to Credit Scoring” (p.127)
na-Não aplicável

Podem efectuar-se diferentes alterações ao limite de crédito, dependendo: do saldo actual da conta; da percentagem utilizada face ao limite actual; da percentagem mais elevada do limite que tem sido sempre utilizado; e do tempo decorrido desde a última alteração.

Tal como no caso da estratégia de revalidação de cartões, esta estratégia pode ser muito complexa recomendando-se começar com uma estratégia relativamente simples, até que se interprete bem o modo de lidar com outras estratégias.

As contas para aumento do limite de crédito deverão ser avaliadas numa base periódica, nomeadamente trimestral ou semestral. Também se poderá aumentar o limite de crédito a pedido do cliente.

A direcção de crédito deve reflectir cuidadosamente sobre o objectivo que pretende alcançar, devendo construir uma tabela que melhor sirva esse objectivo.

3.4.6 COBRANÇAS

A primeira área de interesse para qualquer departamento de crédito é a eficiência obtida no processo das cobranças. Nesta área, a direcção de crédito pode determinar qual a acção de cobrança a ser empreendida a vários níveis de risco e a vários níveis de incumprimento.

A Tabela nº 3.21 é um exemplo ilustrativo do aspecto de uma estratégia de cobranças, dirigida a contas com 30 dias de incumprimento. Todos os tipos de alternativas são possíveis e cada operação de crédito terá tantas condições especiais quantas se pretendam incluir.

Exemplo ilustrativo:

Score	Incumprimento por intervalos da dívida			
	< 100 €	100 € - 300 €	301 € - 500 €	Acima de 500 €
Abaixo de 200	Carta nº1	Telefonema	Telefonema	Carta do advogado
201-210	Carta nº2	Carta nº2	Telefonema	Telefonema
211-240	Reenvio do extracto	Carta nº2	Carta nº3	Telefonema
Acima de 240	Reenvio do extracto	Reenvio do extracto	Carta nº2	Carta nº3

Tabela nº 3.21- Estratégia de Cobranças. Adaptado de “An Introduction to Credit Scoring” p.128

As cartas terão conteúdo diferenciado face à gravidade da situação. Para os demais níveis de incumprimento serão necessárias tabelas de estratégia semelhantes as quais devem tomar em consideração todos os factores que a direcção de crédito julgue conveniente incluir no processo de decisão.

Sempre que seja seguida uma nova estratégia, deve-se prever espaço no ficheiro mestre para se registar qualquer acção que deva ter lugar, de modo a que se possa analisar, posteriormente, a eficácia de cada acção.

A questão que se coloca a cada estratégia é conhecer os resultados que produzem. Neste sentido, poder-se-á questionar: “Em que percentagem dos casos é que o reenvio do extracto resultou em recebimentos?”, “As diversas cartas foram eficazes?”, “Os telefonemas produziram resultados?”.

As respostas a estas questões poderão conduzir a alterações parciais da política de crédito, devendo manterem-se as partes dessa política que se revelaram ser adequadas.

3.4.6.1 *Contas que ultrapassam o limite de crédito*

Apesar da fixação de limites de crédito algumas contas excedem esse limite. Esta situação pode ocorrer como resultado de uma autorização de compra ou uma acumulação de compras de baixo valor, cada uma dentro da quantia automaticamente autorizada, mas que quando acumulada ultrapassa o limite de crédito autorizado.

Em ambos os casos, a instituição credora deverá prever uma estratégia para cada caso em particular.

Uma vez que o *score comportamental* quantifica uma medida de risco apresentada pela conta, a direcção de crédito pode estabelecer uma estratégia orientada para o risco, determinando a acção que deve ser empreendida.

Tal como no caso das cobranças, as instituições financeiras podem querer utilizar uma combinação de *score comportamental* e o valor em dívida, além do limite de crédito, para determinar a estratégia a seguir, mas em outras instituições poderão ter outros critérios de avaliação.

3.4.6.2 *Autorizações para pagamentos com cartões de crédito*

As autorizações para pagamentos com cartões de crédito estão intimamente ligadas às comunicações. Num passado não muito longínquo ainda se presenciava à comunicação telefónica num ponto de venda, para se obter uma autorização de pagamento.

Hoje, as comunicações por satélite e o desenvolvimento contínuo verificado nas tecnologias que suportam esta via de comunicação têm aumentado a qualidade na rapidez dos pagamentos com cartões de crédito.

Esta melhoria de qualidade constata-se na possibilidade do estabelecimento da comunicação a grandes distâncias entre o utilizador do cartão e a instituição que o emitiu.

Em um passado recente era muito difícil controlar as autorizações, principalmente para distâncias longínquas e para zonas com fusos horários muito diferentes. Ainda hoje é difícil para um cidadão nacional, a viajar em certos países do continente africano obter uma autorização rápida para qualquer pagamento com cartão de crédito.

Embora as comunicações sejam hoje mais fáceis e mais baratas, o volume de pedidos de autorização é cada vez maior. A rapidez de resposta é muito importante, tanto para o

consumidor, que não gosta de esperar, como para o vendedor que não quer perder a venda provocada pela desistência do comprador face à sua impaciência.

Os sucessivos avanços nas tecnologias das comunicações constituem uma grande ajuda na melhoria das autorizações de pagamento. Actualmente, cada ponto de venda está ligado directamente ao sistema central de facturação sendo possível “chamar” o programa de autorizações sempre que exista “sinal” de venda. Deste modo, as autorizações de compras tornaram-se relativamente fáceis e os tempos de demora são, normalmente, curtos. Nestes casos, podem efectuar-se muitas autorizações automaticamente segundo critérios incorporados no sistema informático da empresa. Os atrasos só ocorrem quando o programa decide que é necessária a intervenção humana.

As autorizações de compras, em que o cartão não está associado a nenhuma cadeia específica de lojas, são consideravelmente mais difíceis. O cliente pode encontrar-se num local e a entidade financeira a uma grande distância. Nestes casos a comunicação tem que ser estabelecida com algum ponto que possa tomar a decisão.

Os avanços tecnológicos estão constantemente a facilitar este processo, permitindo que o cartão incorpore na banda magnética informação codificada que possa ser disponibilizada e modificada pela máquina do ponto de venda.

Se o cartão mostrar que existe muito espaço até ao limite de crédito para a compra em questão, a instituição financeira pode estabelecer uma estratégia em que não seja necessário nenhum telefonema e a compra poderá ser aprovada automaticamente.

Se a compra for muito superior ao montante fixado pela instituição de crédito terá então de se efectuar um telefonema para algum ponto intermédio onde seja possível calcular o *score comportamental* e aplicar a estratégia adequada.

Hoje é possível enviar cópias de ficheiros mestre completos para os pontos de decisão intermédios, permitindo tomar quase todas as decisões, localmente ou nesses pontos intermédios, sem ter de se recorrer ao ficheiro central.

3.4.6.3 Estratégia “Campeã” versus “Desafiadora”

Uma das questões que se coloca a qualquer gestor de crédito é saber se as estratégias preconizadas são aceitáveis para os diferentes níveis de incumprimento. Ou por outras palavras, se haverá uma estratégia diferente que produza melhores resultados do que aquela

que está a ser utilizada. A resposta a esta questão só poderá ser dada experimentando outra estratégia e comparar os resultados.

Uma estratégia de cobrança que esteja em uso, é aquela que em princípio produz melhores resultados utilizando-se as designações tradicionais de estratégia “*Campeã*” e a sua alternativa por estratégia “*Desafiadora*” (ver Philip Kotler, 1991, p.373), (Anderson, 2007, p.575), (Lewis, 1992, p.134), (Siddiqi, p.143).

Para se saber qual das duas estratégias produzem melhores resultados nos processos de cobrança permite-se que ambas possam ser testadas e revelem, através dos seus relatórios financeiros, os resultados que cada uma obteve.

Se se verificar, após algum tempo de teste que a estratégia “*Campeã*” é aquela que continua a mostrar melhores resultados que a estratégia “*Desafiadora*”, então esta última é descartada e substituída por uma nova estratégia “*Desafiadora*” que medirá “forças” com a estratégia actual.

O processo desenvolve-se por comparação sistemática entre as duas estratégias, até surgir uma estratégia “*Desafiadora*” que produza melhores resultados que a estratégia “*Campeã*”, tomando o seu lugar, isto é, tornando-se na nova estratégia “*Campeã*” e assim sucessivamente.

A operação simultânea das duas estratégias concorrentes não pode ser aplicada a todas as contas, de uma só vez. As razões para esta limitação prendem-se com o rigor da previsão da estratégia “*Desafiadora*”.

O *Sistema de Controlo Adaptável* dispõe de duas *características* que permitem ao gestor de crédito testar a estratégia “*Desafiadora*” com segurança e com o mínimo risco:

- A primeira destas *características* consiste em permitir ao gestor de crédito indicar a percentagem de contas que pretende submeter à estratégia “*Desafiadora*”.

Se esta estratégia não apresentar grandes diferenças da estratégia “*Campeã*”, o gestor de crédito poderá enviar 25 a 50% das contas para a estratégia “*Desafiadora*”. Se, ao invés, a estratégia “*Desafiadora*” for muito diferente da estratégia “*Campeã*” aquele gestor poderá preferir enviar apenas 4 a 5% das contas, no sentido da estratégia concorrente.

O *Sistema de Controlo Adaptável* permite ainda alterar a percentagem de contas tratadas pelas várias estratégias, em qualquer momento, à medida que a confiança adquirida na estratégia alternativa aumenta.

- A segunda *característica* trata o problema de garantir que as percentagens das contas enviadas para cada uma das estratégias concorrentes são estatisticamente equivalentes.

Para que o desempenho das duas estratégias possa ser rigorosamente comparado, devem os conjuntos de contas tratadas pelas respectivas estratégias, ter uma composição semelhante.

A competição entre as estratégias “*Campeã*” vs “*Desafiadora*” não se resume apenas a ter uma estratégia “*Desafiadora*” mas várias ao mesmo tempo. Este procedimento produz resultados mais rápidos, uma vez que não se torna necessário esperar pelo fim da experiência de uma estratégia, para se iniciar a seguinte.

As estratégias utilizadas para a cobrança de contas incumpridoras, cobrança de contas que ultrapassaram o limite de crédito, alterações do limite de crédito, autorizações e reemissão de cartões de crédito, permitem ao gestor de crédito conduzir as suas operações como um SCA.

Este sistema reconhece que o mundo em que vivemos está em constante mudança e que as soluções para os problemas de ontem poderão não ser apropriados aos problemas que hoje enfrentamos, nem tão pouco aqueles que surgirão no futuro.

O *Sistema de Controlo Adaptável* proporciona as ferramentas necessárias para lidar com a complexidade e com a mudança. Através dos testes contínuos aplicados pelas estratégias em presença, detecta-se que a estratégia actual (“*Campeã*”) pode já não produzir os melhores resultados, face às mudanças verificadas no universo dos clientes e no ambiente económico que moldura o momento actual. Nestas situações, o gestor de crédito poderá adaptar o sistema às novas condições e realidades económicas e sociais.

3.4.6.4 *Comentários finais sobre scoring comportamental*

O *scoring* comportamental diz respeito ao comportamento dos indivíduos e este comportamento é modelado pela mudança. Neste sentido, não é necessário saber se é o universo de clientes que mudou ou se foram as alterações verificadas na envolvente económica, os responsáveis pela mudança.

O que é importante é detectar a mudança e a necessária adaptação das suas implicações às novas realidades económicas, sociais, tecnológicas e ambientais. Uma vez que a mudança e a complexidade humana coabitam o mesmo espaço, um SCA é um processo contínuo e não um mero expediente ou um recurso temporário.

Nestes pressupostos, o maior desafio residirá em inventar novas estratégias que sejam capazes de distinguir as diferentes particularidades exibidas entre as contas incumpridoras.

3.5 ALGUNS COMENTÁRIOS

O *estado da arte* do *credit scoring* não se esgota com o desenvolvimento aqui resumido, mas revela-nos o potencial de aplicação desta metodologia.

As metodologias do *scoring de atribuição* e do *scoring comportamental* foram explanadas segundo processos e técnicas concorrentes. Esta metodologia pode ser replicada para qualquer actividade de concessão de crédito, seja esta uma instituição financeira ou não financeira.

A constatação empírica leva-nos a aceitar que a maioria das PME portuguesas não utiliza esta ferramenta pelas razões seguintes:

- 1) É desconhecida pela maioria das PME;
- 2) Nem todas as empresas que conhecem esta ferramenta dispõem de bases de dados devidamente organizadas e preparadas para acolher a implementação destas técnicas;
- 3) O pessoal especializado nesta área é escasso;
- 4) A feitura de um sistema de *scoring* construído para uma empresa particular é muito dispendiosa;
- 5) A maioria das associações empresariais ainda não dispõe de bases de dados tratadas referentes às respectivas actividades económicas que representam, e nem sempre recebem dos seus associados informação estatística adequada, em parte dada a relutância na divulgação desses dados, algumas vezes por manifesta falta de confiança na própria entidade que os representa;
- 6) A escassez de fabricantes de sistemas de *scoring*;
- 7) A comunidade empresarial não está suficientemente sensibilizada para os benefícios desta metodologia, genericamente denominada por *credit scoring*.

CAPÍTULO 4 – RESULTADOS

4.1 RECOLHA, ANÁLISE E TRANSFORMAÇÃO DE DADOS

4.1.1 RECOLHA DE DADOS

A recolha de dados foi efectuada numa instituição financeira emissora de cartões de crédito. Os dados recolhidos referem-se a clientes dessa instituição cuja classificação de *Bom* ou *Mau* cliente se conhece *a priori*.

O critério adoptado na recolha de dados seguiu o método proposto por diversos autores, nomeadamente Lewis, (1992, p.31), Mays, (2001, p.41), Siddiqi, (2006, p.70), Anderson, (2007, p. 260) e já explicado em 3.3.3 e 3.4.

O método referido consiste no registo do comportamento de pagamento dos devedores durante um período que varia entre seis e vinte e quatro meses, ao fim do qual se convencionou designar por *momento zero*.

Durante este período registou-se toda a informação que a conta ia fornecendo, sem, contudo, se tirar quaisquer conclusões.

A partir do *momento zero* é iniciado um novo período de mais seis meses. Este período destina-se a observar e a comparar o comportamento de pagamento com o período anterior, designando-se por *período de observação*.

Após esta observação e comparação, e segundo os indicadores definidos pela instituição de crédito, identificaram-se contas *Boas* e contas *Más*.

Entre as observações registadas durante o *período de observação* destacam-se, entre outros, os dias de atraso no pagamento, o saldo médio da conta, o saldo máximo e mínimo, o valor e o número total de transacções, o número de vezes que o limite de crédito foi excedido, o número de cartas enviadas a lembrar o pagamento.

Da base de dados dessa instituição financeira foi retirada a amostra aqui utilizada, contendo os dados já tratados pelos métodos descritos em 3.3.3 e 3.4, referentes a 2000 contas *Boas* e 2000 contas *Más*, à data de 30 de Junho 2007.

O critério da instituição financeira utilizado na classificação de *Bons* e *Maus* clientes foi o seguinte:

Bom Cliente

- Com pelo menos uma conta activa nos últimos 10 meses (2006-09 a 2007-06)
- Máximo de um atraso nos últimos 12 meses
- Máximo de uma devolução nos últimos 12 meses
- Classes de rfm de rendibilidade e revolving 4 e 5
- Saldo médio das contas nos últimos 3 meses $\geq 1.200\text{€}$
- Contas em análise sem incumprimento ≥ 60 dias nos últimos 24 meses
- Facturação $\geq 500\text{€}$ nos últimos 3 meses (2006-04 a 2007-06)

Mau Cliente

- Contas pelo menos uma vez em incumprimento ≥ 90 dias nos últimos 24 meses, com saldo actual $\geq 500\text{€}$
- Contas três ou mais vezes em incumprimento ≥ 60 dias nos últimos 12 meses, com saldo actual $\geq 500\text{€}$
- Contas que em 2007-06 estejam em carteira.

O critério, que se adoptou para a selecção de 4000 contas (2000 contas Boas e 2000 contas Más), foi o seguinte:

- 1- Para a selecção da nossa amostra seguiu-se a experiência relatada por Lewis (1992), (ver 3.3.3). A amostra tem aproximadamente a mesma dimensão e especificidade do relato de Lewis (ibidem).
- 2- Dividiu-se a amostra em duas:
 - a. uma que se denominou por *in-sample* contendo 80% dos dados de *Bons* e *Maus* na mesma proporção (1600 Bons e 1600 Maus) e que foram utilizados para estimar os parâmetros do modelo;
 - b. e outra amostra que se designou por *out-of-sample* ou *holdout sample* contendo os restantes 20% dos dados (400 contas *Boas* e 400 contas *Más*) que foram utilizados para validar fora da amostra o modelo estimado previamente.

Tendo em conta os critérios acima referidos, foi definida a seguinte metodologia:

- 1- Criou-se a variável COD que assume o valor 1 quando se trata de uma conta *Boa* e o valor 0 quando se trata de uma conta *Má*.
- 2- De seguida procedeu-se à caracterização da amostra *in-sample*. Para tal recorreu-se às medidas de estatística descritiva e estimou-se o modelo de regressão logística, com recurso aos programas SPSS[®] (*Statistical Package for the Social Sciences*) (versão 16) e EVIEWS[®] (versão 6.0).
- 3- Depois de validado estatisticamente o modelo procedeu-se à classificação dos clientes da *holdout sample* que confirmou a capacidade preditiva do modelo previamente estimado.

Deste modo encontrou-se um modelo que permite relacionar a probabilidade de um cliente ser *Bom* pagador com as suas características pessoais onde se incluem os dados da respectiva conta.

4.1.2 ANÁLISE DE DADOS

Ao analisarem-se as características referentes aos 4000 utentes de cartões de crédito, identificaram-se 21, que devem constituir (total ou parcialmente) as variáveis explicativas no modelo de regressão logística, conforme se ilustra na Tabela nº 4.1:

1	v_co_scoring - valor do scoring comportamental referente à conta actual do cliente
2	v_co_limite_credit - limite de crédito (montante máximo que o cliente pode gastar em utilizações com o seu cartão)
3	v_co_saldo_actual - valor actual da dívida
4	ci_co_estado - identifica o código do estado em que a conta se encontra
5	ci_co_class - identifica o código da classificação da conta (o ci_co_estado é uma combinação de várias classificações de conta)
6	v_co_revolving - montante em revolving ou seja valor que ficou por pagar no extracto anterior
7	m_rendibilidade - valor rendibilid mensal conta
8	c_tp_mes - identifica o mês a que respeitam os dados (formato = yyyymm)
9	d_co_class - descrição do código da classificação
10	d_co_estado - descrição do código do estado
11	delinq_60dias – conta delinvente há mais de 60 dias
12	delinq_90dias – conta delinvente há mais de 90 dias
13	género - (M/F)
14	cod_post - código postal
15	data_nasc - data de nascimento
16	estad_civil - estado civil
17	habilit - habilitações literárias
18	região - região geográfica
19	profissão
20	idade
21	rendimento

Tabela nº 4.1- Lista de características dos utentes de cartões de crédito relativos à amostra utilizada no estudo.

Estas 21 características foram agrupados em três categorias (Qualitativas, Quantitativas e Datas) e que se resumem na Tabela nº4.2:

Variáveis Qualitativas	Variáveis Quantitativas	Variáveis “Data”
ci_co_estado - identifica o código do estado em que a conta se encontra	v_co_scoring - valor do scoring comportamental referente à conta actual do cliente	data_nasc - data de nascimento
d_co_estado - descrição do código do estado	v_co_limite_credit - limite de crédito (montante máximo que o cliente pode gastar em utilizações com o seu cartão)	c_tp_mes - identifica o mês a que respeitam os dados (formato = yyyyymm)
d_co_class - descrição do código da classificação	v_co_saldo_actual - valor actual da dívida	
ci_co_class - identifica o código da classificação da conta (o ci_co_estado é uma combinação de várias classificações de conta)	v_co_revolving - montante em revolving ou seja valor que ficou por pagar no extracto anterior	
delinq_60dias – conta delinvente há mais de 60 dias	m_rendibilidade - valor rendibilid mensal conta	
delinq_90dias – conta delinvente há mais de 90 dias	idade	
género- (M/F)	rendimento – remuneração mensal líquida	
cod_post - código postal		
estad_civil - estado civil		
habilit - habilitações literárias		
região - região geográfica		
profissão		

Tabela nº 4.2- Tipologias de variáveis explicativas

Uma vez que o significado das variáveis pode não ser claro, devido às abreviaturas e simplificações, optou-se por descrevê-las de forma mais detalhada como se apresenta a seguir:

a) Estado da conta “d_co_estado” e “ci_co_estado”

A descrição do estado da conta (*d_co_estado*) e o respectivo código de identificação (*ci_co_estado*) estão apresentados na tabela 4.3:

ci_co_estado * d_co_estado Crosstabulation

Count	d_co_estado			
	Contas Activas	Contas Não Activas	Contas Não Utilizáveis	Total
ci_co_estado 1	2602	0	0	2602
2	0	281	0	281
3	0	0	317	317
Total	2602	281	317	3200

Tabela nº 4.3- Tabela cruzada *ci_co_estado* (código de identificação do estado da conta) e *d_co_estado* (descrição do estado da conta)

Do cruzamento destas variáveis verificámos que a *descrição da conta* apresenta três estados diferentes: *Contas Activas*, *Contas Não-Activas* e *Contas Não-Utilizáveis*.

Cada uma destas contas apresenta um *código de identificação* da respectiva conta e que corresponde a:

Descrição (<i>d_co_estado</i>)	Código de Identificação (<i>ci_co_estado</i>)	Obs
Contas Activas	1	2602
Contas Não-Activas	2	281
Contas Não-utilizáveis	3	317
		3200

Tabela nº 4.4- Descrição das contas por Códigos de Identificação

b) Classe da conta “*d_co_class*” e “*ci_co_class*”

A descrição da classe da conta (*d_co_class*) e o respectivo código de identificação (*ci_co_class*) estão apresentados na tabela 4.5:

ci_co_class * d_co_class Crosstabulation

Count	ci_co_class	d_co_class											Total		
		A-Nao cumpriu minimo- Saldo<L. U.	C-2 Meses- Saldo<L. U.	D-3 Meses- Saldo<L. U.	E->=4 Meses- Saldo<L. U.	H- Saldo> L.U.	I-1 Mes- Saldo>L.U.	J-2 Meses- Saldo>L. U.	K-3 Meses- Saldo>L. U.	L->=4 Meses- Saldo>L. U.	P-1 Mes- Saldo<L. U.	Sem Classifica cao			
	0	34	0	0	0	0	0	0	0	0	0	0	0	0	34
	1	0	114	0	0	0	0	0	0	0	0	0	0	0	114
	2	0	0	55	0	0	0	0	0	0	0	0	0	0	55
	3	0	0	0	22	0	0	0	0	0	0	0	0	0	22
	6	0	0	0	0	16	0	0	0	0	0	0	0	0	16
	7	0	0	0	0	0	30	0	0	0	0	0	0	0	30
	8	0	0	0	0	0	0	0	27	0	0	0	0	0	27
	9	0	0	0	0	0	0	0	0	30	0	0	0	0	30
	13	0	0	0	0	0	0	0	0	0	256	0	0	0	256
	19	0	0	0	0	0	0	0	0	0	0	2577	0	0	2577
	20	0	0	0	0	0	0	39	0	0	0	0	0	0	39
	Total	34	114	55	22	16	30	39	27	30	256	2577	0	0	3200

Tabela nº 4.5- Tabela cruzada *d_co_class* e *ci_co_class*

De modo idêntico, verificou-se que a descrição da classe da conta (*d_co_class*) é também classificada por um código numérico (*ci_co_class*).

c) Contas vencidas há mais de 60 dias e 90 dias “*delinq_60 dias*” e “*delinq_90 dias*”

delinq_90dias * delinq_60dias Crosstabulation

Count		delinq_60dias		
		0	1	Total
delinq_90dias	0	2913	153	3066
	1	0	134	134
Total		2913	287	3200

Tabela nº 4.6- Tabela cruzada *delinq_60 dias* e *delinq_90 dias*

Da tabela anterior verificou-se que 2913 contas são consideradas não incumpridoras e do total das 3200 contas apenas 153 atingiram o estado de incumprimento de 60 dias e 134 tinham atingido os 90 dias de incumprimento.

As contas vencidas (incumpridoras) são classificadas por 1 e as contas não vencidas por 0.

d) *Género*

Género

	Frequency	Percent	Valid Percent	Cumulative Percent
Valid F	951	29,7	29,7	29,7
M	2249	70,3	70,3	100,0
Total	3200	100,0	100,0	

Tabela nº 4.7- Tabela de frequência por *Género*

Da Tabela nº 4.7 ressalta a grande diferença entre o número de utentes do género masculino (70,3%) e do género feminino (29,7%). Questionada a instituição financeira sobre as razões desta diferença, soubemos que se trata de uma “pseudo-anomalia”, porquanto a todos os utentes do género masculino que fossem casados é automaticamente emitido um outro cartão para a esposa, embora em ambos os cartões seja dada a mesma identificação de conta.

Na tabela 4.8, e como já referido, o código 0 (COD=0) representa *Mau* pagador e o código 1 (COD=1) representa *Bom* pagador.

Género * COD Crosstabulation

Count		COD		
		0	1	Total
Género	F	553	398	951
	M	1047	1202	2249
Total		1600	1600	3200

Tabela 4.8 Quantidade de *Bons* e *Maus* pagadores por Género

Da Tabela nº 4.8 pode-se extrair que das 951 mulheres, 58% são classificadas como contas *Más*, enquanto que essa percentagem é de 47% nos 2249 homens.

e) Estado civil (*estad_civil*)

Transcrevem-se na tabela 4.9 os atributos do estado civil e a classificação de *Bom* e *Mau* pagador por género.

Género	Estado Civil														
	Viúvo(a)		Casado(a)		Divorciado(a)		Separado(a)		Solteiro(a)		Sem Resposta		Total		
F COD	0	23	4,2%	208	37,6%	66	11,9%	3	0,5%	87	15,7%	166	30,0%	553	100,0%
	1	25	6,3%	219	55,0%	68	17,1%	2	0,5%	52	13,1%	32	8,0%	398	100,0%
	Total	48	5,0%	427	44,9%	134	14,1%	5	0,5%	139	14,6%	198	20,8%	951	100,0%
M COD	0	7	0,7%	514	49,1%	61	5,8%	5	0,5%	108	10,3%	352	33,6%	1047	100,0%
	1	20	1,7%	918	76,4%	93	7,7%	6	0,5%	59	4,9%	106	8,8%	1202	100,0%
	Total	27	1,2%	1432	63,7%	154	6,8%	11	0,5%	167	7,4%	458	20,4%	2249	100,0%
		75	2,34%	1859	58,1%	288	9,0%	16	0,5%	306	9,6%	656	20,5%	3200	100,0%

Tabela nº 4.9- Estado Civil por Frequência e Género por Código (1)

Quando se analisou na alínea anterior o “Género” segundo a classificação *Boas* e *Más* contas, verificou-se que 58% das mulheres são *Más* pagadoras contra 47% dos homens.

Contudo, na tabela 4.9 constatou-se uma inversão desta tendência nas mulheres casadas que são 37,6% de *Más* contas contra 49,1% de homens casados.

Em todos os outros estados-civis as mulheres apresentam maior percentagem de más pagadoras do que os homens à excepção das “Sem resposta”. As mulheres divorciadas e solteiras apresentam percentagem de más contas superiores à dos homens (11,9% e 15,7% contra 5,8% e 10,3% respectivamente).

As mulheres que não responderam apresentam 30% de Más contas contra 33,6% de homens. Entre os viúvos as mulheres também apresentam uma percentagem superior de Más contas relativamente aos homens.

Ao analisarmos melhor estes resultados no sentido de perceber qual o fenómeno associado à mulher casada que a leva a ser melhor pagadora que o homem casado, verificámos empiricamente uma possível razão para esta inversão. Aquando da abertura de conta de um homem casado, a instituição financeira emite um outro cartão com o mesmo número de conta para a esposa.

Quando esta utiliza o cartão e não cumpre com os pagamentos nas datas devidas, o incumprimento é registado na conta do marido. Assim os homens casados, mesmo que não

usem o cartão de crédito, agravam estatisticamente a sua “credibilidade” (capacidade de crédito).

Gênero	Estado Civil														
	Viúvo(a)		Casado(a)		Divorciado(a)		Separado(a)		Solteiro(a)		Sem Resposta		Total		
F COD	0	23	47,9%	208	48,7%	66	49,3%	3	60,0%	87	62,6%	166	83,8%	553	58,1%
	1	25	52,1%	219	51,3%	68	50,7%	2	40,0%	52	37,4%	32	16,2%	398	41,9%
	Total	48	100,0%	427	100,0%	134	100,0%	5	100,0%	139	100,0%	198	100,0%	951	100,0%
M COD	0	7	25,9%	514	35,9%	61	39,6%	5	45,5%	108	64,7%	352	76,9%	1047	46,6%
	1	20	74,1%	918	64,1%	93	60,4%	6	54,5%	59	35,3%	106	23,1%	1202	53,4%
	Total	27	100,0%	1432	100,0%	154	100,0%	11	100,0%	167	100,0%	458	100,0%	2249	100,0%

Tabela nº 4.10- Estado Civil por Frequência e Gênero por Código (2)




Gráfico nº 4.1- Estado Civil por Frequência e Gênero por Código

f) Valor do *scoring* comportamental referente à conta actual do cliente (*v_co_scoring*)

A tabela 4.30 agrupa o número de contas por *Bons* e *Maus* pagadores por intervalos de score:

Score	Bons	Maus
4-300	1	1
301-305	0	1
306-310	0	2
311-315	0	6
316-320	0	3
321-325	0	9
326-330	0	13
331-335	0	11
336-340	0	24
341-345	0	12
346-350	0	5
351-355	0	5
356-362	0	3
363-599	0	35
600-605	0	1
606-610	0	33
611-615	0	17
616-620	0	36
621-625	0	53
626-630	0	101
631-635	0	31
636-640	0	54
641-645	0	32
646-650	0	76
651-655	0	69
656-660	0	76
661-665	0	94
666-670	0	94
671-675	3	87
676-680	5	95
681-685	8	100
686-690	9	130
691-695	21	130
696-700	82	115
701-705	20	68
706-710	93	79
711-715	62	81
716-720	401	64
721-725	47	34
726-730	708	63
731-735	128	17
736-740	218	23
741-745	113	12
746-750	56	3
751-755	3	0
756-760	22	2
765-770	0	0
	2000	2000

Tabela nº 4.11- Frequências de *Bons* e *Maus* por intervalos de *score*

g) Limite de crédito é o montante máximo que o cliente pode utilizar com o seu cartão (*v_co_limite_credit*).

Para se analisar a relação entre a variável *scoring* e a variável *limite de crédito* construiu-se o seguinte diagrama de dispersão:




Gráfico nº 4.2- Distribuição de *Bons* e *Más* contas por *Limite de Crédito* e *Scoring*

O Gráfico nº 4.2 oferece-nos as seguintes explicações e comentários:

g1) A dispersão de clientes *Bons* e *Maus* faz-se em escalões de *limites de crédito* que vão desde 0 euros a 50 000 €.

g2) O intervalo do *scoring* entre os escalões mais elevados (700 a 770 pontos) regista *bons* e *maus* clientes, o que está de acordo com o que atrás foi mostrado na tabela 4.11.

g3) Verifica-se no intervalo entre 200 e 400 da ordenada *v_co_scoring* um conjunto de *Maus* pagadores. De acordo com informação da instituição financeira, este conjunto de contas diz respeito a situações de pré-contencioso, contencioso ou outras situações especiais.

h) Saldo actual da conta (*v_co_saldo_actual*) é o valor em débito à data da observação

i) Montante da conta que ficou por pagar no extracto anterior (*v_co_revolving*)

j) Montante da rendibilidade da conta (*m_rendibilidade*)

k) Idade

Os clientes da amostra têm uma idade média de 55 anos

Descriptive Statistics

	N	Minimum	Maximum	Mean	Std. Deviation
Idade	3200	24	93	54,64	10,066
Valid N (listwise)	3200				

Tabela nº 4.12- Estatísticas descritivas da característica “idade”




Gráfico nº 4.3- Frequências das idades dos utentes da amostra

l) Habilitações literárias (*habilit_d*)

		Habilitações			
		Frequency	Percent	Valid Percent	Cumulative Percent
Valid	12º Ano	21	,7	,7	,7
	Curso Médio	9	,3	,3	,9
	Curso Superior/Licenciatura/Mestrado	329	10,3	10,3	11,2
	Escolaridade obrigatória	12	,4	,4	11,6
	Menos que a escolaridade obrigatória	4	,1	,1	11,7
	Outros	1727	54,0	54,0	65,7
	Sem Resposta	1098	34,3	34,3	100,0
	Total	3200	100,0	100,0	

Tabela nº 4.13- Frequências das diferentes tipologias de habilitações literárias

m) Rendimento – remuneração mensal líquida (*rendimento*)

Esta característica não foi considerada no modelo por apresentar o valor do rendimento, na grande maioria dos casos, igual a zero.

Outras variáveis, tais como código postal, região geográfica, profissão, data de nascimento e data do mês a que respeitam os dados, não mereceram explicações adicionais por serem óbvias.

O procedimento seguinte consistiu em transformar algumas das variáveis qualitativas em *dummies* tendo-se optado por fazer essa transformação manualmente, em vez de as identificarmos como variáveis *categóricas* e assim permitirmos que o programa estatístico SPSS® fizesse escolhas que poderiam contrariar o *Bom* senso imposto pela realidade. Este assunto será desenvolvido em 4.1.3 Transformação de Dados.

4.1.3 TRANSFORMAÇÃO DE DADOS

Para tornar mais fácil a interpretação das estimativas para os coeficientes de algumas das variáveis qualitativas, procedeu-se à sua transformação em variáveis numéricas fictícias

(variáveis *dummy*). A transformação das variáveis é feita segundo uma dicotomização dos atributos, conforme Tabela nº 4.14:

Categorical Variables Codings			
		Frequency	Parameter coding
HabilitDummy	0	2825	,000
	1	375	1,000
ci_co_class(Dummy)	0	2577	,000
	1	623	1,000
d_co_class(Dummy)	0	3058	,000
	1	142	1,000
d_co_estado(Dummy)	0	2602	,000
	1	598	1,000
Gênero(Dummy)	0	2249	,000
	1	951	1,000
Região(Dummy)	0	2310	,000
	1	890	1,000
Estado Civil(Dummy)	0	1859	,000
	1	1341	1,000
ci_co_estado(Dummy)	0	2602	,000
	1	598	1,000

Tabela nº 4.14- Frequências das variáveis categóricas por Códigos

O critério seguido para a atribuição dos códigos 0 e 1 foi considerar como zero os atributos que contivessem o maior número de observações (Anderson, 2007, p.359), conforme se ilustra na Tabela nº 4.15:

Características	Atributos	Frequência	Categ. Referência	Categ. Resposta
			Grupo de Controlo	Grupo de Tratamento
			0	1
Região	Alentejo	135		1
	Algarve	158		1
	Beira Interior	30		1
	Centro	168		1
	Ilhas	136		1
	Lisboa	1063	0	
	Lisboa Cidade	749	0	
	Litoral	211		1
	Norte	52		1
	Porto	342	0	
	Porto Cidade	156	0	
ci_co_class	0	34		1
	1	114		1
	2	55		1
	3	22		1
	6	16		1
	7	30		1
	8	27		1
	9	30		1
	13	256		1
	19	2577	0	
	20	39		1
d_co_class	A-Nao cu	34		1
	C-2 Mese	114		1
	D-3 Mese	55		1
	E->=4 Me	22		1
	H-Saldo>	16		1
	I-1 Mes-	30		1
	J-2 Mese	39		1
	K-3 Mese	27		1
	L->=4 Me	30		1
	P-1 Mes-	256		1
	Sem Clas	2577	0	
Habilitações	12º Ano	21		1
	Curso Mé	9		1
	Curso Su	329		1
	Escolari	12		1
	Menos qu	4		1
	Outros	1727	0	
	Sem Resp	1098		1
Estado Civil	Casado	1859	0	
	Divorcia	288		1
	Sem Resp	656		1
	Separado	16		1
	Solteiro	306		1
	Viúvo	75		1
ci_co_estado	1	2602	0	
	2	281		1
	3	317		1
Género	F	951		1
	M	2249	0	
d_co_estado	Contas Activas	2602	0	
	Contas N	598		1

Tabela nº 4.15- Frequência dos atributos por categorias de Referência e de Resposta

A forma como as categorias são codificadas vai determinar o sentido dos *odds ratios* como também o sinal das estimativas para os coeficientes (Tabachnick, B. G., e Fidell, L. S. (2007, p.464). Os programas SPSS[®] e EVIEWS[®] dão a equação estimada para a probabilidade da variável dependente ser igual a “1”, enquanto que o programa SAS[®] resolve a equação para a categoria codificada por “0”. Por outras palavras, um o *odds ratio* de 4 no SPSS[®] representa, por exemplo, um rácio de 80% de *Bons* pagadores e 20% de *Maus* pagadores); mas se o programa utilizado for o SAS[®] (*SAS Institute Inc*) o *odds ratio* será de 0,25 (rácio entre 20% de *Maus* pagadores e 80% de *Bons* pagadores).

Para uma melhor interpretação, costuma-se usar a dicotomia “*doença*” como a *categoria resposta* codificada por “1” e a “*saúde*” como *categoria de referência* codificada por “0”. Na tabela anterior damos o exemplo da variável “*d_co_estado*” cujos atributos são “*Contas Activas*” (*saudáveis*) codificadas como *categoria de referência* (0) e as “*Contas Não Activas*” e “*Contas Não Utilizadas*” (*doentes*) codificadas como *categoria resposta* (1).

4.1.4 CARACTERIZAÇÃO DAS VARIÁVEIS POR MEDIDAS DE ESTATÍSTICA DESCRITIVA

Para uma melhor caracterização das variáveis, em termos estatística descritiva, apresentam-se as tabelas n^os 4.16 e 4.17:

Univariate Statistics

	N	Mean	Std. Deviation	Missing		No. of Extremes ^a	
				Count	Percent	Low	High
v_co_scoring	3200	686,33	82,832	0	,0	137	0
v_co_limite_credit	3200	8678,06	6957,993	0	,0	0	110
v_co_saldo_actual	3200	4283,3460	4303,24032	0	,0	0	186
v_co_revolving	3200	3618,3288	3809,90513	0	,0	0	176
m_rendibilidade	3200	66,4332	77,21507	0	,0	0	156
ci_co_estadoDummy	3200	,19	,390	0	,0	0	598
ci_co_classDummy	3200	,19	,396	0	,0	0	623
d_co_classDummy	3200	,19	,396	0	,0	0	623
d_co_estadoDummy	3200	,19	,390	0	,0	0	598
delinq_60dias	3200	,09	,286	0	,0	0	287
delinq_90dias	3200	,04	,200	0	,0	0	134
GéneroDummy	3200	,30	,457	0	,0	0	0
EstadoCivilDummy	3200	,42	,493	0	,0	0	0
RegiãoDummy	3200	,28	,448	0	,0	0	0
Rendimento	3200	185,90	925,187	0	,0	0	103
Habilit.Dummy	3200	,46	,499	0	,0	0	0
Idade	3200	54,98	10,173	0	,0	22	97
ci_co_estado	3200	1,29	,634	0	,0	0	317
ci_co_class	3200	16,92	4,984	0	,0	241	0
c_tp_mes	3200	200706,00	,000	0	,0	.	.

a. Number of cases outside the range (Mean - 2*SD, Mean + 2*SD).

Tabela nº 4.16- Medidas de estatística univariada

Descriptives

		N	Mean	Std. Deviation	Std. Error	95% Confidence Interval for Mean		Minimum	Maximum
						Lower Bound	Upper Bound		
v_co_scoring	0	1600	643,17	107,297	2,682	637,91	648,43	4	756
	1	1600	725,23	22,656	,566	724,12	726,34	4	762
	Total	3200	684,20	87,722	1,551	681,16	687,24	4	762
v_co_limite_credit	0	1600	4779,66	3906,821	97,671	4588,09	4971,24	500	25000
	1	1600	14549,75	6241,813	156,045	14243,67	14855,82	452	50000
	Total	3200	9664,71	7139,633	126,212	9417,24	9912,17	452	50000
v_co_saldo_actual	0	1600	2909,563125	3,2349773E3	80,8744331	2750,932075	3068,194175	-292,0000	27742,0000
	1	1600	6475,208125	5,0623481E3	126,5587015	6226,969726	6723,446524	-2815,0000	30464,0000
	Total	3200	4692,385625	4,6065205E3	81,4325478	4532,720354	4852,050896	-2815,0000	30464,0000
v_co_revolving	0	1600	2597,038125	2,9586205E3	73,9655136	2451,958566	2742,117684	,0000	25926,0000
	1	1600	5350,391875	4,5895978E3	114,7399456	5125,335360	5575,448390	,0000	27796,0000
	Total	3200	3973,715000	4,0987917E3	72,4570843	3831,647973	4115,782027	,0000	27796,0000
m_rendibilidade	0	1600	48,3644	65,14222	1,62856	45,1700	51,5587	-14,00	1585,00
	1	1600	96,7456	86,68579	2,16714	92,4949	100,9964	-67,00	497,00
	Total	3200	72,5550	80,38967	1,42110	69,7686	75,3414	-67,00	1585,00
Idade	0	1600	51,666875	9,2238320	,2305958	51,214573	52,119177	30,0000	87,0000
	1	1600	58,963750	9,1679451	,2291986	58,514189	59,413311	35,0000	89,0000
	Total	3200	55,315312	9,8921166	,1748696	54,972445	55,658180	30,0000	89,0000
GéneroDummy	0	1600	,30	,460	,012	,28	,33	0	1
	1	1600	,21	,407	,010	,19	,23	0	1
	Total	3200	,26	,437	,008	,24	,27	0	1
EstadoCivilDummy	0	1600	,48	,500	,012	,46	,51	0	1
	1	1600	,26	,437	,011	,24	,28	0	1
	Total	3200	,37	,483	,009	,35	,39	0	1
HabilitDummy	0	1600	,12	,326	,008	,10	,14	0	1
	1	1600	,15	,353	,009	,13	,16	0	1
	Total	3200	,13	,340	,006	,12	,14	0	1
ci_co_classDummy	0	1600	,42	,493	,012	,39	,44	0	1
	1	1600	,01	,111	,003	,01	,02	0	1
	Total	3200	,21	,411	,007	,20	,23	0	1

Tabela nº 4.17- Medidas de estatística descritiva das variáveis independentes

Da Tabela nº 4.16 verifica-se que o modelo logístico não será afectado negativamente por *missings* e da Tabela nº 4.17 uma observação aos valores mínimos e máximos permite garantir que o modelo logístico, também não será afectado negativamente por *outliers*.

4.2–APLICAÇÃO DO MODELO LOGIT AOS DADOS AMOSTRAIS

Para analisar a relação entre a probabilidade de um cliente ser *Bom* pagador e as suas características pessoais, incluindo os dados da conta, recorreremos ao modelo *logit*, cujos parâmetros foram estimados a partir do EVIEWS[®].

Como variável dependente, considerou-se a variável COD que assume os valores 0 e 1, para clientes *Maus* e *Bons* pagadores, respectivamente.

Como variáveis independentes foram inicialmente consideradas, catorze variáveis conforme consta da Tabela 4.18:

v_co_scoring
v_co_limite_credit
v_co-saldo_actual
v_co_revolving
delinq_60dias
delinq_90dias
m_rendibilidade
idade
ci_co_estado (Dummy)
ci_co_class (Dummy)
género (Dummy)
estado_civil (Dummy)
região (Dummy)
habilit. (Dummy)

Tabela nº 4.18- Catorze variáveis independentes inicialmente consideradas no modelo

Os resultados obtidos directamente a partir do EVIEWS[®] são apresentados nas tabelas da subsecção seguinte.

4.2.1 APLICAÇÃO DO MODELO AOS DADOS IN-SAMPLE

Como ponto de partida foram incluídas no modelo todas as variáveis explicativas inicialmente consideradas. Numa segunda etapa, e seguindo o princípio da parcimônia, foram excluídas as variáveis cujos coeficientes estimados não se revelaram estatisticamente significativos para um nível de significância de 10%. As variáveis excluídas foram:

ci_co_estado (Dummy)

delinq_60dias

delinq_90dias

região(Dummy)

Apresentam-se na Tabela 4.19 os resultados da estimação:

Dependent Variable: COD
Method: ML - Binary Logit (Quadratic hill climbing)
Sample: 1 3200
Included observations: 3200
Convergence achieved after 23 iterations
Covariance matrix computed using second derivatives

Variable	Coefficient	Std. Error	z-Statistic	Prob.
V_CO_SCORING	0.066500	0.003795	17.52427	0.0000
V_CO_LIMITE_CREDIT	0.000261	2.05E-05	12.74539	0.0000
V_CO_SALDO_ACTUAL	0.000499	0.000110	4.526730	0.0000
M_RENDIBILIDADE	-0.008396	0.002934	-2.861424	0.0042
IDADE	0.018678	0.007091	2.634029	0.0084
HABILIT_D	-0.602927	0.132102	-4.564096	0.0000
CI_CO_CLASS_D	-1.434070	0.349123	-4.107634	0.0000
V_CO_REVOLVING	-0.000384	0.000120	-3.201036	0.0014
ESTADO_CIVIL_D	-0.578892	0.134513	-4.303619	0.0000
GENERO_D	0.808648	0.144411	5.599634	0.0000
C	-49.89290	2.752544	-18.12610	0.0000
McFadden R-squared	0.653876	Mean dependent var	0.500000	
S.D. dependent var	0.500078	S.E. of regression	0.260019	
Akaike info criterion	0.486704	Sum squared resid	215.6077	
Schwarz criterion	0.507573	Log likelihood	-767.7269	
Hannan-Quinn criter.	0.494186	Restr. log likelihood	-2218.071	
LR statistic	2900.688	Avg. log likelihood	-0.239915	
Prob(LR statistic)	0.000000			
Obs with Dep=0	1600	Total obs	3200	
Obs with Dep=1	1600			

Tabela nº 4.19- Variáveis explicativas que permaneceram no modelo, depois de excluídas as variáveis cujos coeficientes estimados não se revelaram estatisticamente significativos.

4.2.2 AVALIAÇÃO DA QUALIDADE DO AJUSTAMENTO

Para concluir sobre a bondade do ajustamento na amostra *in-sample* começou-se por analisar alguns dos resultados anteriores.

O modelo é globalmente válido pois rejeita-se a hipótese nula no teste da razão de verosimilhanças (*LR statistics*) que compara o valor máximo do logaritmo da função de verosimilhança de dois modelos, com e sem as variáveis explicativas: *Log likelihood* e *Restr. Log likelihood*, respectivamente.

Uma vez que a probabilidade associada ao teste LR (0.0000) é claramente inferior aos níveis de significância convencionalmente utilizados, existe pelo menos um coeficiente estimado que é estatisticamente significativo; o mesmo é dizer que existe pelo menos uma variável explicativa cuja variação está estatisticamente relacionada com a probabilidade de um cliente ser *Bom* pagador.

Portanto, o modelo com todas as variáveis explicativas evidencia melhores previsões do que aquelas resultantes do modelo só com a constante.

Os coeficientes estimados são todos estatisticamente significativos, atendendo ao valor e à probabilidade associada aos testes Z. Quer isto dizer que todas as variáveis explicativas são estatisticamente relevantes para descrever a probabilidade da variável COD ser igual a 1 (o cliente *Bom* pagador).

A tabela 4.19 dá-nos também informação sobre a contribuição ou importância de cada uma das variáveis explicativas.

As estimativas para os coeficientes β (2ª coluna) são os valores que foram utilizados na função de distribuição logística para estimar a probabilidade de um cliente ser *Bom* pagador.

Verifica-se, ainda, que existem estimativas positivas e negativas que indicam o sentido da relação entre as variáveis explicativas e a variável dependente, ou seja, de que forma a variação numa das variáveis explicativas se repercute, em termos médios, na probabilidade do cliente ser *Bom* pagador.

Assim, os valores negativos indicam que, em média, um aumento na variável explicativa resultará na diminuição da probabilidade de ser *Bom* pagador. São os casos das variáveis: *m_rendibilidade*, *habilit_dummy*, *ci_co_class_dummy*, *v_co_revolving* e *estado_civil_dummy*.

Os valores positivos indicam que em média um aumento na variável explicativa resultará no aumento da probabilidade do cliente ser *Bom* pagador. Estão neste caso as variáveis, *v_co_scoring*, *v_co_limite_credit*, *v_co_saldo_actual*, *idade* e *genero_dummy*.

Quando se refere ao impacte das variáveis explicativas sobre a probabilidade da variável dependente ser igual a 1, costuma calcular-se a exponencial da estimativa para cada um dos coeficientes. Os valores resultantes são estimativas dos rácios de probabilidades ou *odds ratios* para cada uma das variáveis independentes. Os *odd ratios* representam a variação esperada (aumento ou diminuição se o rácio for menor que 1) na variável dependente, quando o valor da variável independente varia uma unidade.

O valor Pseudo-R² de McFadden é 0,65, o que significa que existe um incremento significativo no valor máximo do logaritmo da função de verosimilhança quando todas as variáveis explicativas são consideradas em relação ao modelo que inclui apenas a *constante*.

Para além do modelo *logit* foram ainda estimados os modelos *probit* e *gompit* (baseados nas distribuições normal estandardizada e de valores extremos *tipo I*, respectivamente). Para concluir qual dos modelos é o mais adequado para descrever o processo gerador dos dados, recorreu-se ao teste de Vuong (1989) pois permite comparar modelos *nonnested*⁹ na forma funcional como são os casos dos modelos *logit*, *probit* e *gompit*.

Foram realizados três testes considerando em hipótese nula cada um dos modelos anteriores (*logit*, *probit* e *gompit*) e em hipótese alternativa tomou-se cada um dos dois outros modelos. Assim,

Teste 1: H₀: Modelo *logit*, H₁: Modelo *probit*;

Teste 2: H₀: Modelo *logit*, H₁: Modelo *gompit*;

Teste 3: H₀: Modelo *probit*, H₁: Modelo *gompit*.

Os resultados obtidos foram os seguintes:

	Teste 1	Teste 2	Teste 3
Vuong	2,73	-0,72	-1,76

Tabela nº 4.20- Resultados do Teste de Vuong

⁹ Dois modelos dizem-se *nonnested* quando não é possível apresentar um modelo como caso particular do outro, impondo restrições a certos parâmetros do modelo mais geral. Os modelos podem também ser *nonnested* no que diz respeito à relação funcional e às estruturas do erro.

Uma vez que o valor do teste 1 cai na parte positiva da região crítica (para um nível de significância de 0.05 o valor crítico da normal estandardizada num teste bilateral é aproximadamente 2, conclui-se que o modelo *logit* é mais apropriado do que o modelo *probit* para descrever o processo gerador dos dados que constituem a nossa amostra. Pelo resultado dos testes 2 e 3, e uma vez que não se rejeita a hipótese nula, as diferenças no valor máximo do logaritmo da função de verosimilhança não são estatisticamente significativas entre os modelos *logit* e *gompit*, por um lado, e entre os modelos *probit* e *gompit* por outro.

Portanto, face aos resultados do teste de Vuong, e tendo em conta a superioridade do modelo *logit* sobre o modelo *probit*, decidiu-se prosseguir com a análise aos resultados da regressão logística. Para concluir sobre a bondade de ajustamento pode-se ainda construir um quadro-resumo onde se procede à classificação dos clientes.

Se a probabilidade estimada resultante do modelo for inferior a 0.5 (valor considerado por defeito) o cliente é classificado como Mau pagador. Caso contrário, considera-se que $Y=1$, isto é, que o cliente é *Bom* pagador. Os resultados obtidos são apresentados na Tabela 4.21:

Expectation-Prediction Evaluation for Binary Specification
Success cutoff: C = 0.5

	Estimated Equation			Constant Probability		
	Dep=0	Dep=1	Total	Dep=0	Dep=1	Total
P(Dep=1)≤C	1433	126	1559	1600	1600	3200
P(Dep=1)>C	167	1474	1641	0	0	0
Total	1600	1600	3200	1600	1600	3200
Correct	1433	1474	2907	1600	0	1600
% Correct	89.56	92.13	90.84	100.00	0.00	50.00
% Incorrect	10.44	7.87	9.16	0.00	100.00	50.00
Total Gain*	-10.44	92.13	40.84			
Percent Gai...	NA	92.13	81.69			

	Estimated Equation			Constant Probability		
	Dep=0	Dep=1	Total	Dep=0	Dep=1	Total
E(# of Dep=0)	1374.32	226.03	1600.36	800.00	800.00	1600.00
E(# of Dep=1)	225.68	1373.97	1599.64	800.00	800.00	1600.00
Total	1600.00	1600.00	3200.00	1600.00	1600.00	3200.00
Correct	1374.32	1373.97	2748.29	800.00	800.00	1600.00
% Correct	85.90	85.87	85.88	50.00	50.00	50.00
% Incorrect	14.10	14.13	14.12	50.00	50.00	50.00
Total Gain*	35.90	35.87	35.88			
Percent Gai...	71.79	71.75	71.77			

*Change in "% Correct" from default (constant probability) specification
**Percent of incorrect (default) prediction corrected by equation

Tabela nº 4.21- Resultados do modelo de regressão logística, mostrando-se a taxa de acerto geral de 90, 84%

A informação dada na Tabela 4.20 pode ser resumida nas tabelas 4.22 e 4.23

Classification Table^a

		Predicted		
		COD		
		0	1	Percentage Correct
Observed	COD 0	1433	126	89,56
	COD 1	167	1474	92,13
Overall Percentage				90,84

a. The cut value is ,500

Tabela 4.22 Tabela de classificação final

Taxa de acerto:	_____	_____
Taxa de erro:	_____	_____
Sensibilidade:	_____	_____
Especificidade:	_____	_____

Tabela nº 4.23- Medidas de Classificação: Taxa de acerto; Taxa de Erro; Sensibilidade; Especificidade. Cálculos.

		Classificação Prevista pelo Scorecard	
		Mau Pagador (0)	Bom Pagador (1)
Classificação Actual	Mau Pagador(0)	<p>Negativo verdadeiro 1433</p>	<p>Positivo falso 126 (Erro Tipo II)</p>
	Bom Pagador(1)	<p>Negativo falso 167 (Erro Tipo I)</p>	<p>Positivo verdadeiro 1474</p>

Tabela nº 4.24- Matriz de Classificação e respectivos gráficos

Os valores constantes da *Classification Table* (Tabela nº 4.22) deram a indicação de como o modelo é capaz de prever a categoria correcta (*Bom/Mau*) para cada caso. Pode-se ainda constatar a melhoria de previsão quando as variáveis explicativas são introduzidas no modelo.

O modelo classificou correctamente 90,84% de todos os casos, enquanto que no modelo só com a constante a taxa de acerto foi apenas 50%.

Os resultados apresentados nesta tabela podem também ser utilizados para calcular a sensibilidade (*sensitivity*) do modelo que é a percentagem de clientes *Bons* que foram identificados pelo modelo (os *positivos verdadeiros*), isto é, 92,13% .

A especificidade (*specificity*) do modelo, ou seja a percentagem de clientes *Maus* correctamente classificados (*negativos verdadeiros*) foi de 89,56 %.

4.2.3 EFEITOS MARGINAIS DAS VARIÁVEIS EXPLICATIVAS SOBRE A PROBABILIDADE DE UM CLIENTE SER *BOM* PAGADOR

A interpretação directa dos coeficientes é por vezes complicada, uma vez que num modelo com variável dependente binária as estimativas para os coeficientes não podem ser interpretadas directamente como o efeito marginal de cada uma das variáveis explicativas sobre a variável dependente (excepção para o *Modelo Probabilístico Linear*).

O efeito marginal da variável explicativa X_j em relação à probabilidade de $Y=1$ é o produto da função densidade de probabilidade logística pela estimativa do coeficiente que lhe está associado. Um procedimento sugerido por vários autores, Greene (2002) por exemplo, e quanto tal é possível, consiste em avaliar o efeito marginal para cada observação e considerar a média dos efeitos marginais individuais.

Quando se trata de uma variável *dummy*, e por não ser uma variável contínua, o procedimento anterior não é o mais apropriado para calcular o efeito marginal respectivo. Neste caso é costume calcular-se a diferença nas probabilidades estimadas resultantes de $Dummy=1$ e $Dummy=0$ no ponto médio das variáveis explicativas restantes.

São estes dois procedimentos que estão na base dos resultados que se apresentam na Tabela nº4.25:

<i>v_co_scoring</i>	0.004906
<i>v_co_limite_credit</i>	0.000019
<i>v_co_saldo_atual</i>	0.000037
<i>m_rendibilidade</i>	-0.000619
<i>idade</i>	0.001378
<i>habilit_d</i>	-0.114342
<i>ci_co_class_d</i>	-0.217117
<i>v_co_revolving</i>	-0.000028
<i>estado_civil_d</i>	-0.110437
<i>genero_d</i>	0.193188

Tabela nº 4.25- Tabela dos efeitos marginais

V_CO_SCORING 0.004906

Em média, por cada variação de uma unidade em *v_co_scoring*, a probabilidade do cliente ser bom pagador varia 0.004906 no mesmo sentido, supondo tudo o resto constante.




Gráfico nº 4.4- Árvore de classificação (CHAID) por *v_co_scoring*

V_CO_LIMITE_CREDIT

0.000019

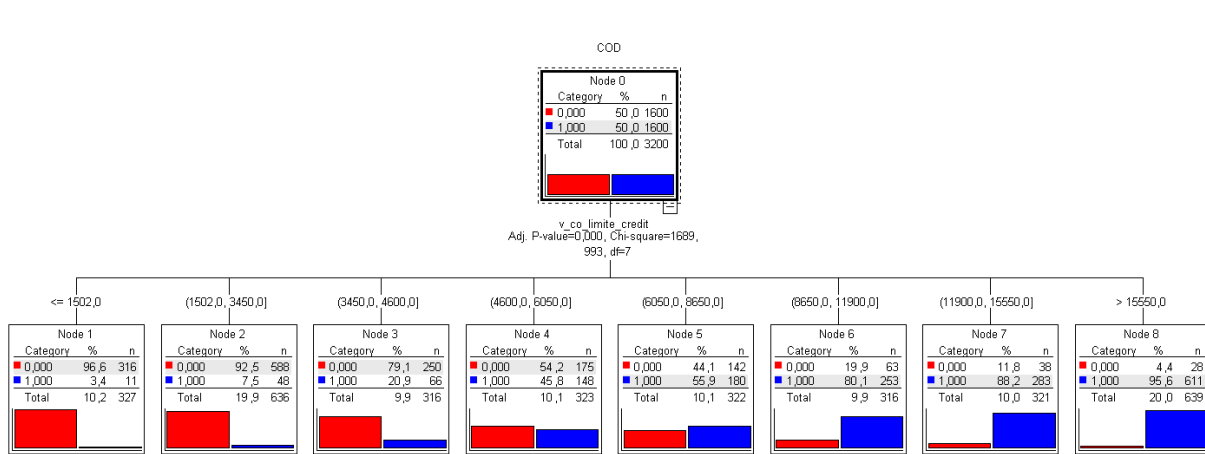


Gráfico nº 4.5- Árvore de classificação (CHAID) por v_co_limit_credit

Em média, por cada variação de uma unidade em *v_co_limite_credit*, a probabilidade do cliente ser bom pagador varia 0.000019 no mesmo sentido, supondo tudo o resto constante.

V_CO_SALDO_ACTUAL

0.000037

Em média, por cada variação de uma unidade em *v_co_saldo_atual*, a probabilidade do cliente ser bom pagador varia 0.000037 no mesmo sentido, supondo tudo o resto constante.




Gráfico nº 4.6- Árvore de classificação (CHAID) por v_co_saldo_atual

M_RENDIBILIDADE -0.000619

Em média, por cada variação de uma unidade em *m_rendibilidade*, a probabilidade do cliente ser bom pagador varia 0.000619 no sentido inverso, supondo tudo o resto constante.

IDADE 0.001378

Em média, por cada variação de uma unidade em *idade*, a probabilidade do cliente ser bom pagador varia 0.001378 no mesmo sentido, supondo tudo o resto constante.

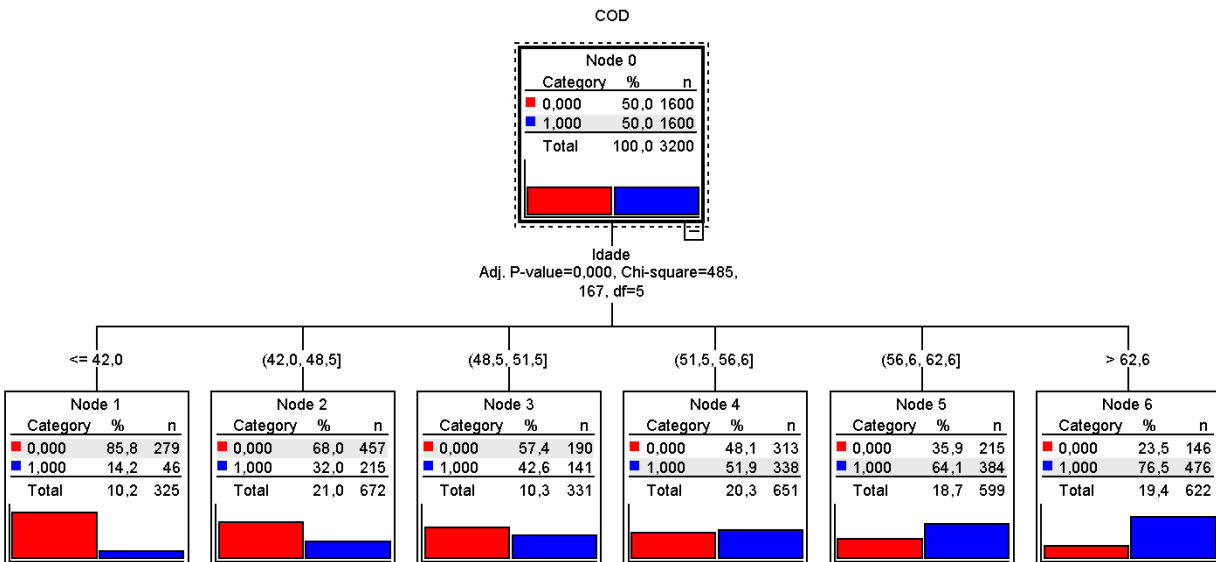


Gráfico nº 4.7- Árvore de classificação (CHAID) por *idade*

HABILIT__D

-0.114342

Em média a probabilidade de um cliente pertencer à Categoria “Resposta” ser Bom pagador é inferior em 0.114342 à mesma probabilidade dos clientes pertencerem à Categoria “Referência”, supondo tudo o resto constante.

		Frequency	Parameter coding
			(1)
HabilitDummy	0	1727	0,000
	1	1473	1,000

Tabela nº 4.26 – Frequências de Bons e Maus na característica *HabilitDummy*

Características	Atributos	Frequência	Categ. Referência	Categ. Resposta
			Grupo de Controlo	Grupo de Tratamento
			0	1
Habilitações	12º Ano	21		1
	Curso Mé	9		1
	Curso Su	329		1
	Escolari	12		1
	Menos qu	4		1
	Outros	1727	0	
	Sem Resp	1098		1

Tabela nº 4.27- Característica *Habilit* por categoria de Referência e por Resposta




Gráfico nº 4.8- Árvore de classificação (CHAID) por *habilit.dummy*

CI_CO_CLASS_D

-0.217117

Em média a probabilidade de um cliente pertencer à Categoria “Resposta” ser *Bom* pagador é inferior em 0.217117 à mesma probabilidade dos clientes pertencerem à Categoria “Referência”, supondo tudo o resto constante.

Categorical Variables Codings

		Frequency	Parameter coding
			(1)
ci_co_class(Dummy)	0	2577	,000
	1	623	1,000

Tabela nº 4.28 Frequências de *Más e Boas* contas da variável independente *ci_co_class*

Características	Atributos	Frequência	Categ. Referência	Categ. Resposta
			Grupo de Controlo	Grupo de Tratamento
			0	1
ci_co_class	0	34		1
	1	114		1
	2	55		1
	3	22		1
	6	16		1
	7	30		1
	8	27		1
	9	30		1
	13	256		1
	19	2577	0	
	20	39		1

Tabela nº 4.29 Frequências dos atributos da característica *ci_co_class*

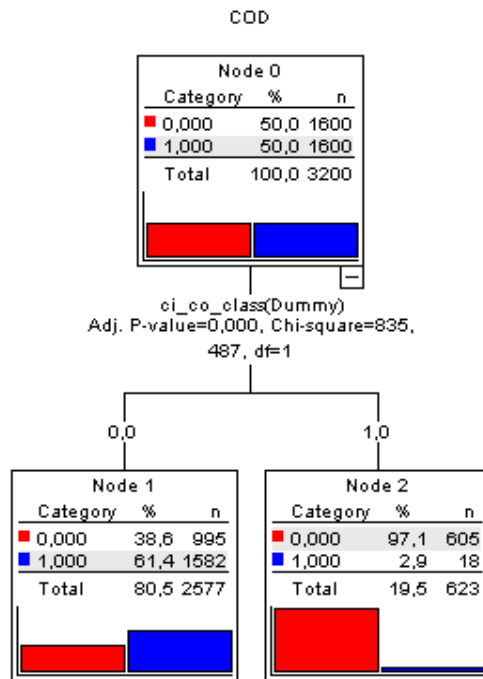


Gráfico nº 4.9- Árvore de classificação (CHAID) por *ci_co_class(Dummy)*

V_CO_REVOLVING -0.000028

Em média, por cada variação de uma unidade em *v_co_revolving*, a probabilidade do cliente ser bom pagador varia 0.000028 no sentido inverso, supondo tudo o resto constante.

ESTADO_CIVIL_D -0.110437

Em média a probabilidade de um cliente pertencer à Categoria “Resposta” ser Bom pagador é inferior em 0.110437 à mesma probabilidade dos clientes pertencerem à Categoria “Referência” (Casado), supondo tudo o resto constante.

Categorical Variables Codings			
		Frequency	Parameter coding (1)
		Estado Civil(Dummy)	0
	1	1341	1,000

Tabela nº 4.30 Frequências de *Más* e *Boas* contas da variável independente Estado Civil (*Dummy*)

Características	Atributos	Frequência	Categ. Referência	Categ. Resposta
			Grupo de Controlo	Grupo de Tratamento
			0	1
Estado Civil	Casado	1859	0	1
	Divorciado	288		
	Sem Resposta	656		
	Separado	16		
	Solteiro	306		
	Viúvo	75		

Tabela nº 4.31 Frequências dos atributos da característica *Estado Civil*




Gráfico nº 4.10- Árvore de classificação (CHAID) por *estado_civil(Dummy)*

GENERO_D

0.193188

Em média a probabilidade de um homem ser *Bom* pagador é superior em 0.193188 à mesma probabilidade das mulheres, supondo tudo o resto constante.

Características	Atributos	Frequência	Categ. Referência	Categ. Resposta
			Grupo de Controlo	Grupo de Tratamento
Género	F	951	0	1
	M	2249	0	1

Tabela nº 4.32 Frequências dos atributos da característica Género

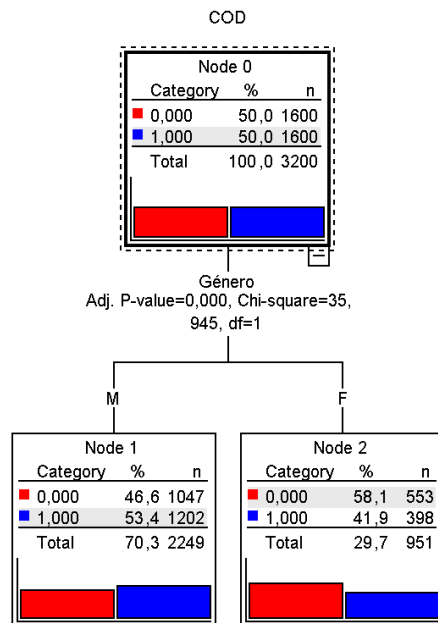


Gráfico nº 4.11- Árvore de classificação (CHAID) por *Género*

4.2.4 TESTE À HETEROCEDASTICIDADE DOS ERROS

A heterocedasticidade é considerada um sério problema nos modelos com variável dependente binária, pois se a variância dos erros não é constante os estimadores para os coeficientes deixam de ser os mais eficientes. Para concluir sobre a homoscedasticidade dos erros vamos calcular o valor do teste LM proposto por Davidson e MacKinnon (1993) assumindo que $v_co_limite_credit$ ¹⁰ é a variável responsável pela heterocedasticidade.

A estatística do teste LM é a soma de quadrados explicada (ESS) da regressão auxiliar cuja variável dependente são os resíduos estandardizados da regressão logística e tem uma distribuição do Qui-quadrado com q graus de liberdade, em que q é o número de variáveis consideradas para explicar a heteroscedasticidade. Neste caso $q=1$ a que corresponde um valor crítico de 3,84.

Para calcular o valor do teste seguimos a metodologia de Davidson e MacKinnon (1993) e recorremos directamente ao EVIEWS[®], tendo-se obtido o valor de $ESS = 37,82$. Como este valor é superior ao valor crítico rejeita-se a hipótese nula e conclui-se que os erros são heteroscedásticos.

Como consequência, os estimadores para os coeficientes da regressão logística deixam de ser os mais eficientes. Para obter estimadores consistentes para a variância dos estimadores recorremos ao procedimento de Huber-White que é disponibilizado pelo EVIEWS[®]. Os resultados obtidos são apresentados na tabela nº 4.33:

O procedimento de Huber-White corrige apenas a variância dos estimadores, não modificando as estimativas para os coeficientes já anteriormente apresentadas.

Apesar da correcção às variâncias, as estimativas para os coeficientes continuam todas estatisticamente significativas confirmando a relevância estatística das variáveis explicativas consideradas.

¹⁰ Para além desta consideraram-se também outras variáveis explicativas e o resultado do teste LM apontou sempre para a rejeição da hipótese da homoscedasticidade.

Dependent Variable: COD
 Method: ML - Binary Logit (Quadratic hill climbing)
 Sample: 1 3200
 Included observations: 3200
 Convergence achieved after 23 iterations
 QML (Huber/White) standard errors & covariance

Variable	Coefficient	Std. Error	z-Statistic	Prob.
V_CO_SCORING	0.066500	0.003411	19.49323	0.0000
V_CO_LIMITE_CREDIT	0.000261	2.21E-05	11.80743	0.0000
V_CO_SALDO_ACTUAL	0.000499	0.000132	3.788578	0.0002
M_RENDIBILIDADE	-0.008396	0.002957	-2.839041	0.0045
IDADE	0.018678	0.006731	2.774966	0.0055
HABILIT_D	-0.602927	0.128098	-4.706776	0.0000
CI_CO_CLASS_D	-1.434070	0.385528	-3.719759	0.0002
V_CO_REVOLVING	-0.000384	0.000130	-2.953830	0.0031
ESTADO_CIVIL_D	-0.578892	0.128583	-4.502090	0.0000
GENERO_D	0.808648	0.130033	6.218793	0.0000
C	-49.89290	2.462915	-20.25766	0.0000
McFadden R-squared	0.653876	Mean dependent var	0.500000	
S.D. dependent var	0.500078	S.E. of regression	0.260019	
Akaike info criterion	0.486704	Sum squared resid	215.6077	
Schwarz criterion	0.507573	Log likelihood	-767.7269	
Hannan-Quinn criter.	0.494186	Restr. log likelihood	-2218.071	
LR statistic	2900.688	Avg. log likelihood	-0.239915	
Prob(LR statistic)	0.000000			
Obs with Dep=0	1600	Total obs	3200	
Obs with Dep=1	1600			

Tabela nº 4.33- *Output* do EVIEWS® ilustrando o procedimento Huber-White para obtenção dos coeficientes da regressão logística

4.2.5 VALIDAÇÃO DO MODELO ATRAVÉS DE *OUT-OF-SAMPLE*

Os valores obtidos para as variáveis independentes que entraram no modelo são os seguintes:

Variáveis na equação	Código	B
<i>v_co_scoring</i>	A	0,066500
<i>v_co_limite_credit</i>	B	0,000261
<i>v_co_saldo_actual</i>	C	0,000499
<i>m_rendibilidade</i>	D	-0,008396
<i>Idade</i>	E	0,018678
<i>Habilit (D)</i>	F	-0,602927
<i>ci_co_class (D)</i>	G	-1,434070
<i>v_co_revolving</i>	H	-0,000384
<i>Estado civil</i>	I	-0,578892
<i>Género (D)</i>	J	0,808648
<i>Constante</i>		-49,89290

Tabela nº 4.34- Valores dos coeficientes B das variáveis presentes na equação da regressão logística

A validação do modelo foi efectuada através de uma amostra (*out-of-sample*) contendo 800 clientes (400 Bons e 400 *Maus*) e aplicada ao modelo de regressão logística de acordo com a seguinte equação:

$$p(Y_i = 1) = \frac{1}{1+e^{-Z_i}} + \varepsilon_i \quad (4.1)$$

$$Z_i = \beta_0 + \beta_1 x_{1i} + \dots + \beta_k x_{ki} \quad (4.2)$$

$$p(Y_i=1)=1/1+e^{-(-49,89290+0,066500 \times A+0,000261 \times B+0,000499 \times C-0,008396 \times D+0,018678 \times E-0,602927 \times F-1,434070 \times G-0,000384 \times H-0,578892 \times I-0,808648 \times J)}$$

Os valores obtidos estão resumidos na Tabela 4.36, o que comprova a robustez preditiva do modelo.

Observed		Predicted		
		COD		
		0	1	Percentage Correct
0	1433	126	89,56%	
COD 1	167	1474	92,13%	
Overall Perc			90,84%	

Tabela nº 4.35

IN-SAMPLE

Observed		Predicted		
		COD		
		0	1	Percentage Correct
0	356	43	89,00%	
COD 1	27	374	93,50%	
Overall Perc			91,25%	

Tabela nº 4.36

HOLDOUT SAMPLE

Da similitude dos resultados obtidos nas duas amostras (*in-sample* e *out-of-sample*), demonstrou-se que o modelo oferece uma considerável robustez preditiva, permitindo antecipar o resultado *Bom* ou *Mau* cliente, e desta forma prever e reduzir os créditos de cobrança duvidosa futuros.

CAPÍTULO 5 – CONCLUSÕES, CONTRIBUIÇÕES ESPERADAS E SUGESTÕES

5.1 CONCLUSÕES DO ESTUDO EMPÍRICO

Do presente estudo empírico ressaltam as seguintes conclusões:

- 1- Os principais factores explicativos identificados pelo modelo logístico (variáveis identificadas com maior força preditiva) foram: *v_co_scoring*, *v_co_limite_credit*, *v_co_saldo_actual*, *m_rendibilidade*, *idade*, *habilit_d*, *ci_co_class_d*, *v_co_revolving*, *estado_civil_d* e *genero_d*.
- 2- A metodologia apresentada neste estudo mostrou que a regressão logística binária é capaz de classificar correctamente 90,84% dos indivíduos (1474 PV+1433 NV= 2907; 3200);
- 3- O modelo classificou melhor os *Bons* pagadores (92,13%; PV=1474; 1600) do que os *Maus* pagadores (89,56%; NV=1433;1600);
- 4- A classificação de *Bom* pagador prevista para 126 indivíduos veio a revelar-se na observação serem *Maus* pagadores (PF; Erro Tipo II) e a classificação de *Mau* pagador prevista para 167 indivíduos veio a revelar-se na observação serem *Bons* pagadores (NF; Erro Tipo I).
- 5- Das 21 variáveis independentes originais apenas 10 (6 quantitativas e 4 *dummies*) foram utilizadas no modelo de previsão.
- 6- A validação do modelo através de uma base de dados fora da amostra, mostrou ser capaz de classificar correctamente 91,25% dos indivíduos (374 PV+356 NV= 730; 800).

Demonstrou-se que a metodologia utilizada identificou dez principais factores caracterizadores de um *Bom* e de um *Mau* pagador, confirmando-se a robustez preditiva do modelo.

5.2 CONCLUSÕES SOBRE A METODOLOGIA

5.2.1 INTRODUÇÃO

A metodologia utilizada neste estudo é o resultado da escolha feita entre outros conjuntos de métodos e de técnicas capazes de mitigar o problema do crescimento do crédito malparado.

O *credit scoring* compila um conjunto de métodos que foram apurados, melhorados e refinados, ao longo das últimas quatro décadas, com o contributo de muitos académicos (Ver Cap.2), gestores, analistas de crédito e instituições financeiras.

A congregação de todo aquele conhecimento só se tornou, efectivamente, útil às instituições, quando foi possível oferecer o conjunto de saberes (*know-how*) através de uma ferramenta de gestão que servisse de utensílio à reparação de problemas resultantes da concessão de crédito.

Essa ferramenta ganhou notoriedade entre a comunidade empresarial através de William R. Fair e Earl J. Isaac (1956) ao conceberem, segundo formas padronizadas de análise, os passos que deveriam ser dados no apoio à decisão da concessão de crédito, com o recurso a métodos estatísticos.

A protecção do “segredo” de todo o conhecimento adquirido deu lugar a *black boxes*, dificultando a replicação daquela ferramenta por outros fabricantes de *scoring*.

A FICO (Fair Isaac Company) tornou-se pioneira na criação daquela ferramenta e ainda hoje assegura a liderança no desenvolvimento de sistemas de *scoring* com aplicação a outras áreas.

O Marketing Directo, vulgarmente designado por “Vendas por Correio”, foi uma dessas áreas beneficiando da aplicação do modelo de regressão logística binária no envio de cartas a potenciais consumidores, com o importante apoio à decisão de “envia carta” ou “não envia carta” em função do conhecimento prévio de características identificadoras do perfil de consumidor.

A classificação por pontos (*score*) de tipos de clientela e a correcta gestão das bases de dados, ajudou a identificar potenciais consumidores para determinados produtos, nomeadamente através das técnicas de *cross-selling* em que a identificação de alguém que

tivesse consumido determinado produto, seria um potencial consumidor de um novo produto que se ajustaria ao seu perfil comportamental (*scoring* comportamental).

O desenvolvimento dos recursos computacionais deram novos impulsos ao *scoring* devido à rapidez de processos, à precisão conseguida nos seus resultados e ao extraordinário volume de informação prospectada pelo *Data Mining*.

A oferta ao consumidor de um crédito rotativo (*revolving credit*) por instituições financeiras e não-financeiras, materializou como meio de pagamento o cartão de crédito. Toda a *estrutura* de concessão de crédito montada sobre um cartão de crédito é feita segundo a metodologia do *credit scoring*.

Os utentes dos cartões de crédito, disseminados em todo o Mundo, beneficiaram das revoluções tecnológicas dos meios de comunicação por satélite, permitindo autorizações de pagamento a longas distâncias da fonte de crédito.

5.2.2 PRINCIPAIS CONCLUSÕES

1-A metodologia do *credit scoring* constitui uma das principais ferramentas para a mitigação do risco de crédito. Ao mitigar o problema, o crédito malparado é reduzido e esta redução é conseguida à custa da detecção atempada de potenciais incumpridores.

Da constatação dos resultados oferecidos pelo estudo, concluímos que o *credit scoring* é uma metodologia capaz de prever e reduzir os créditos de cobrança duvidosa.

2-A metodologia do *credit scoring* distingue os métodos aplicados a candidatos a crédito (*application scoring*) daqueles que já beneficiaram da sua concessão e cujo comportamento de pagamento permite indiciar futuros incumpridores (*behavioural scoring*).

Da constatação dos resultados verificados entre 4000 utentes de cartões de crédito (*behavioural scoring*), concluímos que o *scoring* comportamental permite prever a probabilidade de incumprimento, através da construção (definição) prévia do perfil de *Bom* e *Mau* pagador.

3-A vulgarização da utilização dos cartões de crédito deve-se em grande parte ao desenvolvimento desta metodologia associada a novas tecnologias de comunicação em tempo real, potenciando e generalizando este meio de pagamento.

4-As bases de dados, devidamente tratadas, constituem uma das premissas básicas para o sucesso desta metodologia.

5-O custo associado ao tratamento das bases de dados é muito elevado, não só pelo tempo consumido na compilação dos dados, como no custo da construção de tabelas de *scoring*.

6-Os elevados custos inerentes ao desenvolvimento e implantação desta metodologia, restringe o universo de aplicação, deixando de fora do seu alcance a maioria das PME.

7-A ausência de uma cultura estatística na maioria das empresas e o desconhecimento dos benefícios resultantes do *scoring* tem como consequência a falta de atenção dada a esta metodologia e à escassez de quadros especializados nesta área.

8-A metodologia do *scoring* tem aplicação em outras áreas diferentes de as do crédito, nomeadamente na área dos seguros, nas agências de informações comerciais, no marketing, na gestão produção, nos recursos humanos.

5.3 CONTRIBUIÇÕES ESPERADAS

5.3.1 PARA A TEORIA

Desde o início do pensamento científico que a compreensão da natureza se tem pautado pela simplicidade das proposições científicas. A natureza humana e a complexa componente idiossincrásica a ela associada, deverá obedecer a este mesmo princípio como sendo o mais poderoso método para a sua compreensão.

A diminuição do risco da concessão de crédito nas tomadas de decisão, pela metodologia apresentada, pressupõe moderação e simplicidade nos métodos de avaliação.

A presente dissertação acatou o princípio da parcimónia e a adequabilidade de previsão ao modelar a função *logit* com apenas dez variáveis de um conjunto inicial de vinte e uma características.

Numa perspectiva mais abrangente sobre a Teoria da Gestão do Risco de Crédito, acreditamos que a mesma será enriquecida se a metodologia do *credit scoring* tiver uma presença mais proeminente. Este enriquecimento permitirá uma melhor compreensão das

teorias que explicam os processos que descrevem a ajuda à decisão de concessão e avaliação do risco do crédito.

A constatação da utilidade do presente contributo para a teoria só será melhor evidenciada quando as instituições financeiras e não-financeiras reconhecerem os seus méritos aquando da sua aplicação aos processos de gestão do risco do crédito.

5.3.2 PARA A GESTÃO

O modelo de regressão logística, apesar da sua popularidade junto da *comunidade científica*, está longe de poder constituir uma ferramenta de utilização frequente em muitas actividades económicas.

Dada a reduzida utilização dos métodos estatísticos na gestão do crédito, recomenda-se que o tratamento dos dados empresariais seja uma das prioridades da Gestão.

O tratamento desses dados pode ser efectuado por centros de investigação que disponibilizem às diferentes actividades económicas os principais factores caracterizadores do perfil de risco da sua clientela.

O conhecimento mais profundo do comportamento de grupos de risco, reduziria os níveis de incerteza e explicaria melhor as consequências de tomadas de decisão não devidamente ponderadas.

5.3.3 PARA AS POLÍTICAS PÚBLICAS

O tratamento de dados tem permitido às instituições em particular, e ao Estado Português em geral, uma melhor eficiência nos seus processos de gestão.

Sem aquele tratamento e relacionamento dessa informação os processos de gestão seriam mais demorados e menos eficazes. Por esta via melhora-se a inter-relatividade dos sistemas de gestão com influência directa nos comportamentos e condutas profissionais e sociais.

O não investimento na prospecção de dados, sua limpeza e tratamento, retarda o conhecimento e na ausência deste as probabilidades de se tomarem boas decisões são menores. O Banco de Portugal, o INE, os Institutos Públicos entre outros organismos deveriam concertar informação específica em várias áreas de interesse económico,

disponibilizando à sociedade um bem público (o conhecimento), permitindo assim a construção de modelos de desenvolvimento até agora inexplorados.

A descoberta de conhecimento através de bases de dados¹¹ de natureza governamental, para a identificação de padrões de desenvolvimento, deverá constituir uma das preocupações do Governo de forma a reduzir o desperdício, aumentar a produtividade e replicar os modelos de sucesso aplicados em outros contextos.

A promoção de uma cultura estatística no seio das organizações alicerçada no conhecimento derivado da prospecção de dados (*data mining*), resultará em processos de decisão com menor risco, maior consistência e maior sustentabilidade temporal.

Nesta perspectiva, abrir-se-iam novas oportunidades de emprego para os jovens especializados nestas matérias. A inevitável melhoria nos processos de avaliação do risco aumentaria o conhecimento das organizações, tornando-as mais eficazes e mais protegidas da ameaça do incumprimento de pagamento.

5.4 SUGESTÕES PARA FUTURAS INVESTIGAÇÕES

A metodologia apresentada neste estudo pode constituir um ponto de partida para outros trabalhos que pretendam investigar questões relacionadas com processos de mitigação do risco de crédito, do risco de investimento, do risco de insolvência, entre tantos outros.

O aumento do investimento público tem sido uma das políticas económicas apontadas para a mitigação de crises económicas, se bem que a sua aplicação à economia possa ser feita com elevados graus de risco.

O investimento público tem sido uma das áreas de decisão política que tem revelado um elevado grau de risco, não só pelas quantias envolvidas mas também pela incerteza do seu sucesso.

Entre a decisão de realizar um projecto ou não realizá-lo deveria de existir um conjunto de variáveis já identificadas por projectos anteriores, que avaliassem a probabilidade de sucesso desses investimentos.

¹¹ KDD-Knowledge Discovery in Databases. Ver Brachman,R.J. *et al.*(1996)- *The Process of Knowledge Discovery in Databases. The KDD Process for Extracting Useful Knowledge from Volumes of Data*, págs.37-57.

A necessidade destes estudos torna-se ainda maior quando em momentos de grande turbulência económica e social as decisões incorrectas consomem muito esforço do erário público.

Este sacrifício social não pode ser exaurido por erros de decisão, muitas vezes baseados em subjectividades de cariz política ou em estudos de credibilidade duvidosa, alguns deles encomendados à medida dos resultados que se pretendem evidenciar.

A realização de obras públicas de avultado investimento, sem conhecimento do risco associado, tem produzido frequentes “derrapagens” financeirasa e em alguns casos essas obras são de utilidade pública muito discutível, dada a relação custo-benefício demonstrada.

O modelo *logit* é uma ferramenta estatística importante, neste tipo de estudos. Contudo toda a eficácia da sua utilidade é fortemente questionada se na integração do modelo as variáveis com maior capacidade preditiva forem ignoradas, desconhecidas ou mal-interpretadas.

A questão parece-nos pertinente quando questionamos as razões porque se repetem hoje os mesmos erros que já foram cometidos no passado.

Porque razão os factores explicativos desses erros não servem de conhecimento para modelar estatisticamente novos projectos?

BIBLIOGRAFIA

- Allen, L. e Saunders, A. (2004). "Special Issue on The Path to Basel II Adoption". *Journal of Financial Services Research*, Vol.26, págs. 101-191.
- Allison, P. D. (2005). "Logistic Regression using SAS, Theory and Application". *SAS Institute Inc.*
- Altman, E. I., (1968). "Financial Ratios. Discriminant Analysis and the Prediction of Corporate Bankruptcy". *Journal of Finance*, vol.23, n° 4, págs. 589-609.
- Altman, E. I., Haldeman, R. G. e P. Narayanan. (1977). "ZETA Analysis. A new model to identify bankruptcy risk of corporations". *Journal of Banking and Finance*, vol.1, págs. 29-54.
- Altman, E.I., e Saunders, A., (1998). "Credit risk measurement: Developments over the last 20 years". *Journal of Banking and Finance*, vol.21, págs. 1721-1742.
- Altman, I. E., e Hotchkiss, E., (2006), "Corporate Financial Distress and Bankruptcy (3rd edition)", *John Wiley & Sons, Inc.*
- Anderson, R. (2007). "The Credit Scoring Toolkit. Theory and Practice for Retail Credit Risk Management and Decision Automation". *Oxford University Press.*
- Aziz, A., Lawson, G. H. (1989). "Cash flow reporting and financial distress models". *Ph.D Dissertation.*
- Balcaen, S. e Ooghe, H., (2004). "Alternative methodologies in studies on business failure: Do they produce better results than the classical statistical methods?" *Art. 2004/249, Faculteit Economie en Bedrijfskunde.*
- Batista, A. (2004). "A Gestão do Crédito como Vantagem Competitiva (3^a edição)" p. 43-77 . *Vida Económica.*
- Beaver, W.(1966). "Financial Ratios as Predictors of Bankruptcy". *Journal of Accounting Research*, vol 6, págs 71-102.
- Bento, J. e Machado, J.F.(2009) – "Plano Oficial de Contabilidade". *Porto Editora*
- Biggs, D., de Ville, B. e Suen, E. (1991). "A Method of Choosing Multiway Partitions for Classification". *Journal of Applied Statistics*, Vol. 18, págs. 9-62.
- Bishop, C.M. (2003). "Neural Networks for Pattern Recognition" (ed.2003). *Oxford University Press.*
- Bonne, T. & G. Armingier (2001), "Diskriminanzanalyse", in *Handbuch Data Mining*
- Boyle, M., Crook, J.N., Hamilton, R., e Thomas, L.C. (1992). "Survey of Consumer Finance", *Board of Governors of the Federal Reserve System, Washington, DC.*
- Breiman, L., Friedman, J. H., Olshen R. A. e Stone, C. J. (1984). "Classification and Regression Trees", *Wadsworth, Belmont, CA.*
- Chatterjee, S. e Barcun, S. (1970). "A nonparametric approach to credit screening". *J. Amer. Statistics Association*, 65, 150-154.
- Claessens, S., Krahnen, J. e Lang, W. W. (2005). "The Basel II Reform and Retail Credit Markets". *Journal of Financial Services Research*, Vol.28, págs. 5-13.

- Coffman J. Y. (1986). "The Proper Role of Tree Analysis in Forecasting the Risk Behaviour of Borrowers". *MDS Reports, Management Decision Systems, Atlanta, GA, 3, 4, 7, 9.*
- Cortes, B. (2005). "Sistemas de Suporte à Decisão". *FCA.*
- Crook, J.N., Hamilton, R., e Thomas, L.C.,(1992). "A comparison of a credit scoring model with a credit performance model" .*The Service Industries Journal 1.*
- Darwin, C. (1859). "On the Origin of Species". *John Murray, London.*
- Desai, V. S., Conway, D. G., Crook, J. N. E Overstreet, G.A. (1997). "Credit scoring models in the credit union environment using neural networks and genetic algorithms". *IMA Journal of Mathematics Applied in Business and Industry, 8, 323-346.*
- Desai, V. S., Crook, J. N. e Overstreet, G.A. (1996). "A comparison of neural networks and linear scoring models in the credit union environment". *European Journal of of Operations Research 95, 24-37.*
- Dierick, F., F. Pires, M. Scheicher & K.G. Spitzer (2005), *The New Basel Capital Framework and its Implementation in the European Union*, Occasional Paper Series, No. 42, European Central Bank, Frankfurt/M, December.
- Dimitras, A.I., Zanakis, S.H. e Zopounidis, C.(1996). "A survey of business failures with an emphasis on prediction methods and industrial applications". *European Journal of Operational Research, vol 90, págs 487-513.*
- Dong, Y. (2007). "An Application of Support Vector Machines in Small-Business". *Credit Scoring Conference on Innovative Computing, Information and Control, 2007. ICICIC '07.*
- Durand, D. (1941) *Estudo publicado no National Bureau of Economic Research - New York.*
- Eisenbeis, R.A., (1978). "Problems in applying discriminant analysis in credit scoring models". *Journal of Banking Finance, 2, págs. 205-219.*
- Eklund, T., Larsen, K., Bernhardson, E. (2001). "Model for analyzing credit risk in the enterprise sector". *Economic Bulletin, Oslo, Noruega, vol. LXXII, n. 3, p. 99-106.*
- Espahbodi, H. e Espahbodi, P. (2003). "Binary choice models and corporate takeover". *Journal of Banking and Finance, Vol.27, págs.549-574.*
- Ewert, R., Szczesny, A. (2002). "Risikoindikatoren, Rating und Ausfallwahrscheinlichkeit im Kreditkundengeschäft – Eine empirische Untersuchung vor dem Hintergrund von Basel II", *Betriebswirtschaftliche Forschung und Praxis, Vol. 54, p. 574-590.*
- Fair Isaac, (2006). "A discussion of Data Analysis – Prediction and Decision Techniques". *FICO Edit.*
- Fisher, R.A. (1936). "The use of multiple measurements in taxonomic problems", *Annals of Eugenics 7, 179-188*
- Fix, E. e Hodges, J. (1952). "Discriminatory Analysis, Nonparametric Discrimination, Consistency Properties". *Report 4, Project 21-49-004, School of Aviation Medicine, Randolph Field, TX.*
- Freed, N. e Glover ,F. (1981b). "Simple but powerful goal programming formulation for the discriminant problem". *European J. Oper. Res., 7, 44-60.*

- Freed, N. e Glover, F. (1981a). "A linear programming approach to the discriminant problem". *Decision Sci.*, 12, 68-74.
- Frisch, R. (1934). "Statistical Confluence Analysis by Means of Complete Regression Systems". *Institute of Economics, Univers. Oslo, public. 5, 1934.*
- Frydman, H., Altman, E.I., e Kao, D-L. (1985) "Introducing Recursive Partitioning for Financial Classification: The Case of Financial Distress". *Journal of Finance, Vol.11, págs. 269-291.*
- Galindo, J. & P. Tamayo (2000), "Credit Risk Assessment Using Statistical and Machine Learning: Basic Methodology and Risk Modeling Applications", *Computational Economics*, Vol. 15, pp. 107-143.
- Greene, W.H. (2002). "Econometric analysis". *Prentice Hall.*
- Gross, D. B. e Souleles, N. S., (2002). "An Empirical Analysis of Personal Bankruptcy and Delinquency". *Review of Financial Studies, Vol. 15, págs. 319-347.*
- Hadidi, N. (2003). "Classification Rulemaking Using Decision Trees". *Data Management, Quality and Technology Call Papers and Rulemaking Papers, Casualty Actuarial Society, págs. 253-284.*
- Hand, D. J. (2001). "Modelling consumer credit risk". *IMA Journal of Management Mathematics, Vol.12.*
- Hand, D. J. e Henley, W. E. (1997). "Statistical classification methods in consumer credit scoring: a review". *J.R.Statist.Soc.A (1997), 160, Part 3, pp. 523-541.*
- Hayden, E. (2002). "Modeling an Accounting-Based Rating System for Austrian Firms". *125 f. Dissertation (Doktor der Sozial und Wirtschaftswissenschaften). University of Vienna, Austria, Viena.*
- Haykin, S. (1999). "Neural Networks: a comprehensive foundation", 2/E.
- Hebb, D.O. (1949). "The Organization of Behavior". *Willey, New York.*
- Henley, W. E. e Hand, D. J. (1996). "A k-NN classifier for assessing consumer credit risk", *Statistician, 65, 77-95.*
- Henley, W. E., (1995). "Statistical Aspects of Credit Scoring". *Ph.D. thesis, Open University, Milton Keynes, U.K.*
- Hill, M. (2005), "Investigação por Questionário". *Edições Sílabo, 2ª edição.*
- Holland, J. H. (1975). "Adaptation in Natural and Artificial Systems". *University of Michigan Press, Ann Arbor.*
- Holmen, J. (1988), "Using financial ratios to predict bankruptcy: an evaluation of classic models using recent evidence", *ABER, Vol. 19 No.1, p.52-63.*
- im Marketing*, Wiesbaden, pp. 193-239.
- Jagtiani, J. A., Kolari, J. W., Lemieux, C. M., Hwan Shin, G. (2000). "Predicting Inadequate Capitalization: Early Warning System for Bank Supervision". *Supervision and Regulation Department, Federal Reserve Bank of Chicago, Emerging Issues Series (S&R-2000-10R).*
- Johnson, R.W.(2002). "Credit Scoring and Credit Control". *Thomas, Crook e Edelman edit. p. 19-32.*

- Jones, F.L. (1987). "Current Techniques in Bankruptcy Prediction". *Journal of Accounting Literature*, vol. 6, págs 131-164.
- Jost, A. (1998). "Data Mining, in Credit Risk Modeling". E. Mays, ed. *Glenlake Publishing, Chicago*, 129-154.
- Kaltofen, D., Möllenbeck, M., e Stein, S. (2004). "Modellierung eines Risikofrüherkennungssystems für das Kreditgeschäft mit mittelständischen FirmenKunden". in S.Paul & S. Stein (eds), *Brennpunkt Kreditgeschäft, ff. forschungsfolge 03, Frankfurt/M.*, p. 161-174.
- Kaltofen, D., Paul, S. e Stein, S. (2006). "Retail Loans & Basel II". *European Credit Research Institute-ECRI Research Report Nr.8*.
- Kass, G.V. (1980). "An Exploratory Technique for Investigating Large Quantities of Categorical Data". *Applied Statistics*, 29, p. 119-127.
- King, R.D., Henery, R., Feng, C., e Sutherland, A.(1994). "A comparative study of classification algorithms: statistical, machine learning and neural network". *Machine Intelligence*, vol. 13, (K. Furukwa, D. Michie e Muggleton editors). *Oxford: Oxford University Press*.
- Kotler, P. (1991). "Marketing Management-Analysis, Planning, Implementation and Control". *Prentice-Hall International Editions*.
- Lang, W. W. e Santomero, A. M. (2002). "Risk Quantification of Retail Credit: Current Practices and Future Challenges". *Federal Reserve Bank of Philadelphia, Philadelphia, December*.
- Lewis, E. M., (1992). "An Introduction to Credit Scoring". *Fair, Isaac and Co., Inc.* p. XV.
- Loh, Wi-Yin e Shih, Yu-Shan (1997). "Split Selection Methods for Classification Trees". *Statistica sinica*, Vol.4, p. 815-840.
- Maddala, G. S. (1983). "Limited-dependent and qualitative variables in econometrics". *Econometric Society monographs*, Cambridge.
- Madeira, M.(2009). "Cosmologia, Matemática e Filosofia". <http://cmatfil.blogspot.com/2009/03/metodologia-metodo-modelo-definicoes.html>.
- Makowski P. (1985). "Credit scoring branches out", *Credit World*, 75, 30-37
- Mangasarian, O. L. (1965). "Linear and nonlinear separation of patterns by linear programming". *Oper. Res.*, 13, 444-452.
- Martin, D. (1977). "Early Warning of Bank failure – a logit regression approach". *Journal of Banking and Finance*, Vol.1, págs. 249-276.
- Mavri, M., Vassilis, A., Ioannou,G., Gaki, E. and Koufodontis, I. (2008). "A two-stage dynamic credit scoring model, based on customers' profile and time horizon". *Journal of Financial Services Marketing* 13, 17–27.
- Mays, E. (2001). "Handbook of Credit Scoring". *The Glenlake Publishing Company, Ltd*.
- Mays, E. (2004). "Credit Scoring for Risk Managers: The Handbook for Lenders". *Thomson South–Western*.
- McCulloch, W.S. & Pitts,W. (1943). "A Logical Calculus of the Ideas Immanent in Nervous Activity". *Bulletin of Mathmatical Biophysics* 5 , 115-133.

- Ohlson, J.A. (1980). "Financial Ratios and The Probabilistic Prediction of Bankruptcy". *Journal of Economic Theory*, vol. 79, págs. 1-45 e *Journal of Accounting Research*, Vol.18, págs. 109-131.
- Ooghe, H. e Balcaen, S. (2002). "Are failure prediction models transferable from one country to another? An empirical study using Belgian financial statements". *Vlerick Working Papers 2002/5*.
- Paul, S. (2006). "Basel II im Überblick". *Hofmann, Gerhard (ed.), Basel II und MaRisk, Frankfurt/M.*
- Persons, O. S. (1999). "Using financial information to differentiate failed vs. surviving finance companies in Thailand: an implication for emerging economies". *Multinational Finance Journal*, vol. 3, n. 2, p. 127-145, 1999.
- Platt, H.D., Platt, M. B. (2002). "Predicting corporate financial distress: reflections on choice-based sample bias". *Journal of Economics and Finance*, vol. 26.
- Popper, K. R. (1994) – "A vida é aprendizagem. Epistemologia evolutiva e sociedade aberta". *Biblioteca de Filosofia Contemporânea. Edições 70. Título original: All Life is Problem Solving*.
- Press, S. J. e Wilson, S. (1978). "Choosing Between Logistic Regression and Discriminant Analysis". *Journal of the American Statistical Association – JSTOR*.
- Quinlan, J.R. (1986). "Induction of Decision Trees, Machine Learning". *Vol.1 págs. 81-106*.
- Quinlan, J.R. (1993). "C4.5: Programs for Machine Learning". *San Mateo*.
- Reis, E. (2001). "Estatística Multivariada Aplicada" (2ª Edição). *Edições Sílabo*.
- Ripley, B. D. (2002). "Pattern recognition and neural networks". *Cambridge*.
- Rosenblatt, F. (1958). "The Perceptron: A Probabilistic Model for Information Storage and Organization in the Brain". *Psychol. Rev.* , nº65, págs. 386-408.
- Russell Davidson e James G. MacKinnon (1993). "Estimation and Inference in Econometrics". *Oxford University Press, New York*.
- Safavian S. R. e Landgrebe D. (1991). "A survey of decision tree classifier methodology", *IEEE Trans. Systems Man Cybernetics*, 21, 660-674.
- Schewe, G. e Leker, J. (2000). "Statistische Insolvenzdiagnose: Diskriminanzanalyse versus logistische Regression", in *J. Hauschildt & Leker (eds.), Krisendiagnose durch Bilanzanalyse, 2nd edition, Köln, págs. 168-178*.
- Shumway, T. (2001). "Forecasting Bankruptcy More Accurately: A Simple Hazard Model". *Journal of Business*, vol.74, nº1, págs. 101-124.
- Siddiqi, N. (2006). "Credit Risk Scorecards: Developing and Implementing Intelligent Credit Scoring". *John Wiley & Sons, Inc., Hoboken, New Jersey*.
- Srinivasan, V. e Kim, Y.H. (1987b). "Credit granting: "A comparative analysis of classification procedures", *Journal of Finance*, 42,665-683.
- Thomas, L.C., (2009). "Consumer Credit Models. Pricing, Profit and Portfolios". *Oxford University Press*.
- Thomas, L.C., Edelman, D. B., Crook, J.N., (2006). "Readings in Credit Scoring: Recent developments, advances and aims". *Oxford University Press*.

- Thomas, L.C., Edelman, D.B., Crook, J.N. (2002). "Credit Scoring and Its Applications", *SIAM Monographs on Mathematical Modeling and Computation*.
- Westgaard, S., Wijst, N. (2001). "Default probabilities in a corporate bank portfolio: a logistic model approach". *European Journal of Operational Research*, 135, p. 338-349, 2001.
- Wiginton, J. C., (1980). "A note on the comparison of *logit* and discriminant models of consumer credit behavior". *Journal of Financial Quantitative Analysis*, 15, págs. 757-770.
- Wilson, N., Summers, B., Hope, R. (2000). "Using payment behavior data for credit risk modeling". *International Journal of the Economics of Business*, vol. 7, n. 3, p. 333-346.
- Yobas, B., Crook, N., Ross, P. (2000). "Credit scoring using neural and evolutionary techniques" *IMA Journal of Mathematics Applied in Business and Industry* (2000) 11,111-125.
- Zavgren, C.V., Friedman, E. (1988). "Are bankruptcy prediction models worthwhile? An application in securities analysis". *Management International Review*, vol. 18, 1988.

ANEXOS

ANEXO 1 - Acordo de Basileia II (Breve resumo)

Dada a importância do *credit scoring* na mitigação do risco, esta técnica surge referenciada no *Acordo de Basileia* como um meio de os Bancos poderem controlar o risco de uma forma mais rigorosa.

A prevenção e redução do crédito malparado, constituindo uma das directrizes daquele acordo, conduziu os Bancos a evidenciarem um melhor conhecimento das técnicas de avaliação do risco sobre os empréstimos concedidos à sua clientela. As causas remotas apontadas para a necessidade deste acordo, relatam-se no resumo seguinte:

Segundo Kaltofen *et al.*(2006), desde o início dos anos da década de 1980 que vinha a sentir-se por parte dos países das maiores economias, certos apelos para uma harmonização urgente dos muitos e distintos padrões de supervisão bancária internacional. Estes apelos ganharam mais força quando se fez sentir a necessidade de erradicar o arbítrio das entidades reguladoras, nos países em que os empréstimos bancários estavam sujeitos a políticas de supervisão mais liberais e permissivas. Os órgãos de supervisão dos bancos centrais dos Estados Unidos da América e do Reino Unido, através de uma estratégia concertada, conseguiram passar para os governadores dos bancos centrais, do então designado “Grupo dos Dez”, o compromisso de seguirem as recomendações que estes dois países fizeram à Comissão de Basileia para a Supervisão Bancária em 1988, (o então chamado “Acordo de Capital de Basileia”, hoje designado por “Basileia I”).

A publicação intitulada por “Convergência Internacional de Medição de Capital e Padrões de Capital – Uma revisão ao enquadramento”, editada em Junho de 2004 (Comissão de Basileia, 2004), seguida da consulta de vários artigos que versavam esta matéria, já constituíam na altura uma tentativa da Comissão de Basileia para a sua quase completa revisão ao Acordo de 1988 (“O novo acordo de Basileia sobre Capital” ou “Basileia II”). Através desta revisão, o objectivo da comissão foi o “Fortalecimento adicional da consistência e estabilidade do sistema bancário internacional”, enquanto se mantinham os requisitos gerais anteriores reguladores sobre Capital.

Os objectivos dos novos regulamentos visavam gerir os riscos da Banca numa base mais compreensível e mais sensibilizada para o risco. Ao mesmo tempo, a comissão

pretendeu estabelecer uma maior equidade competitiva entre os bancos, encorajando-os a desenvolver sistemas de gestão de risco de crédito. Sob este novo formato, seria usado um conceito de *três pilares* para alcançar estes objectivos.

Durante décadas, os Bancos tinham sido expostos aos requisitos mínimos de fundos próprios (Pilar 1) relativamente aos montantes de crédito concedidos, e desde 1988 também ao *risco de mercado*. Sob o novo enquadramento, contudo, a regulamentação existente, relativa ao *risco de crédito* seria agora ampliada para uma maior abrangência segundo a adopção de *ratings* externos ou através de referências de *ratings* internos. Ao mesmo tempo, o então designado por *risco operacional* seria, pela primeira vez, limitado por regulamentação quantitativa. Relativamente a estas duas áreas de risco, a comissão persegue “uma visão futura” (como antes o fez para os riscos de mercado) para assegurar que o novo enquadramento manteria a paz, a par do desenvolvimento do mercado e avanços nas práticas da gestão do risco.

Aos Bancos é-lhes permitido a escolha entre as abordagens standardizadas e as abordagens próprias (internas) mais sofisticadas. Embora estas últimas exijam mais “input” de desenvolvimento, os reguladores têm, entretanto, preferido estes métodos devido à sua maior exactidão e sensibilidade ao risco, encorajando os Bancos a aplicá-los.

O acordo de Basileia II assenta em três pilares:

Pilar 1 – Requisitos de Fundos Próprios Mínimos: Os requisitos de capital mínimo baseados no Risco de Crédito, Risco de Mercado e Risco Operacional têm o objectivo de: a) reduzir o risco de insucesso através da protecção contra perdas; b) permitir o acesso continuado aos mercados financeiros para satisfazer as necessidades de liquidez e; c) proporcionar incentivos a uma gestão de risco prudente (¶¶ 40-718).

Pilar 2 – Processo de Supervisão: A supervisão qualitativa por entidades reguladoras de controlo interno de risco bancário e do acesso ao capital (¶¶ 719-807), incluindo a autoridade no processo de supervisão para poder exigir aos Bancos que detenham mais capital do que era exigido no Pilar 1.

Pilar 3 – Disciplina de Mercado: Novas condições de divulgação pública para compelir a uma melhor gestão de risco bancário (¶¶ 808-822).

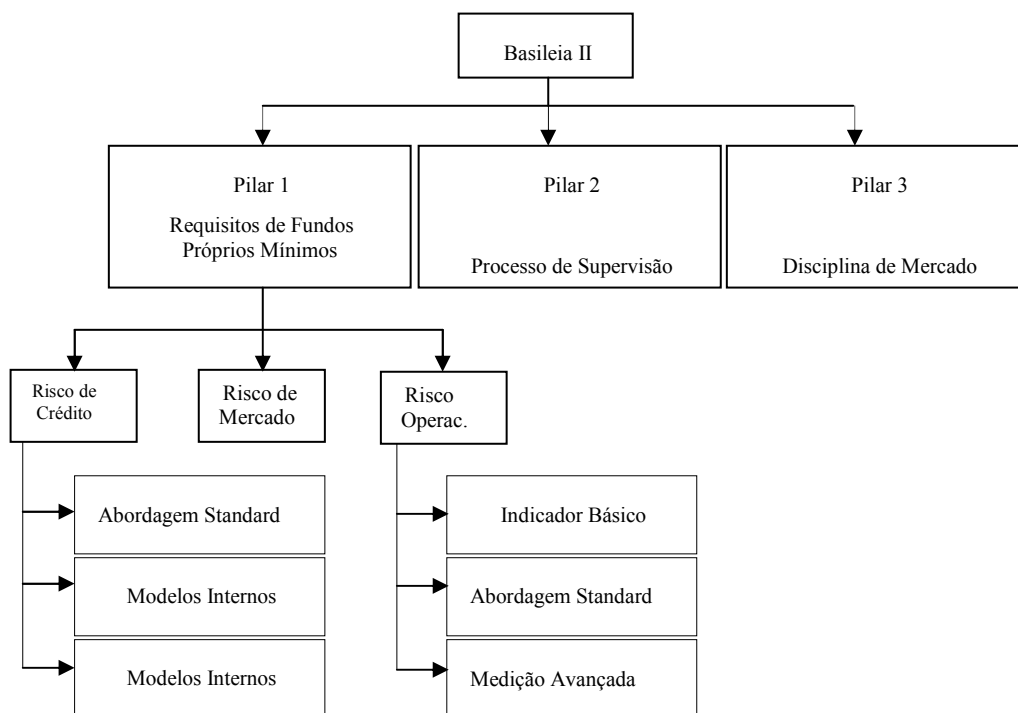


Gráfico nº A1.1 - Os três pilares do Acordo de Basileia II

Nos EUA os recursos e os fluxos internos de um Banco estão tradicionalmente sujeitos a uma auditoria regular. Esta prática que até agora (2007) apenas tem sido utilizada em muitos poucos regimes nacionais (Bancos Centrais) europeus, será o ponto central do 2º pilar do enquadramento de Basileia.

O Processo de Revisão de Supervisão (SRP- *Supervisory Review Process*) determinará o perfil de risco individual de um Banco, ficando sujeito a auditorias locais regulares, examinando-lhe as suas principais capacidades e processos operativos, nomeadamente as suas abordagens próprias (internas) no que concerne o risco de crédito, como acima foi descrito.

Sob o 3º Pilar a Comissão de Basileia procura aumentar a transferência da exposição (ao risco) dos Bancos para que os “marketers” financeiros possam disciplinar os Bancos através das suas condições de retorno.

Contudo, é importante que os *três pilares* sejam tratados como um enquadramento único, em vez de cada um individualmente.

Certos métodos, que procuram avaliar a condição de fundos próprios mínimos (Pilar 1), especialmente naqueles desenvolvidos internamente pelos Bancos, devem ser apenas aplicados desde que tenham sido integralmente auditados pela autoridade supervisora (Pilar 2).

Esta situação só poderá ocorrer desde que o Banco tenha informado os mercados financeiros, da estrutura dos seus sistemas dentro do enquadramento das suas obrigações de divulgação (Pilar 3).

A implementação do novo enquadramento nos membros da União Europeia foi planeada para o final de 2006, embora algumas abordagens avançadas sobre a ponderação de risco ficaram apenas disponíveis no final de 2007 (Capital Adequacy Directive 3 (CAD 3)).

Em larga medida, o CAD 3 segue as regras propostas pela Comissão de Basileia. Contudo, há diferenças. As principais diferenças referem-se ao âmbito de aplicação e à série de abordagens disponíveis para instituições financeiras, ao calcular as suas condições reguladoras de capital.

Em contraste com o enquadramento revisto, que é meramente uma recomendação, o CAD 3 é normativo. É responsabilidade dos Estados membros da União Europeia transpor a directiva para as suas jurisdições nacionais, tornando-a vinculativa em todas as instituições financeiras, que estão domiciliadas na União Europeia. (Dierick et al., 2005).

Agrupamento das exposições ao risco em “pools” como característica principal da abordagem IRB de retalho de Basileia.

Sob o novo enquadramento de regulação de capital de Basileia II permitir-se-á, pela primeira vez, que os Bancos agrupem os seus empréstimos a particulares e a pequenas empresas num “portefólio de retalho”. Como resultado desta acção, poderão calcular melhor as condições exigidas de capital mínimo necessário, para cobertura do risco de crédito destes portefólios de retalho (Paul, 2006).

Ao mesmo tempo que se tem feito um progresso significativo na compreensão do risco de créditos comerciais, tem-se empreendido uma pesquisa muito menor na ponderação (e gestão) do risco de crédito em portefólios de retalho, tanto numa base teórica como numa base prática (Allen et al., 2004), (Claessens et al., 2005).

Esta constatação é surpreendente atendendo à estreita gama de opções que o acordo de Basileia II concede aos Bancos, ao calcular as condições mínimas de capital para os seus portefólios de retalho. E, portanto, não existirá diferenciação entre um requisito basilar (*foundation*) e uma abordagem avançada baseada em classificações internas (IRB- *Internal Ratings Based*) que já se encontra noutras classes de fundos (por ex: portefólios de empresas).

A abordagem de retalho IRB é uma abordagem avançada e, portanto, muito mais exigente.

Em primeiro lugar, as novas directivas determinam que os Bancos devem avaliar todas as variáveis de perda, as quais são introduzidas nas fórmulas de Basileia a fim de determinar a condição mínima de capital necessário para cobrir o risco de crédito. Neste contexto, os Bancos devem recolher dados sobre a probabilidade de incumprimento (PD - *Probability Default*), o incumprimento traduzido em perdas (LGD- *Loss Given Default*) e a exposição ao incumprimento (EAD- *Exposure At Default*).

Em segundo lugar, Basileia II pretende que ao calcularem-se estas variáveis, os Bancos não deverão valorizar as suas reclamações de dívidas individualmente, mas sim agrupá-las por *famílias* homogéneas. Neste pressuposto, exige-se aos Bancos que avaliem as variáveis de perda a fim de obterem a condição de capital necessário, para fazer face aos empréstimos agrupados.

Basileia II não contém instruções vinculativas sobre como os Bancos deverão agrupar empréstimos semelhantes em *famílias* com características homogéneas.

A Comissão de Basileia apenas recomenda que os Bancos considerem pelo menos três *condutores de risco* (secção 402): 1) características do perfil de risco de quem solicita empréstimo; 2) características de risco da transacção (incluindo produto e/ou tipos colaterais) e; 3) delinquência de exposição.

Cada *condutor de risco* deve ser descrito segundo cálculos numéricos (embora Basileia não forneça qualquer informação suplementar sobre a forma de se proceder a esses cálculos numéricos e não estabeleça quaisquer padrões) e para cada *condutor de risco*, pelo menos um dos cálculos numéricos deverá ser incluído no processo de segmentação.

Isto significa que a escolha de construtores de risco adequados e dos respectivos cálculos é deixada ao critério dos Bancos, dando-lhes considerável liberdade. Contudo os

Bancos devem documentar os seus procedimentos para que as autoridades reguladoras os possam examinar, aliás como manifesto no Pilar 2.

Neste ponto, Basileia II oferece novamente um alto grau de flexibilidade na concepção e implementação deste processo de formação de *famílias homogéneas*, significando que não existem especificações vinculativas de supervisão sobre como devem ser construídos os agrupamentos *homogéneas* de risco.

Além do mais, o enquadramento de Basileia não restringe nem a escolha de critérios nem o número de sub-segmentos em que aqueles agrupamentos devem ser feitos.

Os Bancos, além de seleccionarem os cálculos numéricos mais adequados para os *três condutores* de risco anteriormente mencionados, também são livres de identificar outros condutores de risco e construir outros modelos de cálculo, descrevendo-os e incluí-los no processo de formação de grupos por *famílias homogéneas*.

Como condição mínima qualitativa, Basileia apenas estipula que deve existir uma quantidade suficiente de empréstimos num *agrupamento* que permita fazer avaliações dos parâmetros de risco, que sejam estáveis e que possam ser validados estatisticamente.

Depois de um período de transição de três anos, dever-se-ia conservar um historial de dados, abrangendo pelo menos cinco anos. Ao mesmo tempo, seria necessário evitar concentrações excessivas de candidatos a empréstimos, com vista a um determinado nível de risco de crédito (Comissão de Basileia sobre Supervisão de Crédito (2006):secção 406).

Basileia também espera que os Bancos efectuem controlos, pelo menos uma vez por ano, de modo a verificar a validade do processo de segmentação.

A característica central da abordagem IRB para o retalho é a constituição de agrupamentos de risco homogéneos. De acordo com as directivas reguladoras, foi desenvolvida uma “*abordagem de segmentação optimizada*” no que respeita ao caso de incumprimento de crédito, o que permitirá aos Bancos melhorarem a sua ponderação de risco de crédito e a correspondente gestão de recursos de capital próprios.

Lang & Santomero (2002), Gross & Souleles (2002) e Hand (2001), referem as vantagens da utilização de métodos estatísticos na optimização de modelos de *credit scoring*, bem como a dos procedimentos de classificação para identificação de padrões, nos dados do candidato a empréstimo.

Lang & Santomero (2002, pág.19) também consideram que o capital global exigido será menor se as probabilidades de incumprimento (PD) forem calculadas num nível inferior de segmentação.

Abordagens para identificar pools de risco homogéneos

- *Visão geral de métodos matemático-estatísticos para a classificação de empréstimos de retalho*

De um ponto de vista formal, a principal tarefa é obter indicadores sensíveis e selectivos de função de risco a partir de um conjunto de k previsores, $X_1 \dots X_k$, de modo a quantificar o risco de crédito em termos de incumprimento.

No caso do incumprimento ser modelado como uma variável dicotómica Y com as classes ($c_1|c_2$), este cenário representa um problema normal de classificação binária, oferecendo uma ampla gama de algoritmos estandardizados, estabelecidos e bem documentados (Bonne & Armingier, 2001, pág. 199; Hadidi, 2003; Hand & Henley, 1997).

Kaltofen *et al.*(2006) definiram como objectivos para a sua investigação, um incumprimento no pagamento de um empréstimo como uma variável de resposta, na base da qual poderiam calcular a probabilidade média de incumprimento (PD) expressa como o quociente entre os empréstimos em incumprimento e todos os empréstimos em consideração num determinado *agrupamento homogéneo* (ou *família*).

O período de previsão é estabelecido entre os períodos de observação da variável de resposta e os previsores. A sua duração é especificada pelo objectivo do conceito subjacente de pesquisa (neste caso, Basileia II exige um período de um ano).

Assim, com vista a esta classificação, analisam-se: os dados históricos; e as técnicas de classificação que determinam quais os previsores (provenientes de um determinado conjunto de condutores reguladores de risco) que são mais adequados para explicar os atributos da variável de resposta.

Por isso, uma abordagem adequada seria utilizar técnicas de análise discriminante, as quais em geral e independentemente podem ser aplicadas para o objectivo de separar objectos (neste exemplo, estamos a inferir PD de condutores de risco) em (sub-) segmentos mais homogéneos (Bonne & Armingier, 2001, pág. 199).

A capacidade de cada abordagem para distinguir entre exposições com falha e normais depende, aproximadamente de duas questões: 1) a robustez do algoritmo específico aplicado; e 2) a qualidade dos dados incluídos.

Claro que esta última questão requer o armazenamento e manutenção de dados de modo correcto, completo e disponível. Segundo (Bonne & Arminger, 2001, pág. 199), os métodos estatísticos seleccionados deverão estar de acordo com a presença ou ausência de pressupostos de distribuição no que se refere aos valores dos parâmetros das variáveis preditivas. Enquanto os métodos paramétricos exigem aqueles pressupostos (geralmente a assunção de uma distribuição normal $N(\mu;\sigma)$), os métodos não-paramétricos não exigem isso e, portanto, não estão ligados a tais estruturas. Como os pressupostos da distribuição não são frequentemente postas em prática, os métodos não-paramétricos são considerados como os métodos mais robustos (Galindo & Tamayo, 2000, p. 115).

ANEXO 2 – Maximum Likelihood Estimates (MLE)

As estimativas de probabilidade máxima para β satisfazem as seguintes equações:

$$\sum_{i=1}^n w_i (y_i - \hat{\pi}_i) x_{ij} = 0, \quad (\text{A2.1})$$

para o parâmetro j th

Onde:

$$x_{i0}=1 \text{ para } i=1, \dots, n$$

Note-se o seguinte:

- (1) Utiliza-se um algoritmo do tipo Newton-Raphson para se obter o MLE. A convergência pode ser baseada em:
 - a. Diferença absoluta para as estimativas do parâmetro entre as iterações;
 - b. Diferença percentual na função *log-likelihood* entre as sucessivas iterações;
 - c. Número máximo de iterações especificadas.
- (2) Durante as iterações, se $\hat{\pi}_i(1 - \hat{\pi}_i)$ for menor que 10^{-8} para todos os casos, a função *log-likelihood* estará muito próxima de zero. Nesta situação, as iterações cessam.

Depois de se obterem as estimativas da probabilidade máxima para $\hat{\beta}$, a matriz da covariância assintótica é estimada por I^{-1} , o inverso da matriz de informação I , em que:

$$I = - \left[E \left(\frac{\delta^2 L}{\delta \beta_i \delta \beta_j} \right) \right] = \mathbf{X}' \mathbf{W} \hat{\mathbf{V}} \mathbf{X}, \quad (\text{A2.2})$$

$$\hat{\mathbf{V}} = \text{Diag}[\hat{\pi}_1(1 - \hat{\pi}_1), \dots, \hat{\pi}_n(1 - \hat{\pi}_n)], \quad (\text{A2.3})$$

$$\mathbf{W} = \text{Diag}(w_1, \dots, w_n), \quad (\text{A2.4})$$

$$\hat{\pi}_i = \frac{\exp(\hat{\mu}_i)}{1 + \exp(\hat{\mu}_i)} \quad (\text{A2.5})$$


e

$$\hat{\mu}_i = X_i' \hat{\beta}. \quad (\text{A2.6})$$

ANEXO 3 – European Payment Index 2008

http://www.europeanpayment.com/11_ENG_R.asp

IN BRIEF



Intrum Justitia, Europe's leading provider of Credit Management Services, annually surveys thousands of companies in 25 European countries on a variety of payment risk issues. The information gathered is used to better understand national and Pan-European payment risk relating to consumers and businesses alike.

Summary of the results for 2008

The 2008 Intrum Justitia Payment Risks Survey indicates that payment risks among consumers, businesses and public authorities are expected to deteriorate over the next 12 months, despite the stabilisation seen during 2007 on a Pan-European level.

The evidence indicates that the fundamental changes required to combat late payment are still missing in the majority of countries.

The economic uncertainty facing Europe in 2008 due to the credit crunch and rising oil and food prices points to a period ahead when it will be even harder to get paid on time.

Payment risks have already increased in Switzerland, Spain, Italy, Ireland and France. The Nordic countries remain at their traditional low levels of payment risk, while the UK remains relatively stable.

The actual survey was implemented during January and February 2008, so the broader effects of the US credit crunch have yet to fully reveal their impact on the European economy.

Payment duration decreased on a Pan-European level compared to previous years.
 59,2 days in 2006
 58,6 days in 2007
 55,5 days in 2008

Regional development	Payment duration in days 2008	2007	2006
Sweden, Norway, Denmark, Finland	51.8	51.0	50.0
France, Belgium, The Netherlands	56.5	59.5	56.0
UK, Ireland	52.0	51.0	51.0
Germany, Austria, Switzerland	48.0	48.5	48.0
Estonia, Latvia, Lithuania	58.9	57.4	58.0
Portugal, Spain, Italy	51.5	51.1	51.0
Poland, Czech Republic, Hungary	44.0	45.5	45.0

Portugal, Greece and Cyprus are the countries where it takes longest to be paid, while the fastest is Finland followed by the other Nordic countries.

Payment delay increased from 16 days in 2007 to 17 days in 2008 - the highest level since 2004.

All three customer groups (Consumer, Business and Public Sector) contributed to the positive trend in payment duration, although strong regional and local differences exist. Still the public sector is the latest payer in many countries, with rather long delays in payment.

Pan-European level	Payment duration in days	
	2007	2008
Consumer	42.0	40.0
Business	58.0	55.5
Public Sector	98.0	93.0

Payment loss

Unfortunately the payment loss increased on a Pan-European level from 1,9% in 2007 to 2,0% in 2008. In 10 countries the payment loss increased. The lowest payment loss was measured in Finland (0,6%) and the highest in Lithuania and Czech Republic both 3%.


Regional development	Payment duration in days 2008	2007	
		2007	2008
Sweden, Norway, Denmark, Finland	31.0	31.0	30.0
France, Belgium, The Netherlands	52.5	52.5	52.0
UK, Ireland	50.0	51.0	51.0
Germany, Austria, Switzerland	48.0	48.0	45.0
Estonia, Latvia, Lithuania	60.0	57.4	54.0
Portugal, Spain, Italy	61.5	61.1	61.0
Poland, Czech Republic, Hungary	44.8	45.0	45.0

Trend in payment risks

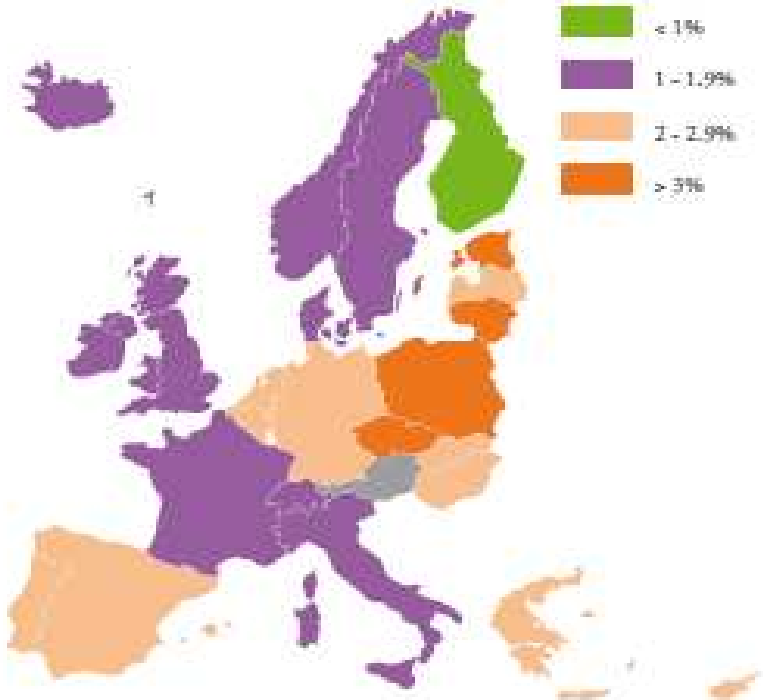
Some 55% of the companies surveyed believe that payment risks will remain the same, while 30% expect it to get harder to receive payment. Businesses in Hungary, Ireland, Portugal and Spain are the most pessimistic.

Risk development is rather stable, a worrying fact for now

From a Pan-European perspective, according to the 2008 survey, the late payment trend has largely stabilised. In some countries, the risks decreased slightly, while in others there has been slight or no increase. However, this is actually of great concern against the background of current economic uncertainty due to external risk factors such as the credit crunch and oil and food price increases. The pan-European average for the amount of time to receive payment decreased from 58.6 to 55.5 days in 2008.









Payment loss



EUROPEAN PAYMENT INDEX

Risk Index	Explanation of the Risk Index values
100	No payment risk, cash payments, payment at delivery or pre-payment, no credit
101-124	Stay alert to keep present situation
125-149	Intervention necessary
150-174	Intervention inevitable, take measures to lower the risk profile
175-199	Intervention emergency, take measures to lower risk profile
> 200	Case of emergency, take measures to lower risk profile

Legend

	120 - 129
	130 - 139
	140 - 149
	150 - 159
	160 - 169
	More than 170



COUNTRY REPORTS

Risk profile

For each country, you will find an individual risk profile. In a easy to read way, the profile shows the basic criteria for the overall assessment of payment risks (Payment Index).

Explanation of risk indicators:

Duration	Calculation of the effective payment duration in days.
Delay	Calculation of the absolute duration of delay in days as well as in relation to the agreed payment term.
DSO	Calculation of the individual age groups in relation to the total value of the outstanding receivables. The different lengths of the contractually agreed payment terms are taken into consideration when assessing the age structure.
Loss	Calculation of the declared payment losses.
Forecast	Calculation of the forecast, prepared by the companies questioned, on how the payment risks are anticipated to develop.
Consequences	Calculation of the consequences stated by the companies of the payment risks for their company.

Please note the explanation below for a better understanding of the Payment Index.

Payment Index

The payment index is used to compare different economies, regions or sectors. Alongside technical financial figures, the index is based on assessments from the companies surveyed. The data forming the basis of the index is generated yearly using a standardised written panel survey. List of basic data elements: Contractual payment term (in days); Effective payment duration (in days); Age structure of receivables (DSO); Payment loss (in %); Estimate of risk trends; Characterisation of the consequences of late payment; Causes of late payment. The Payment Index is calculated from eight differently weighted sub-indices, which are based on a total of 21 individual values.

Payment Index - Implications for Credit Policy

100	no payment risks, i.e. payments are made in cash, on time (or in advance) and without any credit
101 - 124	preventive actions - measures to secure the current situation are recommended
125 - 149	need to take action
150 - 174	strong need to take action
175 - 199	major need to take action
over 200	urgent need to take action

PORTUGAL



Economic Development (%)

	US \$1,000 (2007)	Average EU27
GDP per capita	15	25
GDP growth	1.5	2.9
Unemployment rate	8.0 (2007)	6.6
Inflation	2.4 (2007)	2.1

Portugal's economy remains sluggish. The Portuguese economy continues to grow at the slowest rate in the whole of Europe. There was a continuing if slight increase from a low in 2005 (0.5%) to 2007 (1.5%), but the global downturn has stopped this rise and the forecast is for the economy to fall during 2008 (1.7%).

In terms of GDP per capita, since 2000 the Czech Republic, Greece, Malta and Slovenia have all overtaken Portugal. The country's GDP per head has fallen from just over 80% of the EU 25 average in 1999 to just over 70% last year. It is projected to fall to 65% in 2008.

There are numerous reasons for Portugal's poor economic performance, but a key factor has been the attractiveness of lower-cost producers in Central Europe and Asia. Last year's slight upturn was due to investment growth of 3.2% along with an increase in private consumption.

Payment: Behaviour and Risks

Risks have increased compared with 2007. The share of receivables has a better balance than last year with 49.6% being paid within 60 days but the payment loss increased from 2.3% to 2.7%. The average payment duration decreased in all segments, but is still among the highest in Europe.

	Consumer B2C	Business B2B	Public Authorities
Average payment term in days	54.1	47.1	57.4
Average payment duration in days	50.9	46.1	107.6
Average delay in days 2008	19.2	33.0	40.4
Average delay in days 2007	22.8		

Of the business participants that responded, 52% believe that the risk of late customer payments will remain the same while 40% think it will rise. 22% of respondents said they will need more financial staff in the coming 12 months.

Payment Index

2004	151
2005	154
2006	150
2007	152
2008	150

Share of receivables (%)

	Up to 30 days	31 to 60 days	Older than 60 days
2004	18.8	49.4	31.8
2005	19.4	49.8	30.8
2006	19.5	49.9	30.6
2007	20.9	52.2	26.9
2008	25.1	50.9	24.0

Payment loss (%)

	total turnover
2004	2.3
2005	2.4
2006	2.7
2007	2.5
2008	2.7

Main export

	Risk Index
Spain	138
Italy	158
UK	151
Germany	150
Netherlands	149
France	148