

CREDIT SCORING APLICADO AO SEGMENTO EDUCACIONAL



Marcelo José Vieira de Melo Sobrinho



EDITORA CONHECIMENTO LIVRE

Marcelo José Vieira de Melo Sobrinho

Credit Scoring aplicado ao segmento educacional

1ª ed.

Piracanjuba-GO
Editora Conhecimento Livre
Piracanjuba-GO

1ª ed.

Dados Internacionais de Catalogação na Publicação (CIP)

Melo Sobrinho, Marcelo José Vieira de
M528C Credit Scoring aplicado ao segmento educacional
/ Marcelo José Vieira de Melo Sobrinho. – Piracanjuba-GO

Editora Conhecimento Livre, 2022

108 f.: il

DOI: 10.37423/2022.edcl531

ISBN: 978-65-5367-132-4

Modo de acesso: World Wide Web

Incluir Bibliografia

1. risco-de-crédito 2. credit-scoring 3. instituições-educacionais I. Melo Sobrinho, Marcelo José
Vieira de II. Título

CDU: 658

<https://doi.org/10.37423/2022.edcl531>

O conteúdo dos artigos e sua correção ortográfica são de responsabilidade exclusiva dos seus respectivos autores.

EDITORA CONHECIMENTO LIVRE

Corpo Editorial

Dr. João Luís Ribeiro Ulhôa

Dra. Eyde Cristianne Saraiva-Bonatto

MSc. Frederico Celestino Barbosa

MSc. Carlos Eduardo de Oliveira Gontijo

MSc. Plínio Ferreira Pires

Editora Conhecimento Livre

Piracanjuba-GO

2022



10.37423/2022.edcl531



O conteúdo deste livro foi desenvolvido inicialmente em formato de dissertação, apresentada como requisito complementar para obtenção do grau de Mestre em Administração, na área de concentração Gestão Organizacional, do Programa de Pós- Graduação em Administração da Universidade Federal de Pernambuco, sob orientação do Prof. Dr. Charles Ulises de Montreuil Carmona.

LISTA DE FIGURAS

Figura 1 (2) Função de distribuição acumulada.....	38
Figura 2 (2) Rede neural artificial <i>perceptron</i> multicamadas.....	43

LISTA DE TABELAS

Tabela 1 (2) Modelo de pontuação de crédito baseado na probabilidade histórica.....	26
Tabela 2 (3) Atrasos ocorridos em 2006.....	51
Tabela 3 (3) Lista de variáveis dicotômicas.....	56
Tabela 4 (3) Lista de variáveis dicotômicas históricas.....	57
Tabela 5 (4) Teste de normalidade.....	62
Tabela 6 (4) Teste de normalidade das variáveis transformadas.....	63
Tabela 7(4) Modelo de aprovação de crédito preliminar - análise discriminante	64
Tabela 8(4) Teste de heterocedasticidade de White, aprovação de crédito –análise discriminante..	64
Tabela 9 (4) Modelo de aprovação de crédito - análise discriminante.....	65
Tabela 10 (4) Centróides e parâmetros para classificação do modelo de aprovação de crédito - análise discriminante.....	65
Tabela 11 (4) Teste de fator inflação de variância, aprovação de crédito – análise discriminante.....	66
Tabela 12 (4) Modelo de <i>behavioral scoring</i> preliminar - análise discriminante.....	70
Tabela 13 (4) Teste de heterocedasticidade de White, <i>behavioral scoring</i> – análise discriminante.....	70
Tabela 14 (4) Modelo de <i>behavioral scoring</i> - análise discriminante.....	71
Tabela 15 (4) Teste de fator inflação de variância para <i>behavioral scoring</i> – análise discriminante..	71
Tabela 16 (4) Centróides e parâmetros para classificação do modelo de <i>behavioral scoring</i> – análise discriminante.....	72
Tabela 17 (4) Modelo de aprovação de crédito - regressão logística.....	74
Tabela 18 (4) Teste de Hosmer-Lemeshow , aprovação de crédito - regressão logística.....	77
Tabela 19 (4) Modelo <i>behavioral scoring</i> - regressão logística.....	78
Tabela 20 (4) Teste de Hosmer-Lemeshow, <i>behavioral scoring</i> - regressão logística.....	80
Tabela 21 (4) Partição das amostras para RNA.....	80
Tabela 22 (4) Modelo de aprovação de crédito - RNA.	82
Tabela 23 (4) Análise de sensibilidade, modelo de aprovação de crédito - RNA.....	84

Tabela 24 (4) Resultado da RNA com variáveis suprimidas - aprovação de crédito.....	85
Tabela 25 (4) Modelo <i>behavioral scoring</i> - RNA.....	86
Tabela 26 (4) Análise de sensibilidade, modelo de <i>behavioral scoring</i> - RNA.....	87
Tabela 27 (4) Resultado da RNA com variáveis suprimidas - <i>behavioral scoring</i>	87
Tabela 28 (4) Matriz de classificação do modelo de aprovação de crédito – análise discriminante..	88
Tabela 29 (4) Matriz de classificação do modelo <i>behavioral scoring</i> - análise discriminante.....	88
Tabela 30 (4) Matriz de classificação do modelo de aprovação de crédito – regressão logística.....	90
Tabela 31 (4) Matriz de classificação do modelo <i>behavioral scoring</i> - regressão logística.....	90
Tabela 32 (4) Matriz de classificação do modelo de aprovação de crédito - redes neurais.....	92
Tabela 33 (4) Matriz de classificação do modelo <i>behavioral scoring</i> - redes neurais.....	92
Tabela 34 (5) Resumo da capacidade preditiva dos modelos.....	96

LISTA DE QUADROS

Quadro 1 (2) Lista de agências de <i>rating</i>	30
Quadro 2 (3) Lista inicial de variáveis consideradas no estudo.....	54
Quadro 3 (3) Lista de variáveis transformadas apresentando categoria ordinal.....	54

Lista de Abreviaturas

ADL -Análise discriminante linear.

APTO -Reside em apartamento.

BAIROCAT- Categoria dos bairros.

CELM- Celular da mãe.

CELP- Celular do pai.

CONTRATO- Existência de contrato.

DATA CAT- Categoria das datas de pagamentos.

DESCP- Desconto percentual na mensalidade.

DUMMY 2004- Débitos no ano de 2004.

DUMMY 2005- Débitos no ano de 2005.

EMPPAI- Emprego do pai.

EMPRM- Emprego da mãe.

FONEC- Telefone residencial.

FUNCM- Função exercida pela mãe.

FUNCPAI -Função exercida pelo pai.

INSTMAE- Instrução da mãe.

INSTPAI-Instrução do pai.

IRMAOS- Quantidade de irmãos.

PSAUDE- Plano de saúde.

PUBM- Mãe possui emprego público.

PUBP- Pai possui emprego público.

Sumário

1 INTRODUÇÃO.....	11
1.1 APRESENTAÇÃO DO TEMA	11
1.2 JUSTIFICATIVA.....	13
1.3 PROBLEMA DE PESQUISA.....	14
1.4 OBJETIVOS	15
1.4.1 OBJETIVO GERAL	15
1.4.2 OBJETIVOS ESPECÍFICOS	15
2 REFERENCIAL TEÓRICO.....	15
2.1 RISCO DE CRÉDITO	15
2.2 POLÍTICA E ANÁLISE DE CRÉDITO	17
2.3 TÉCNICAS DE GERENCIAMENTO DO RISCO DE CRÉDITO	20
2.3.1 SISTEMAS ESPECIALISTAS	20
2.3.2 CREDIT SCORING	25
2.3.3 RATING	29
2.4 TÉCNICAS APLICADAS AOS MODELOS DE CREDIT SCORING.....	33
2.4.1 ANÁLISE DISCRIMINANTE.....	34
2.4.2 MODELOS DE ESCOLHA DISCRETA, LOGIT E PROBIT	38
2.4.3 REDES NEURAIS.....	42
3 METODOLOGIA	48
3.1 TIPO DE PESQUISA	48
3.2 HIPÓTESE	49
3.3 POPULAÇÃO E AMOSTRA	49
3.4 COLETA DE DADOS	50
3.5 DEFINIÇÃO DE INADIMPLÊNCIA	51
3.6 DEFINIÇÃO DAS VARIÁVEIS	53
3.7 MEDIDAS DE AJUSTAMENTO DOS MODELOS E SOFTWARE.....	58
4 RESULTADO	61

4.1 MODELOS DESENVOLVIDOS	61
4.1.1 ANÁLISE DISCRIMINANTE	62
4.1.1.1 ANÁLISE DISCRIMINANTE – APROVAÇÃO DE CRÉDITO	62
4.1.1.2 ANÁLISE DISCRIMINANTE – BEHAVIORAL SCORING	70
4.1.2 REGRESSÃO LOGÍSTICA	75
4.1.2.1 REGRESSÃO LOGÍSTICA - APROVAÇÃO DE CRÉDITO	75
4.1.2.2 REGRESSÃO LOGÍSTICA – BEHAVIORAL SCORING	79
4.1.3 REDES NEURAIS ARTIFICIAIS	81
4.1.3.1 REDE NEURAL - APROVAÇÃO DE CRÉDITO	82
4.1.3.2 REDE NEURAL - BEHAVIORAL SCORING	86
4.1.4 COMPARAÇÃO ENTRE A CAPACIDADE PREDITIVA DOS MODELOS	89
4.1.4.1 MATRIZES DE CLASSIFICAÇÃO DOS MODELOS DE ANÁLISE DISCRIMINANTE	89
4.1.4.2 MATRIZES DE CLASSIFICAÇÃO DOS MODELOS DE REGRESSÃO LOGÍSTICA	91
4.1.4.3 MATRIZES DE CLASSIFICAÇÃO DO MODELO DE REDE NEURAL	93
4.1.5 VANTAGENS E DESVANTAGENS DA UTILIZAÇÃO DOS MODELOS DE CREDIT SCORING	94
5 CONCLUSÕES	96
5.1 CONSIDERAÇÕES SOBRE OS RESULTADOS OBTIDOS	96
5.2 LIMITAÇÕES ENCONTRADAS E SUGESTÕES PARA FUTURAS PESQUISAS	99
REFERÊNCIAS	102

1 INTRODUÇÃO

1.1 APRESENTAÇÃO DO TEMA

A incerteza presente no ambiente empresarial torna o risco um aspecto inerente no desempenho das atividades para os participantes do mercado, indistintamente de suas peculiaridades individuais, setoriais ou geográficas. A incerteza surge em decorrência da incapacidade humana em prever com absoluta certeza os eventos que estão por vir. Como menciona Assaf Neto (2003) as decisões empresariais estão direcionadas para um futuro no qual pouco se conhece, onde se torna necessário introduzir um elemento de incerteza na tomada de decisão. Uma vez que esta incerteza pode ser mensurada é possível afirmar que uma deliberação é tomada sob um ambiente de risco.

Os riscos aos quais uma empresa está exposta, segundo Prado, Bastos e Duarte Júnior (2000), podem ser provenientes de diversas fontes como o risco de mercado, operacional, de crédito, entre outros. É a possível vulnerabilidade a estes fatores que estimula as empresas a monitorar o ambiente no qual estão inseridas, de modo que possam desenvolver métodos para minimizar possíveis ameaças e transformá-las em um diferencial competitivo. Como ressalta Jorion (2000) uma exposição a riscos de modo cauteloso e estratégico torna-se preponderante para o êxito comercial.

Diante das incertezas do mercado é que os modelos estatísticos surgem como uma ferramenta de fundamental importância para o gerenciamento eficaz do risco.

O presente trabalho é direcionado especificamente para o risco de crédito. Este segmento do conhecimento científico tem tomado crescente significância e atraído cada vez mais a atenção da comunidade acadêmica, e dos participantes do mercado, pela sua aplicabilidade na proteção dos agentes econômicos. No Brasil este tema começou a receber maior atenção a medida que o Plano Real, implantado em 1994, possibilitou o deslocamento dos recursos disponíveis no país, até então direcionados para a especulação financeira e financiamento da dívida interna devido ao processo inflacionário descontrolado, para atividades produtivas através da concessão de crédito (PRADO; BASTOS; DUARTE JR., 2000).

Entre as instituições que predominantemente são caracterizadas pela atividade financeira, o gerenciamento do risco de crédito desempenha um papel primordial, pois está associado a atividade principal da instituição. Problemas na carteira de crédito de empresas dessa natureza possuem uma relação negativa direta com seu desempenho financeiro. Deste modo existe uma preocupação e uma cultura orientada para o gerenciamento do risco. Por outro lado, para instituições que não tem na

concessão de crédito um dos objetivos primordiais da organização, o risco de crédito apresenta-se como um desafio adicional, pois não há uma competência estabelecida que possa viabilizar uma análise de crédito de maneira confiável e precisa, nos termos da necessidade de cada usuário.

Um segmento que historicamente não tem direcionado esforços suficientes para o gerenciamento do risco de crédito é o educacional, fato este que pode ser percebido pelo crescente nível de inadimplência que o setor tem enfrentado nos últimos anos, segundo o Sindicato das Escolas Particulares de Pernambuco (2006).

Diferentemente de outros tipos de empreendimento, aqueles direcionados para a área educacional trabalham com a prestação de serviços, o que difere bastante dos empreendimentos que recorrem a oferta de recursos monetários ou fornecimento de bens físicos e que são objeto de estudo para pesquisas de inadimplência com maior frequência, como os trabalhos de Thomas (2000), Lee e Jung (2000), Cia (2001) e Almeida e Passari (2005). No entanto, o fornecimento de um serviço educacional e sua contraprestação pecuniária também pode ser percebida como um crédito, onde a instituição arca com os custos de manutenção da estrutura, remuneração de funcionários, entre outras despesas, durante o mês e espera ser remunerada ao final deste período.

Recentemente este setor tem sido severamente penalizado pela inadimplência de seus clientes. Em 23 de novembro 1999 foi sancionada a lei 9.870 limitando os meios que estavam disponíveis as estas instituições para exigir o pagamento pela contraprestação de seus serviços. Esta lei vedou a suspensão da prestação dos serviços pela inadimplência por parte do cliente, e ao mesmo tempo não permite que a documentação do inadimplente fique retida. Estas medidas funcionam como um mecanismo que não prima pelo incentivo ao cumprimento do pagamento das mensalidades, e colocam como única medida cabível recorrer a cobrança no âmbito judicial.

O gerenciamento do risco de crédito não é uma área relativamente nova, por outro lado o levantamento bibliográfico realizado neste estudo demonstrou que não existem muitos estudos que se propõe a trabalhar com o desenvolvimento de modelos direcionados para empresas não financeiras. Sendo assim, o presente trabalho destina-se a verificar a possibilidade de implantação de modelos de risco de crédito em instituições de ensino, comparando o desempenho dos modelos entre diferentes metodologias de estimação.

Um trabalho neste sentido tem como função principal auxiliar instituições que historicamente não gerenciam seu risco de inadimplência de maneira ativa, e possibilitá-las uma administração financeira mais sadia.

1.2 JUSTIFICATIVA

A estabilização econômica obtida após a implantação do plano Real é tida como um marco na concessão de crédito para a realidade brasileira, pois permitiu a transferência de recursos do financiamento da dívida interna para atividades produtivas (PRADO; BASTOS; DUARTE JR, 2000). Deste modo, a atenção despendida à administração do risco de crédito tem tomado volume para corresponder as expectativas da crescente demanda por recursos.

O foco desta preocupação tem sido primordialmente direcionada, tanto pelo meio acadêmico como pelos agentes de mercado, para o desenvolvimento de modelos de risco de crédito relacionados para a concessão de recursos na forma de empréstimos, para pessoas físicas e jurídicas, ou para a previsão de concordatas que se configura como um caso específico de risco de crédito, onde há a possibilidade do não recebimento do capital investido.

Como comenta Amorin Neto (2000) a concessão de crédito extrapolou os limites bancários e permeia diversas atividades empresariais como: cooperativas de crédito, empresas de cartões de crédito e o comércio em geral. Para instituições financeiras a análise minuciosa dos riscos inerentes a concessão de empréstimos faz parte do corpo de suas atividades principais, por isso existe uma maior concentração no número de trabalhos para este segmento. No entanto, outras atividades empresariais têm percebido a necessidade de gerenciar melhor sua carteira de crédito.

O segmento educacional é uma destas áreas que não tem na concessão de crédito sua atividade principal e que tem percebido a duras penas a necessidade de desenvolver métodos de se precaver contra as altas taxas de inadimplência que tem enfrentado. Segundo o Sindicato das Escolas Particulares de Pernambuco (2006) o percentual de alunos da rede particular em situação de inadimplência alcançou o patamar médio de 35% no ano de 2005.

Poucos trabalhos que enfocam a concessão de crédito por parte de instituições não financeiras têm sido desenvolvidos, e mais especificamente para a área educacional não há registro de estudos deste tipo na literatura financeira nacional. Sendo assim a elaboração de um estudo nesta área contribuiria para o desenvolvimento e expansão do conhecimento do risco de crédito.

Torna-se especialmente relevante desenvolver um estudo sobre o risco de crédito para que as instituições de ensino situadas na cidade do Recife possam obter uma ferramenta que os permita gerenciar eficazmente o risco de inadimplência.

1.3 PROBLEMA DE PESQUISA

A questão da inadimplência, para as instituições do segmento educacional atuantes no estado de Pernambuco, tem se tornado cada vez mais crítica e alguns fatores tem se tornado preponderantes para esta situação. A redução do poder aquisitivo das famílias que habitualmente mantêm seus filhos em escolas particulares tem sido um deles. Como um reflexo desta situação, segundo a Secretaria Estadual de Educação (2006), em 1996 as escolas particulares correspondiam a 14,4% dos alunos matriculados no ensino médio em todo o estado, já em 2005 este percentual foi reduzido a 12,3%. Associado a este fato está o aumento do número de escolas funcionando regularmente na região; dados da Secretaria de Educação (2006) indicam que nos dois últimos anos 392 novas escolas iniciaram suas atividades atingindo o número total de 2.549, aumentando assim o número de vagas disponíveis ao mesmo tempo em que o número de alunos foi reduzido. A soma de todos estes fatores desencadearam um fluxo de inadimplência no setor que tem atingido a marca de 35%, segundo dados do Sindicato dos Estabelecimentos de Ensino do Estado de Pernambuco (2006).

Como mencionado anteriormente a sanção da lei 9.870 tornou ainda mais crítica a inadimplência nas escolas particulares, limitando os meios disponíveis para que estas cobrassem as dívidas que lhes são devidas. A consequência desta lei, que visa preservar o direito a educação dos alunos, é que não há um incentivo para que os responsáveis pelo pagamento dos serviços educacionais mantenham as mensalidades quitadas, pois as sanções disponíveis, a partir de então, recaem apenas na esfera jurídica.

Por não fazer parte de seu objetivo principal, as instituições de ensino historicamente tem tornado a administração do risco de crédito como uma atividade secundária. As poucas instituições que realizam alguma atividade neste sentido limitam-se apenas a consultas ao Serviço de Proteção ao Crédito (SPC) e ao Serasa, sem que, no entanto, haja uma real intenção de limitar o acesso aos serviços da empresa.

É diante deste contexto que a inadimplência tem se tornado uma questão de suma importância para as instituições de ensino, e a modelagem estatística, mais especificamente o credit scoring, apresenta-se como uma possível alternativa para superar as limitações legais, ao passo que possibilita o gerenciamento ativo do risco de crédito.

Deste modo foi formulada a seguinte questão de pesquisa que norteou o desenvolvimento do presente trabalho: A utilização de modelos de credit scoring constitui-se em uma alternativa viável

para identificar o risco de inadimplência dos clientes da instituição pesquisada, atuante no ensino privado de nível médio e fundamental, localizada na cidade do Recife?

1.4 OBJETIVOS

Os pontos que delinearão este trabalho, e contribuirão para responder a pergunta de pesquisa são sistematizados nos seguintes objetivos:

1.4.1 OBJETIVO GERAL

Avaliar se a utilização de modelos de credit scoring constitui-se em uma alternativa viável para identificar o risco de inadimplência dos clientes da instituição pesquisada, atuante no ensino privado de nível médio e fundamental, localizada na cidade do Recife.

1.4.2 OBJETIVOS ESPECÍFICOS

- Realizar uma revisão teórica sobre os principais modelos de avaliação de risco de crédito e suas principais aplicações, limitações e benefícios;
- Captar e estruturar um banco de dados com as variáveis que sejam capazes de refletir a capacidade creditícia dos clientes da instituição de ensino;
- Aplicar modelos de credit scoring que identifiquem a possibilidade de que os clientes tornem-se inadimplentes;
- Realizar uma comparação entre os diferentes resultados obtidos com os métodos utilizados na construção dos modelos, verificando o desempenho de cada um na previsão de inadimplência;
- Avaliar as possíveis contribuições de cada modelo na prevenção do risco de crédito para as instituições de ensino.

2 REFERENCIAL TEÓRICO

2.1 RISCO DE CRÉDITO

No contexto financeiro o termo crédito é freqüentemente reconhecido como “a entrega de um bem ou de um valor presente mediante a promessa de pagamento em data futura” (SILVA, 1998, p.64). Deste modo é possível perceber que o crédito está intimamente associado à concessão de recursos monetários por instituições financeiras, além de apresentar-se como uma ferramenta capaz de propiciar a aquisição de bens físicos.

A forte associação com as instituições financeiras, percebida nas principais obras de referência sobre risco de crédito, como Altman et al (1977), Altman (1968), Ohlson (1980), Beaver (1966), entre

outros, é em grande parte decorrente do fato de que o fornecimento de recursos integra uma das principais atribuições das instituições financeiras e conseqüentemente compõe uma das fontes de recursos.

Para o comércio e a indústria, o crédito assume um papel de facilitador da venda, permitindo ao consumidor ter acesso a um produto ao qual não dispõe da totalidade dos recursos de maneira imediata e ao mesmo tempo permite alavancar as vendas do comerciante. (SILVA, 1998).

No entanto, o crédito é um instrumento bastante versátil, capaz de integrar qualquer atividade remunerada. Sendo assim, perceber o crédito sob a perspectiva apresentada anteriormente, limita sua utilização a possibilidade de acesso a valores monetários e a bens de consumo. Alguns autores como Securato (2002) expandem a caracterização do crédito para estabelecer uma relação mais ampla envolvendo quaisquer dois entes, um na posição de doador e outro de tomador de recursos, mesmo que o lastro da operação seja uma mercadoria ou serviço.

Na caracterização do autor supra mencionado, o fornecimento de um bem ou serviço, desde que pago em uma data futura, deve ser reconhecido como uma espécie de financiamento, pois a empresa estará abrindo mão de receber a remuneração na data presente pela promessa de pagamento posterior.

Santos (2003) afirma que uma vez que a concessão de crédito pressupõe um compromisso de pagamento em data futura existe uma possibilidade de que esta contra prestação não se verifique, dando origem ao risco de crédito.

O risco é comumente caracterizado como a incerteza quanto a ocorrência de determinado resultado, ou mais especificamente, como a dispersão em relação a um valor médio esperado (ASSAF NETO, 2003).

Deste modo o risco de crédito se configura como uma situação em que as partes envolvidas na relação de crédito não desejam ou não são capazes de cumprir suas obrigações contratuais (JORION, 2003).

Diante desta possibilidade de perda é que as instituições, sejam elas financeiras ou não, sentem, cada vez mais, a necessidade de ter acesso a mecanismos que as possibilitem um gerenciamento ativo de seus riscos.

O segmento de serviços é uma área que chama a atenção por freqüentemente ser marginalizada nos estudos e livros que se dedicam ao gerenciamento do risco de crédito, por esta razão é que este

trabalho será dedicado ao estudo das peculiaridades específicas dos serviços educacionais como uma maneira de suprir a lacuna existente na literatura e contribuir para seu desenvolvimento teórico e empírico.

2.2 POLÍTICA E ANÁLISE DE CRÉDITO

O crédito está inserido nas mais diversas atividades econômicas, funcionando como um mecanismo facilitador das relações de troca, viabilizando investimentos dispendiosos, aumentando o nível de atividades das empresas, permitindo o acesso a bens e serviços ou ainda podendo funcionar como um indutor de poupança. Desta maneira é que Securato (2002) afirma que o crédito desempenha um papel social de extrema importância para o sistema econômico.

No entanto, o estabelecimento da política de crédito também deve ser vista como uma questão específica de cada empresa e particularmente importante, pois determina o nível de risco ao qual está disposta a se expor, que por sua vez desenvolve papel determinante no desempenho financeiro da empresa.

Segundo Securato (2002) a política de concessão de crédito assume um papel estratégico no desenvolvimento das atividades empresariais. O autor complementa que ao estabelecer sua política creditícia a empresa deve estar ciente de algumas questões internas a empresa e que devem ser consideradas, assim como o potencial reflexo sobre o seu desempenho, são elas:

O volume de vendas: dependendo da sensibilidade da demanda à disponibilidade de recursos, uma política de crédito mais flexível ou mais restritiva, quanto a dilatação dos prazos, tem o poder de influenciar o volume de vendas. Assim devem ser consideradas na análise da política de crédito as capacidades instalada e ociosa da empresa.

Estrutura de custos da empresa: a composição dos custos da empresa também se configura como um fator importante no estabelecimento da política de crédito, uma vez que é preciso adequar o tempo dos pagamentos das despesas incorridas no fornecimento do serviço ou produto com o tempo dos rendimentos que serão recebidos ao longo do prazo estipulado para o financiamento.

Custos dos investimentos em valores a receber: os critérios para definição do financiamento devem refletir o custo de captação dos recursos investidos na elaboração do objeto financiado, ou seja, devem estar embutidos no crédito os juros pagos pelos recursos de terceiros, ou no caso de recursos próprios, o custo de oportunidade que o dinheiro poderia estar rendendo em outros empreendimentos.

Custo com incobráveis: os custos incorridos no procedimento de cobrança dos inadimplentes, assim como as perdas procedentes de produtos não resgatáveis são itens significativos no estabelecimento da política de crédito por interferirem diretamente no desempenho final da empresa. Este tipo de situação torna-se ainda mais crítica quando se trata de serviços pela própria intangibilidade do negócio.

Todos estes fatores são determinantes sobre a capacidade de concessão de crédito que por sua vez influencia o nível de risco ao qual a empresa estará incorrendo. Como mencionado anteriormente o crédito tornou-se uma ferramenta que não se restringe mais as instituições financeiras, e sendo assim, para algumas áreas de negócio disponibilizar a opção de financiamento apenas se configura como um requisito mínimo, uma característica qualificadora, que as capacita a se tornar competitiva e participar do mercado.

Deste modo, é que a vulnerabilidade ao risco de crédito tem se tomado cada vez mais presente no mundo dos negócios estimulando as empresas a monitorar o ambiente na qual estão inseridas de modo que possam desenvolver métodos para minimizar possíveis ameaças inerentes a suas atividades.

É neste contexto que a análise de crédito é percebida como um forte aliado da política de concessão de crédito na tentativa da obtenção do êxito comercial. A análise do risco de crédito consiste justamente em um instrumento que permite as empresas avaliarem a capacidade creditícia daqueles que solicitam financiamento e fornecem uma base consistente para tentar minimizar o risco que as empresas invariavelmente incorrem quando estabelecem suas diretrizes de crédito ao tentar se posicionar no mercado.

A análise de potenciais clientes ocorre através do levantamento de informações presentes e passadas sobre suas características pessoais e de consumo. Essas características por si só não contribuem de modo significativo para identificar possíveis problemas de inadimplência, devendo então ser comparadas com as características históricas de clientes que se tornaram maus pagadores. Por outro lado essas características podem ser analisadas segundo critérios estabelecidos pela empresa como mínimos aceitáveis para que se possa levar em consideração a possibilidade de concessão de recursos.

Esses critérios utilizados na análise dão origem ao que Silva (1998) denomina de modelos de base quantitativa e qualitativa. A análise qualitativa foi a primeira a surgir e é baseada

preponderantemente em critérios subjetivos, decorrentes da experiência individual, que o analista julga importante para identificar a capacidade de pagamento de cada cliente.

Por sua vez a análise quantitativa surgiu em decorrência da necessidade de aperfeiçoar a avaliação do solicitante de financiamento tornando a análise de crédito menos suscetível a critérios de julgamento pessoal. A modelagem quantitativa utiliza técnicas estatísticas para identificar as características que melhor distinguem os bons pagadores dos inadimplentes a medida que atribui pesos a cada uma delas de modo a criar um escore identificador.

Silva (1998) ressalta a importância da decisão de crédito ser precedida de uma análise técnica, valendo-se das variáveis relacionadas a capacidade de pagamento do cliente, pois as técnicas normalmente são utilizadas para coagir o devedor a saldar suas dívidas, como contratos e ações judiciais, são de pouca valia se este realmente não dispuser de recursos para satisfazer seus pagamentos.

Por outro lado, Caouette et al (1999) ressaltam que dificilmente um crédito é concedido a clientes que estão em situação financeira difícil e tenham uma alta probabilidade de se tornarem maus pagadores. O que acontece, no entanto, é que a capacidade de pagamento do cliente se desequilibra ao longo do tempo em consequência de eventos desfavoráveis.

Deste modo é que o desenvolvimento de modelos de base quantitativa para a análise de crédito ganharam mais importância entre as empresas que utilizam o financiamento para desempenhar suas atividades, pois possibilitaram o fornecimento de subsídios para tomada de decisão que não são facilmente percebidas quando se leva em consideração apenas o histórico de clientes e projeções da disponibilidade de recursos futuro.

No caso do fornecimento de crédito para o segmento educacional existem muitas das mesmas características do risco incorrido no financiamento de um bem físico ou recursos financeiros, como o relacionamento de confiança entre dois entes, neste caso a instituição de educação como fornecedor de recursos e os pais ou responsáveis pelos alunos como consumidores, em que a escola se abstém de usufruir recursos no presente investindo em infra-estrutura, contratação do corpo docente, e em troca recebe a promessa de pagamento em data futura, onde os clientes se comprometem a desembolsar recursos a medida que o serviço é prestado.

No entanto diferentemente dos bens físicos não existe uma garantia real que possa ser retomada para saldar o débito como acontece no financiamento de bens físicos onde o próprio bem objeto é utilizado como garantia.

Por isso é que o desenvolvimento de uma modelagem de crédito se torna ainda mais importante para empreendimentos educacionais, que historicamente não possuem uma cultura de crédito.

2.3 TÉCNICAS DE GERENCIAMENTO DO RISCO DE CRÉDITO

Segundo Saunders (2000) os modelos de risco de crédito podem ser classificados em duas categorias distintas. A primeira diz respeito as abordagens tradicionais nos quais se enquadram os sistemas especialistas ou de análise subjetiva, os modelos de credit scoring ou pontuação de crédito e por último os sistemas de classificação também denominado de rating. A segunda classificação é denominada pelo autor de abordagens novas as quais abrangem os modelos de portfólio. Estes últimos são desenvolvidos em sua maioria por empresas privadas especializadas em avaliação de crédito ou pelas próprias instituições concedentes de recursos. Entre eles destacam-se os modelos: CreditMetrics, KMV, McKinsey, CreditRisk+, CreditPortfolioView. Os sistemas de avaliação baseados no Rating são focados na avaliação do risco de crédito de títulos e ações de grandes empreendimentos, o que se distancia da atenção concedida por este trabalho ao crédito da pessoa física. Deste modo seu conteúdo e metodologia de análise não serão abordados, cabendo uma leitura aprofundada as obras de referência¹.

2.3.1 SISTEMAS ESPECIALISTAS

Sistema especialista, também conhecido com julgamental, pode ser conceituado como um sistema de avaliação de crédito fundamentado em um conjunto de regras, que estabelecem os critérios a serem ponderados, assim como seus parâmetros, ao se analisar os fatores que permeiam a concessão de crédito. Sua utilização compõe-se com um dos primeiros esforços em direção a análise de risco creditício, sendo assim, são baseados preponderantemente em avaliações subjetivas de um conjunto de normas fundamentadas em experiências anteriores de analistas de crédito (FENSTERSTOCK, 2005).

A avaliação de crédito é uma função que tradicionalmente tem grande relevância na atividade bancária pelo fato de que conceder crédito integra uma de suas principais atividades. Sendo assim, Caouette et al (1999) comentam que a avaliação tradicional de risco surgiu em decorrência da mudança de foco da avaliação do balanço para o fluxo de caixa.

Os autores comentam que no princípio as avaliações eram feitas baseadas na disponibilidade de bens que pudessem ser oferecidas em caso de inadimplência. Estes empréstimos eram destinados a suprir a deficiência de caixa no curto prazo. A medida que as necessidades de financiar ativos fixos aumentou, a análise das garantias perdeu importância, pois poucas empresas possuem bens suficientes para cobrir altos empréstimos e ao mesmo tempo em que algumas destas garantias não possuem mercado secundário. Deste modo as empresas passaram a focar na capacidade de geração de recursos que pudessem arcar com os custos do empréstimo. A partir de então a necessidade de realizar uma análise completa sobre as características do solicitante de crédito possibilitou a criação do sistema especialista.

Neste contexto o sistema especialista pode ser entendido como uma metodologia de análise de crédito, o qual utiliza avaliações subjetivas para identificar a capacidade do solicitante de financiamento em arcar com as despesas do crédito.

Ao mencionar avaliações subjetivas remete-se a possibilidade de discricionariedade do analista em utilizar julgamentos valorativos pessoais para atribuir ponderações a critérios específicos detalhados pelas exigências da política de crédito da empresa. Outro ponto permeado pela subjetividade se relaciona a identificação dos critérios pelos quais o solicitante deve ser avaliado, de modo que possam refletir da maneira mais fidedigna sua disponibilidade de recursos.

Apesar da grande importância do sistema especialista para a avaliação de crédito existem muitas limitações relacionadas a sua utilização. Para Caouette et al (1999) este sistema é bastante dispendioso, pois exige a manutenção de uma grande quantidade de analistas para fazer frente a demanda de recursos, além do mais são necessários treinamentos contínuos numa tentativa de uniformizar o padrão de análise.

Existem inúmeros critérios de podem ser levados em consideração durante análise de crédito, seja o solicitante uma pessoa física ou jurídica. No entanto a literatura financeira frequentemente relaciona alguns aspectos principais que devem ser analisados, conhecidos como os C's do crédito.

Nas palavras de Caouette et al (1999, p.76), "Todo sistema de concessão de crédito ressoa como princípios, checklist, diretrizes e procedimentos, todos com o objetivo de treinar os não iniciados ou assegurar que os especialistas – os executivos de crédito – tenham pensado em todas as questões relevantes".

Posteriormente houve uma sistematização dos critérios de avaliação de solicitantes de crédito no que ficou conhecido como os 5 C's do crédito. Silva (1998) ressaltou a importância da inclusão de mais um ponto para análise denominado de conglomerado. A seguir são apresentados os C's do crédito:

Caráter – para Silva (1998) o caráter está associado a intenção do devedor em saldar seus débitos adquiridos com financiamentos. O caráter é uma denominação genérica que está relacionada como a índole, a moral do devedor. Esses critérios por sua vez são bastante abstratos e devem ser avaliados sob alguns aspectos específicos.

O primeiro deles é a pontualidade no cumprimento dos prazos de pagamento. Este fato pode ser percebido como um bom indicador da intenção de criar uma relação de confiança com o credor.

Um segundo aspecto que pode ser utilizado para averiguar o caráter de um solicitante é através da existência de desabonos como protestos e ações judiciais. Esses indicadores funcionam como provas sobre o histórico de incapacidade de honrar compromissos. Essas informações sobre relacionamentos passados negativos podem ser adquiridas através do convenio entre instituições fornecedoras de crédito, assim como empresas especializadas como o Serviço de Proteção ao Crédito (SPC).

Capacidade – Para Blatt (1999) a capacidade refere-se, de uma maneira geral, a uma avaliação das qualidades curriculares do indivíduo, envolvendo a análise de aspectos como a habilidade no gerenciamento de sua vida pessoal e profissional. Para o autor este é um dos aspectos mais difíceis na avaliação do risco por se tratar de variáveis muito mais relacionadas com a percepção de quem analisa do que com as próprias informações disponíveis.

Silva (1998) afirma que para avaliar esse tipo de critério seria necessário realizar uma varredura em toda a história de vida dos clientes e suas estratégias, presente e futura, o que foge do escopo da análise de crédito. Por esta dificuldade de obtenção de informações completas é que a subjetividade apresenta-se como um fator preponderante na avaliação do critério capacidade.

Sendo assim, a questão da capacidade pretende verificar se a maneira com que o cliente conduz sua vida é capaz de torná-lo digno do crédito por tempo suficiente para saldar as despesas incorridas.

Condições – Para Silva (1998) este aspecto na avaliação do crédito está direcionado ao modo como as forças presentes no ambiente em que o indivíduo está inserido podem influenciar seu

desempenho financeiro sem que, no entanto, estes possam ter controle ou responsabilidade sob sua ocorrência.

Este aspecto na avaliação pretende identificar a susceptibilidade dos rendimentos a alterações no ambiente macroeconômico. A medida do critério condições pode ser feita com base no conhecimento das atividades dos clientes no que concerne ao mercado em que atua, podendo atuar em empresas públicas ou privadas, na composição de seus rendimentos, variando entre fixos e variáveis ou ainda uma composição dos dois. Dependendo das características do indivíduo frente a critérios como estes é possível mensurar o grau de sujeição a eventos desfavoráveis, e que contribuem de forma positiva para o risco do concedente de crédito.

De modo mais direcionado para as empresas, Blatt (1999) expõe que a análise das condições é direcionada para o levantamento de aspectos gerais e conjunturais dos negócios e ramo de e complementa que as informações geradas possibilitem uma previsão do futuro do cliente.

Segundo o mesmo autor a sensibilidade das empresas as influências externas são decorrentes de fatores como: a conjuntura econômica e política do país e da região, segmento da atividade, qualidade e essencialidade dos produtos e serviços, retrospectiva histórica e perspectiva de futuro.

Capital – o capital é compreendido como a análise da situação econômico financeira e patrimonial do solicitante do crédito, na tentativa de identificar a real disponibilidade de recursos para pagamento de obrigações. Blatt (1999, p. 44) complementa afirmando que se trata de uma avaliação “da fonte de receita e renda do cliente, ou seja, quais as origens de seus recursos, sua frequência e consistência”.

Conglomerado – é o termo cunhado por Silva (1998, p. 88) direcionado, a princípio, para a avaliação de um aspecto empresarial, onde é levantada a importância de se proceder a “análise não só de uma empresa específica que esteja pleiteando o crédito, mas o exame do conjunto, conglomerado de empresas no qual a solicitante de crédito esteja contida”.

Segundo o mesmo autor, a análise deve ir muito além do que entende por conglomerado na forma da lei, devendo o aspecto econômico do relacionamento entre as empresas se sobrepor a simples detalhes jurídicos.

O intuito de se proceder a uma análise deste tipo é ter um panorama da solidez do grupo de empresas, que de alguma maneira estão interligadas como um todo, e ter a possibilidade de avaliar

o risco em uma dimensão mais completa, pois o mau desempenho de alguma das empresas do grupo pode abalar a solidez financeira das demais.

Trazendo o conceito de conglomerado para avaliar a pessoa física, Blatt (1999) comenta que a este item deve abranger a análise de todos os indivíduos que possivelmente possam responder solidariamente a um débito, como: dependentes, o cônjuge, garantidores, entre outros. O mesmo autor comenta que muitas vezes as características de uma única pessoa demonstra que esta não é capaz de arcar sozinha com um crédito, necessitando de agentes que possam responder pelo débito em caso de inadimplência.

Colateral – é definido por Silva (1998) como a disponibilidade do solicitante de crédito em oferecer garantias adicionais àquelas que normalmente são exigidas. Essas garantias são um possível reflexo da insuficiência de características que assegurem ao credor o recebimento de dívidas que lhe são devidas.

Como ressalta Blatt (1999) esta garantia não deve ser interpretada como uma obrigação principal, mas apenas como um instrumento acessório da obrigação. Um dos motivos que levam a assumir esta afirmação como verdadeira é o fato de que o credor não tem o interesse em tornar a execução ou administração de garantias sua atividade principal.

Outro fator relevante, comentado por Silva (1998), é que a execução de garantias possui algumas limitações, como: a depreciabilidade do bem, a falta de liquidez, o baixo valor da garantia em relação a dívida total, entre outras, que tornam a execução de garantias pouco atraentes caso ocorra uma eventual inadimplência durante a transação.

Estes seis critérios são os que habitualmente constam na maior parte da literatura financeira, mas que não esgotam as possibilidades de análise, até porque a dinâmica entre os diferentes tipos de segmentos empresariais necessita de diferentes aspectos de avaliação.

Uma vez discutidos os pontos principais utilizados na avaliação do risco de crédito sob a ótica do sistema especialista, faz-se necessário realizar uma ressalva a respeito de sua utilização.

Apesar de ser um sistema que possui uma lógica ao avaliar os padrões de risco de crédito, o sistema especialista padece da ausência de fundamentos estatísticos, o que torna sua utilização, de maneira isolada, extremamente frágil. Esta limitação dificulta a quantificação do risco de crédito, o que inviabiliza a identificação dos fatores que estatisticamente influenciam a inadimplência, tornando a técnica inerentemente imprecisa. (FENSTERSTOCK, 2005).

Por outro lado, é inegável a contribuição do sistema especialista no desenvolvimento da análise de risco de crédito. Suas premissas continuam sendo válidas e são utilizadas para embasar sistemas mais elaborados que procuram unir a teoria apresentada pelos sistemas especialistas com a precisão dos métodos estatísticos.

2.3.2 CREDIT SCORING

O credit scoring consiste no desenvolvimento de um modelo capaz de fornecer uma medida quantitativa que reflete a credibilidade de um indivíduo, quanto ao pagamento de um produto ou serviço, baseando-se em um conjunto de informações preditoras (LEE; JUNG, 2000). O escore de crédito pode ser percebido também como um mecanismo que permite o reconhecimento do status de diferentes grupos, como adimplentes e inadimplentes, em uma população, ao se realizar a previsão de um evento (TOMAS, 2000).

A possibilidade de realizar uma avaliação da credibilidade de um indivíduo tomando-se por base mecanismos estatísticos, concede ao credit scoring uma vantagem em comparação aos sistemas de julgamento subjetivo quanto a rapidez e a confiabilidade com que as decisões são tomadas, além de possibilitar uma redução nos custos de análise e no monitoramento de créditos existentes (ROSEMBERG; GLEIT, 1994)

Os modelos de credit scoring surgiram como uma evolução natural da análise para concessão de crédito que se baseia preponderantemente na avaliação de critérios de maneira subjetiva. Diversas alterações ocorridas no ambiente financeiro tornaram o, já limitado, antigo processo de avaliação, baseado no sistema especialista, inviável. Sem a pretensão de exaurir a lista de alterações ambientais que conduziram ao desenvolvimento de modelos estatísticos de risco de crédito, Caouette et al (1999) elencam algumas das mais significativas:

- Desregulamentação, permitindo a entrada de novas entidades prestando serviços de empréstimos, forçando a redução das margens sobre empréstimos;
- Ampliação dos segmentos que são atendidos pelos serviços de crédito;
- A mudança do foco dos empréstimos baseados no balanço para a geração de fluxo de caixa;
- Aumento dos riscos extra balanço;
- Securitização, fomentando o desenvolvimento de novas ferramentas de risco, e
- Avanços na teoria financeira.

Estas mudanças expuseram ainda mais a fragilidade dos sistemas especialistas que não conseguiam conferir rapidez e homogeneidade as avaliações de crédito conforme crescia a demanda por tal instrumento.

Segundo Santos (2003), a pontuação de crédito é um instrumento desenvolvido para que o analista avalie a possibilidade de que determinado cliente venha a tornar-se inadimplente no futuro. Esta avaliação é elaborada através da atribuição de uma pontuação para algumas características do solicitante de crédito, estabelecidas previamente pelo analista. O critério de escolha se dá de acordo com a capacidade de segregação entre os bons clientes, que quitam seus débitos em tempo oportuno, e os maus clientes que se encontram em situação de inadimplência.

Para elaborar a pontuação de um solicitante de crédito além da seleção das variáveis chave e da atribuição de uma pontuação a cada uma delas, deve ser utilizado uma ponderação indicando a importância do atributo para a identificação da capacidade de crédito do cliente.

Quando se elaboram modelos de credit scoring para pessoas físicas, Santos (2003) ressalta a importância de se considerar na análise fatores como: informações pessoais e financeiras, fonte geradora de renda, patrimônio, atividade empresarial, idoneidade e informações sobre o contrato de crédito.

Por outro lado, se a análise de crédito estiver sendo desenvolvida para pessoas jurídicas também devem ser considerados fatores como: tempo de atuação da empresa, evolução do faturamento, concentração das vendas, indicadores financeiros, entre outros.

O ponto chave desta ferramenta é que a distingue da análise clássica é o modo como as variáveis são selecionadas e os pesos são atribuídos.

Blatt (1999) comenta que inicialmente os modelos de credit scoring funcionavam como um modelo quantificado dos C's do crédito, onde as pontuações eram estabelecidas com base na probabilidade histórica de se verificar a presença ou não de algumas características que estivessem relacionadas aos bons e maus pagadores, podendo ainda ser aplicada uma gradação de pontos indicando a qualidade do aspecto avaliado. Um exemplo deste tipo de pontuação é apresentado em seguida:

Tabela 1(2): Modelo de pontuação de crédito baseado na probabilidade histórica.

Característica.	Histórico de bons pagadores	% Bons	Histórico de maus pagadores.	% Maus	Prob. da informação.
1.Atividade Profissional.					
Diretor	256	8%	4	2%	4/1
Gerente/Supervisor	480	15%	20	10%	3/1
Operacional	672	21%	48	24%	7/8
Trabalhador não especializado.	1792	56%	128	64%	7/8
Total	3200	100%	200	100%	
2.Propriedade da Moradia.					
Própria.	1920	60	60	30	2/1
Alugada.	960	30	120	60	1/2
Outros.	320	10	20	10	1/1
Total	3200	100	200	100	
3.Tempo de Emprego.					
Até 2 anos	320	10	80	40	1/4
De 3 a 5 anos.	640	20	60	30	2/3
De 6 a 10 anos..	960	30	40	20	3/2
Mais de 10 anos.	1280	40	20	10	4/1
Total	3200	100	200	100	

Fonte: Adaptado Santos (2003).

Neste exemplo características que apresentam altos valores de probabilidade eram considerados como informações relevantes para distinguir os bons dos maus pagadores. Porém, com é possível perceber, apesar de fornecer uma medida quantitativa da probabilidade de ocorrência de um evento, técnicas como esta ainda carecem de uma sofisticação estatística, além de sofrerem da ausência de instrumentos precisos que determinem a importância de cada uma das características.

O desenvolvimento e popularização da microinformática possibilitou a aplicação de diversas técnicas quantitativas na análise de crédito, com o intuito de minimizar a subjetividade ainda remanescente em alguns aspectos da avaliação. Entre as técnicas utilizadas destacam-se: a análise discriminante, a regressão logística, a regressão probit, mais recentemente a utilização de redes neurais, entre outras.

Todas estas técnicas valem-se de dados históricos de clientes para compor o modelo. Partindo do pressuposto de que ao se basear na análise de dados passados, estes forneceram uma boa perspectiva do futuro comportamento dos clientes. Sendo assim, a atribuição de ponderações, através de procedimentos estatísticos, proporciona o estabelecimento de uma fórmula que pondera

as características dos indivíduos e cria um escore final refletindo o nível de risco que o cliente representa (SANTOS, 2003).

Mesmo utilizando sistemas estatísticos para elaborar as ponderações, os modelos não são capazes de segregar corretamente todos os bons e os maus solicitantes de crédito em todas as previsões. Estas falhas ocorrem, entre outros motivos, por considerar, durante a análise, que os dados históricos são replicáveis no contexto atual, além das próprias limitações das técnicas estatísticas. Outro ponto que contribui para explicar falhas na identificação dos clientes ,deve-se principalmente as peculiaridades intrínsecas a cada solicitante de crédito. Por exemplo, um cliente pode possuir indícios de que não é capaz de arcar com os débitos assumidos, no entanto pode possuir características morais que o conduzem a buscar alternativas para saldar suas dívidas, ou seja, a modelagem estatística não é capaz de captar todos os aspectos envolvidos na tomada de decisão para pagamento de débitos (THOMAS, 2000).

Uma vez que a utilização de técnicas estatísticas permite o estabelecimento de pontuações para todos os solicitantes de crédito, torna-se crucial a criação de um valor que possa ser utilizado como parâmetro de referência, ou ponto de corte, indicando a pontuação mínima para aprovar a relação de crédito. Este ponto de corte deverá ser estabelecido de modo que otimize a relação entre a aceitação de bons clientes e rejeite o máximo possível de inadimplentes.

Erros obtidos nesta classificação sujeitam a empresa credora a potenciais perdas devido a rejeição de bons clientes, denominado erro tipo I, e perdas devido ao aceite de maus clientes, chamado de erro tipo II. Sendo assim as empresas que utilizam a metodologia de credit scoring devem estabelecer uma política de ponto de corte onde as perdas incorridas sejam compensadas pela identificação de bons clientes (CHAIA, 2003).

Os modelos de credit scoring podem ser divididos, quanto aos seus objetivos, em modelos de aprovação de crédito e comportamental, também denominado de behavioral scoring (THOMAS, 2000).

O objetivo da aplicação dos modelos de aprovação de crédito é a previsão do comportamento futuro dos atuais e novos clientes, em relação ao pagamento de débitos nos termos do acordo de crédito. Para isto é utilizado um conjunto de dados sobre a vida pessoal e profissional do solicitante de crédito (ROSEMBERG; GLEIT, 1994).

Por sua vez, o modelo comportamental também visa a previsão da inadimplência, e distingui-se do modelo de aprovação, pois é focado na análise de indivíduos que já são clientes da instituição, possibilitando a incorporação de dados sobre o histórico de pagamentos dos clientes ao conjunto de informações preditoras. Ao absorver estas informações passadas o behavioral scoring pode ser percebido como um mecanismo que possibilita o gerenciamento dos créditos existentes, o que permite a tomada de decisões quanto a alterações no limite de crédito, a realização de cobranças preventivas, administrar a recuperação de débitos, entre outras medidas (THOMAS, 2000).

Segundo o autor supra citado o behavioral scoring também pode ser percebido como um sistema de aprovação de crédito, onde as variáveis comportamentais podem ser obtidas de fontes externas e serem tratadas como uma informações extra. Esta abordagem tem apresentado bons resultados, como é possível perceber em trabalhos como Dessai et al (1996), Almeida e Passari (2005), conferindo aos modelos um desempenho superior em suas previsões.

A utilização dos modelos de credit scoring permitiu um grande avanço, qualitativo e quantitativo, ao realizar a análise do risco de crédito quando comparado com os sistemas especialistas. No entanto, o alcance destes benefícios trouxe consigo um aumento na complexidade da avaliação de risco.

O desenvolvimento destes modelos passaram a exigir tanto a experiência da análise de crédito, como um conhecimento profundo do embasamento estatístico das técnicas que potencialmente podem ser utilizadas. Por outro lado, uma vez que os modelos são desenvolvidos o papel do analista tornou-se mais limitado, pois estes não dispõe do conhecimento utilizado no procedimento estatístico, e seus resultados são percebidos como uma caixa preta (FENSTERSTOCK, 2005).

2.3.3 RATING

O rating consiste em um sistema de classificação que reflete um conjunto de observações e percepções de agências especializadas, sobre a capacidade futura dos devedores de efetuarem, dentro do prazo, o pagamento do principal e dos juros de suas obrigações (SANTOS, 2003).

Segundo Saunders (2000) o rating surgiu como uma ferramenta utilizada para avaliar a capacidade de pagamento dos clientes que solicitavam empréstimos. Segundo o mesmo autor uma das primeiras empresas a utilizar esse sistema foi a U.S. Office of the Controller of the Currency (OCC) que classificava os solicitantes de empréstimos através de cinco categorias de acordo com a possibilidade de inadimplência. Esta avaliação era utilizada como um mecanismo para provisionamento de recursos contra possíveis perdas decorrentes dos empréstimos.

Posteriormente muitos bancos e agências especializadas desenvolveram um sistema próprio de classificação de risco, com diferentes gradações para as classificações, e expandiram sua utilização para avaliar a capacidade de pagamento de títulos emitidos por empresas privadas, por municípios e países.

Para Blatt (1999) o rating fornecido por estas agências é composto por um conjunto de informações detalhadas sobre um cliente e por isto são utilizadas para o gerenciamento efetivo de risco e oportunidades. Sua utilização cuidadosa pode contribuir para que o investidor maximize suas oportunidades e funcione como um mecanismo de advertência contra possíveis riscos associados aos empreendimentos.

As empresas que trabalham com sistemas de rating apresentam suas classificações através de um sistema alfanumérico, que indica, em diversos graus, a possibilidade de que o devedor não salde suas dívidas. Essas classificações, diferentemente do sistema especialista e do credit scoring, não avaliam a capacidade de pagamento dos devedores de forma individual, mas os enquadram em faixas de risco. O quadro a seguir traz exemplos de algumas empresas especializadas em rating e suas classificações.

Nome da Agência.	Ano de fundação.	Mercado de atuação.	Símbolos de rating para curto prazo.	Símbolos de rating para longo prazo.
Australian Rating (S&P).	1981	Local	A.1+ a C.1+	AAA a C
Canadian Rating Service (CBRS).	1972	Local	A-1 a A-4	A++ a D
Dominion Bond Rating Service (DBRS)	1976	Local	R-1 a U	AAA a C
Agence d'Evaluation Financiere (S&P)	1986	Local	T-1 a T-4	AAA a D
Credit Rating Services of Indian Ltd.	1988	Local	P-1 a P-5	AAA a D
Japan Bond Research Institute	1979	Local	Não Disponível	Não Disponível
Japan Credit Rating Agency	1985	Local	J-1 a J-5	Aaa a D
Mikuni & Co.	1975	Local	Não Disponível	AAA a D
Nippon Investor Service.	1985	Local	A-1 a D	AAA a D
Korean Investor Service	1985	Local	A-1 a D	AAA a D
International Bank Credit Analysis (UK)	1979	Bancos	Não Disponível	A a E.
Duff & Phelps	1932	Local	Duff-1 a Duff-3	1 a 17
Fitch IBCA	1913	Global	F-1 a F-4	AAA a D
Moody's Investor Service	1909	Global	P-1 a P-3	Aaa a C
Standard & Poor's	1922	Global	A-1 a D	AAA a D

Quadro 1 (2) Lista de agências de rating.

Fonte: Moody's Investor Service.

Estas classificações refletem um conjunto de informações de caráter qualitativo e quantitativo quer sejam de origem pública ou privada. As agências utilizam diferentes procedimentos para atribuir ou revisar uma avaliação e freqüentemente não são muito claras quanto a metodologia utilizada na análise (CAOINETTE et al, 1999)

Apesar dos diferentes critérios utilizados pelas empresas, a classificação quanto a possibilidade de inadimplência freqüentemente é homogênea. No entanto, como ressalta Santos (2003), diferenças em aspectos qualitativos como: diferentes modelos de coleta de dados, metodologias de mensuração de risco empregada, experiência dos avaliadores, entre outros, fazem com que algumas vezes as empresas de rating discordem entre suas avaliações.

Apesar destas divergências de classificação as empresas de rating têm demonstrado que o desempenho de suas avaliações, quanto a previsão de inadimplência, tem obtido boa precisão (CAOINETTE et al ,1999).

As informações fornecidas por estas agências de rating dispõem de muita credibilidade entre os investidores, deste modo, como comenta Caouette et al (1999), o mercado tende a corroborar a exatidão do trabalho das agencias de rating, no sentido de que os retornos dos títulos estão fortemente relacionados com as avaliações.

Deste modo considerando que o rating reflete um conjunto de informações sobre a capacidade de crédito e conseqüentemente o risco de não obter os vencimentos esperados, as avaliações são utilizadas como um parâmetro para ajustar os retornos esperados dos investimentos.

As alterações no ambiente de negócios nos quais as empresas estão inseridas impõem uma constante mudança na capacidade de crédito. Por isto, segundo Caouette et al (1999), as avaliações de rating são constantemente revistas, e as possíveis reconsiderações são realizadas baseando-se não só em relação aos ganhos declarados, mas também em função de diversos fatores econômicos e financeiros que possam afetar a capacidade creditícia dos agentes, como por exemplo: as alterações significativas na política cambial, mudanças da rentabilidade dos ativos, alterações no padrão de concorrência, entre outros.

Conforme afirma Securato (2002), a utilização de rating para avaliação de risco já se constitui uma prática bastante difundida entre bancos internacionais, no entanto esta prática só tomou impulso no mercado brasileiro após o acordo da Basiléia. As idéias lançadas por este acordo estimularam o Banco

Central do Brasil (BACEN) a adotar o rating como um mecanismo para provisionamento de crédito em liquidação duvidosa.

Esta utilização ocorreu por meio do estabelecimento da resolução Nº 2682 de 1999, onde o BACEN determinou, por meio dos artigos 1 e 6, que as operações de crédito devem ser classificadas em ordem crescente de risco e o provisionamento de recursos para fazer face a prováveis perdas na concessão de crédito estabelecido da seguinte maneira (BANCO CENTRAL DO BRASIL, 2006):

- 0,5% sobre o valor das operações classificadas como de risco nível A;
- 1% sobre o valor das operações classificadas como de risco nível B;
- 3% sobre o valor das operações classificadas como de risco nível C;
- 10% sobre o valor das operações classificadas como de risco nível D;
- 30% sobre o valor das operações classificadas como de risco nível E;
- 50% sobre o valor das operações classificadas como de risco nível F;
- 70% sobre o valor das operações classificadas como de risco nível G;
- 100% sobre o valor das operações classificadas como de risco nível H.

Outro fator apresentado por Securato (2002) que estimulou e expandiu a utilização do rating, para instituições além das financeiras, foi a necessidade de captação de recursos nos mercados internacionais e domésticos para investimentos em mercados emergentes. Este tipo de investimento exige a disponibilidade de informações precisas e imparciais freqüentemente obtidas através de agências de rating.

Analisando os as características discutidas é possível perceber que o sistema de rating constitui-se como um mecanismo intermediário entre o sistema especialista e o credit scoring, onde é possível utilizar a análise objetiva para realizar a classificação do risco de crédito, e ao mesmo tempo ajustá-lo de maneira subjetiva incorporando na análise elementos de difícil quantificação.

O resultado desta análise conjunta permite classificar indivíduos e empresas dentro de classes de risco, valendo-se de grande número de critérios. Esta quantidade de variáveis, objetivas e subjetivas, constitui-se ao mesmo tempo em uma força e uma limitação da técnica. Uma análise minuciosa sobre as diversas características de um solicitante de crédito demanda muito tempo e recursos, por isso constitui-se como uma técnica de análise voltada apenas para os crédito que apresentam uma viabilidade econômica, por este motivo são mais utilizadas para grandes empresas. Por outro lado a união de fatores objetivos e subjetivos confere a análise uma riqueza de detalhes não alcançada por outras técnicas.

2.4 TÉCNICAS APLICADAS AOS MODELOS DE CREDIT SCORING

O foco do trabalho é a identificação da viabilidade da utilização de modelos de credit scoring, de modo que possam contribuir para o gerenciamento do risco de crédito na instituição de ensino escolhida para a pesquisa. Sendo assim, diante da explanação dos três sistemas de avaliação de crédito cabe então apresentar os motivos pelos quais o modelo de credit scoring se apresenta como a modelagem que melhor se adequa a estrutura da pesquisa.

Como é possível perceber através da explanação realizada anteriormente, os sistemas especialistas assim como o rating e o credit scoring são mecanismos semelhantes quanto a sua função de gerenciamento do risco de crédito, diferindo basicamente quanto a sofisticação estatística para o cálculo das probabilidades de inadimplência.

Deste modo a utilização dos modelos de credit scoring apresentou-se como a opção mais adequada ao estudo, pois são capazes de superar as ineficiências básicas dos sistemas especialistas e do rating, além do mais possibilitam o fornecimento medidas quantitativas do risco de crédito, onde sua utilização ocorre de maneira simples e objetiva, não demandando da instituição recursos e informações que estejam além de sua capacidade.

Optou-se pela não utilização do sistema especialista, pois este não possui um fundamento estatístico de modo que fosse possível quantificar a contribuição que sua utilização traria para o gerenciamento do risco da instituição. A não objetividade da técnica é justificada, como comentado anteriormente, pois os critérios pelos quais os solicitantes do crédito são avaliados são fortemente influenciados pela subjetividade do analista de crédito.

Por sua vez, o sistema de avaliação através do rating é capaz de utilizar a objetividade ausente nos sistemas especialistas e utilizar a subjetividade como uma medida de ajuste para os critérios que não podem ser quantificados. Porém sua utilização para fins de gerenciamento de risco de crédito em uma instituição não financeira, focando na avaliação de pessoas físicas, fica comprometida. Sua operacionalização exigiria uma análise pormenorizada da vida pessoal e profissional dos clientes, o que certamente seria motivo de constrangimento e potencialmente uma fonte problemas e de ações judiciais. Outro fator que torna sua utilização inexecutável é a ausência de viabilidade econômica, pois exigiria a contratação de vários analistas que pudessem cobrir toda a gama de clientes da instituição de ensino.

A seguir serão apresentadas as técnicas de análise discriminante, regressão logística e redes neurais que serão utilizadas no desenvolvimento dos modelos de credit scoring.

2.4.1 ANÁLISE DISCRIMINANTE

A análise discriminante constitui-se em um dos primeiros métodos multivariados utilizados na formulação de uma modelagem estatística aplicada à avaliação do risco de crédito.

Os primeiros estudos focados na avaliação do risco de crédito eram denominados de modelos univariados, pois eram baseados na identificação de fatores, tomados de maneira isolada, capazes de prever a possibilidade de inadimplência. Estes estudos observavam diversos índices financeiros e traçavam um perfil daqueles que possuíam uma maior associação com empresas que não conseguiam pagar suas dívidas na data de vencimento.

Entre os primeiros estudos univariados destaca-se o trabalho de Beaver (1966) que mesmo valendo-se de índices financeiros, analisados separadamente e de maneira seqüencial, obtiveram um forte poder de previsão em seus modelos que visavam a identificação futura de empresas em processo de falência.

No entanto, a utilização de modelos univariados ainda apresentava severa limitação, devido à dificuldade em lidar com as inúmeras variáveis disponíveis, assim como a incapacidade das diferentes pesquisas em demonstrar de maneira conclusiva a característica que obtém melhor desempenho ao realizar previsões (ALTMAN, 1968).

Diante da necessidade de tornar a análise de crédito ainda mais precisa e ágil, a utilização da análise discriminante surgiu como um método que potencializa o poder de previsão, avaliando simultaneamente o perfil total das características dos objetos em análise, assim como suas interações (ALTMAN, 1968).

A análise discriminante constitui-se como um caso especial da análise de regressão, onde variáveis métricas e não métricas são utilizadas como variáveis independentes, e a variável dependente constitui-se de um atributo qualitativo ao qual é atribuído um número identificador.

Para Altman (1968) a análise discriminante múltipla (ADM) é uma técnica estatística utilizada para classificar observações dentro de grupos dependentes, estabelecidos previamente, baseando-se em um conjunto de características individuais de cada uma das observações.

Hair et al (2002) estabelecem, de maneira mais objetiva, que a análise discriminante é uma técnica que envolve a criação de uma variável estatística, estruturada através da combinação linear de uma ou mais variáveis independentes, que possam segregar as observações como pertinentes a grupos distintos, de acordo com a característica média de cada grupo.

A discriminação é obtida estabelecendo-se pesos para cada característica de modo a criar uma variável estatística ponderada, que tenha o poder de maximizar a variância entre grupos, relativamente à variância dentro dos grupos (HAIR et al 2002). Em outras palavras a discriminação é obtida através da atribuição de pesos a cada uma das características de uma unidade de análise, seja ela um objeto, um indivíduo, ação, entre outras, de modo que a soma ponderada destes valores criem uma pontuação. Esta pontuação é um indicativo de qual grupo esta unidade de análise pertence. Por sua vez, este score, ou pontuação, deve segregar os grupos de modo a maximizar a diferença entre os grupos distintos ao mesmo tempo em que torna os objetos dentro de cada grupo mais homogêneos.

Segundo Altman (1968), existem algumas questões chave que devem ser analisadas ao se utilizar modelos para previsão, entre elas estão a identificação das características mais importantes para segregar os dados, qual a importância que deve ser atribuída as características e como estabelecer os pesos de maneira objetiva.

O critério de seleção das características que comporão os modelos de credit scoring pode ser selecionado através de duas abordagens: a primeira envolve a identificação de variáveis utilizadas em estudos anteriores ou do modelo teórico que baseia a questão de pesquisa. A segunda abordagem é intuitiva e baseia-se no conhecimento adquirido pelo pesquisador em relação ao potencial de explicação de uma variável, para a qual não existe pesquisa prévia ou teórica. (HAIR et al, 2002)

O peso, ou importância, atribuído às características é um reflexo da sua capacidade de distinguir corretamente objetos como pertencentes a grupos distintos. O critério estatístico utilizado na análise discriminante para estabelecer estes pesos é o mesmo utilizado na análise de regressão convencional, ou seja, mínimos quadrados ordinários, que visa a minimização do erro quadrático médio entre as previsões e o valor real de um dado. Sendo assim, a ponderação indica a importância relativa de uma característica em classificar corretamente um objeto dentro de um grupo, pressupondo que as demais característica permanecem constantes.

A análise discriminante possibilita a classificação de indivíduos ou objetos dentro de grupos de comportamento dicotômico, denominado de análise discriminante simples, ou grupos com mais de duas classificações, chamada de análise discriminante múltipla. Estudos direcionados à análise de crédito, com maior frequência, utilizam a análise discriminante simples para identificar grupos dicotômicos como solvente e não solventes, bons e maus pagadores, entre outros.

Segundo Johnston e Dinardo (2001) a discriminação é obtida estabelecendo-se pesos da variável estatística para cada variável, obtendo-se uma equação que assume a seguinte forma:

$$Y = X\beta_1 + u$$

Onde:

Y = escore discriminante, na forma de um vetor coluna de $n \times 1$ observações sobre Y .

X = uma matriz de dados $n \times k$, contendo todas as variáveis independentes do modelo e o termo de intercepto;

β_i = um vetor coluna $k \times 1$ dos pesos desconhecidos;

u = vetor coluna $n \times 1$ relativo aos erros da regressão.

Apesar de seu avanço em relação aos primeiros modelos univariados, existem também alguns fatores limitantes para utilização da análise discriminante direcionada a elaboração de modelos de credit scoring. Por se tratar de um caso especial do método de regressão multivariada as mesmas restrições são aplicáveis a ambos os casos, tais como: a normalidade das variáveis regressoras, a variância homocedástica das perturbações, o resultado da regressão não garante que a pontuação discriminante situe-se dentro do limite lógico de 0 e 1. (JONSTON, 2002; MADALA, 1988; GUJARATI, 2000)

Por outro lado, existem artifícios que permitem a utilização dos dados superando estas limitações.

A não normalidade das variáveis independentes utilizadas na regressão é uma questão delicada para a análise discriminante. Isto ocorre por que a gaussianidade das variáveis permite que as estimativas referentes aos erros padrão sejam não viesadas, e deste modo as inferências realizadas sobre os testes de hipóteses serão eficientes, obtendo mínima variância. Por outro lado o cálculo dos coeficientes da análise discriminantes, através do método dos mínimos quadrados ordinários, não utiliza a normalidade dos dados como pressuposto para a estimação dos parâmetros. Deste modo a não normalidade das variáveis pode ser percebida como uma questão crítica na análise discriminante, podendo viesar os resultados, quando o objetivo da regressão está associada a inferência estatística, muito embora não represente um questão relevante quando o foco é a

estimativa de ponto (GUJARATI, 2000). Esta limitação pode ser superada ao se utilizar um grande número de dados na amostra ou ainda através de transformações como a raiz quadrada, uso do logaritmo ou ainda a transformação Box-Cox (HAIR et al, 2002).

A variância heterocedásticas das perturbações é uma limitação inerente à estimação da regressão que utiliza uma variável dependente qualitativa, pois os erros serão proporcionais variações das variáveis regressoras (GREENE, 2002). No entanto, esta limitação pode ser contornada artificialmente, dividindo todas as variáveis do modelo por, onde indica o valor estimado da variável dependente estimada pelo método dos mínimos quadrados. Este procedimento é conhecido como método dos mínimos quadrados ponderados. (JOHNSTON; DINARDO, 2001).

Outro método de correção da heterocedasticidade é o mecanismo de White, o qual permite atingir as ineficiências apresentadas, porém preservando as estimativas pontuais dos parâmetros. A correção de White, segundo Johnston e Dinardo (2001), baseia-se na utilização de um vetor de erros quadráticos na construção da ponderação da matriz de variância, como demonstrado a seguir:

$$\text{var}(b) = (X'X)^{-1} X' \sigma^2 \hat{\Omega} X (X'X)^{-1}$$

onde:

X = indica uma matriz $n \times k$, de variáveis independentes e o termo de intercepto;

$\hat{\Omega}$ = é uma matriz identidade $n \times k$;

Onde o vetor desconhecido σ_i^2 , de variância homocedástica, é substituído por e^2 obtidos como resíduos da regressão. Tem-se, assim, um estimador consistente da matriz de variância para o conjunto de coeficientes da regressão (JOHNSTON; DINARDO, 2001).

Por sua vez, ao estabelecer uma pontuação discriminante fora do limite lógico de 0 e 1 o autor sugere a utilização do numero inteiro mais próximo (GUJARATI, 2000).

Apesar destas limitações a análise discriminante múltipla ainda é uma técnica bastante utilizada por possuir características fundamentais desejadas ao se pesquisar sobre risco de crédito. A primeira é funcionar como uma análise de perfil, onde a análise discriminante possibilita uma avaliação objetiva de um conjunto de características pertencentes a um indivíduo de modo que permite enquadrá-lo como pertencente a um grupo específico com características semelhantes. A segunda é por tratar-se

de uma técnica preditiva analítica em que a análise discriminante estabelece uma função que permite a classificação de diferentes amostras detentoras das mesmas variáveis preditivas. (HAIR et al, 2002).

2.4.2 MODELOS DE ESCOLHA DISCRETA, LOGIT E PROBIT

Logit e probit são modelos de regressão que utilizam como variável dependente respostas que assumem natureza dicotômica, e procuram encontrar um relacionamento não linear entre as variáveis explicativas e preditivas (GREENE, 2002).

Os modelos de escolha discreta, de modo análogo à análise discriminante, também é uma técnica utilizada para identificar as variáveis que contribuem para explicar determinado fenômeno. A grande diferença entre as técnicas é que os modelos de escolha discreta são estruturados para lidar especificamente com dados dicotômicos, permitindo, assim, superar os limites impostos a análise discriminante, como a normalidade dos dados e a linearidade das relações.

A principal questão que torna este tipo de modelagem mais atrativa frente ao método linear é que a estrutura do modelo limita os resultados da regressão ao resultado dicotômico esperado, ou seja, 0 ou 1 (GREENE, 2002).

O relacionamento não linear entre as variáveis independentes e dependentes é outro fator que torna a utilização dos modelos logit e probit mais atrativos, pois indica que o efeito incremental das informações preditivas não são constantes ao longo do tempo. (GUJARATI, 2000).

No contexto do risco de crédito esta relação indica que a medida que uma variável independente aumenta, cresce a probabilidade de que um indivíduo se torne um bom pagador ou mal pagador, contudo, a partir de certo nível o acréscimo no valor da variável afeta cada vez menos o status de pagamento do indivíduo. Este critério é bastante intuitivo principalmente quando se pensa a respeito da relação entre renda, patrimônio ou experiência com a possibilidade de inadimplência. Este tipo de relação pode ser percebida através do gráfico de uma função de distribuição acumulada de uma variável independente:




Figura 1 (2) – Função de distribuição acumulada.

Fonte: Greene (2002)

As propriedades deste tipo de função, ou relação matemática, apresenta o formato de uma curva sigmóide e pode ser encontrada em diversas funções de distribuição acumulada (FDA). Ao se utilizar a função de distribuição acumulada normal é gerado o modelo probit, freqüentemente representado por $\Phi(\cdot)$, e quando utilizada a função de distribuição acumulada logística é denominado modelo logit, identificado por $\Lambda(\cdot)$ (GREENE, 2002).

Diversas funções, utilizando diferentes distribuições, desde que limitem o intervalo de saída a 0 ou 1, podem ser utilizados na composição de um modelo de escolha discreta, no entanto os modelos logit e probit são mais utilizados em aplicações econométricas (GREENE, 2002).

Jonhston e Dinardo (2002) apresentam de maneira intuitiva a estrutura subjacente ao modelo partindo do princípio de que observando-se uma variável y que toma os valores, 0 ou 1, define-se uma outra variável não observável y^* , que estabelece a seguinte relação:

$$y^*_i = X_i\beta + \varepsilon_i, \text{ e:}$$

$$y_i = \begin{cases} 1 & \text{se } y^*_i > 0 \\ 0 & \text{no caso contrário.} \end{cases}$$

Este modelo é semelhante à regressão linear, onde X_i indica uma matriz de variáveis independentes, β uma matriz coluna com os coeficientes da regressão e ε_i indica uma matriz coluna contendo os erros da regressão. Por sua vez y^*_i indica uma variável não observável, como por exemplo, a

disposição de indivíduos em quitar débitos na data de vencimento da dívida. Não é possível perceber a disposição apenas seu resultado indicado pelo status de adimplente ou inadimplente.

Esta relação pressupõe que $\varepsilon \sim N(0, \sigma^2)$

Sendo assim é possível notar que:

$$prob(y_i = 1) = prob(y_i^* > 0) = prob(X\beta + \varepsilon_i > 0) = prob(\varepsilon_i > -X_i\beta) = prob\left(\frac{\varepsilon_i}{\sigma} > -X_i \frac{\beta}{\sigma}\right)$$

O σ indica o desvio padrão do ε . Ao se utilizar o artifício de dividir os erros pelo σ ,

foi possível transformar $\frac{\varepsilon}{\sigma}$ em uma distribuição normal padronizada permitindo o cálculo da probabilidade desejada.

Sendo assim é possível reescrever a equação anterior da seguinte maneira:

$$prob(y_i = 1) = prob\left(\frac{\varepsilon_i}{\sigma} > -X_i \frac{\beta}{\sigma}\right) = prob\left(\frac{\varepsilon_i}{\sigma} < X_i \frac{\beta}{\sigma}\right) = \Phi\left(X_i \frac{\beta}{\sigma}\right)$$

Por outro lado a $prob(y_i = 0)$ é complementar a $prob(y_i = 1)$ ou seja:

$$prob(y_i = 0) = 1 - prob(y_i = 1) = 1 - \Phi\left(X_i \frac{\beta}{\sigma}\right)$$

Uma vez que a função de verossimilhança é o produto da probabilidade de cada observação pode-se indicar a função de verossimilhança para o modelo probit como:

$$L = prob(y_1 = 0) * prob(y_2 = 0) * ... * prob(y_m = 0) * prob(y_{m+1} = 1) * ... * prob(y_n = 1)$$

Onde o subscrito da variável y , de 1, ..., m indicam as observações tais que $Y_i = 0$ e por $m + 1$, ..., n as $n-m$ observações onde $y_i = 1$.

Reescrevendo a equação acima de acordo com o modelo anterior temos:

$$\begin{aligned}
&= \prod_{i=1}^m \left[1 - \Phi \left(X_i \frac{\beta}{\sigma} \right) \right] \prod_{i=m+1}^n \left[\Phi \left(X_i \frac{\beta}{\sigma} \right) \right] \\
&= \prod_{i=1}^n \Phi \left(X_i \frac{\beta}{\sigma} \right)^{y_i} \left[1 - \Phi \left(X_i \frac{\beta}{\sigma} \right) \right]^{1-y_i}
\end{aligned}$$

Ou ainda reescrevendo na forma da função logaritmo da verossimilhança como demonstrado abaixo:

$$= \sum \left\{ y_i * \ln \left[\Phi \left(X_i \frac{\beta}{\sigma} \right) \right] + (1 - y_i) * \ln \left[1 - \Phi \left(X_i \frac{\beta}{\sigma} \right) \right] \right\}$$

Segundo Jonhston e Dinardo (2002) é conveniente para o modelo normalizar o Φ , de modo que seja igual a um, para que se possa trabalhar a função no formato $\Phi(X_i\beta)$.

Por fim, a relação $\Phi(X_i\beta)$ compreendida acima pode ser substituída pela função de distribuição acumulada normal que é definida da seguinte maneira:

$$prob(y_i = 1) = \Phi(X_i\beta) = \int_{-\infty}^{X_i\beta} \frac{1}{\sqrt{2\pi}} \exp\left(-\frac{z^2}{2}\right) dz$$

Ou ainda pela distribuição acumulada logística assumindo o seguinte formato:

$$prob(y_i = 1) = \Lambda(X_i\beta) = \frac{\exp X_i\beta}{1 + \exp X_i\beta}$$

A função de distribuição normal, representada por $\Phi(\cdot)$ faz com que a probabilidade situe-se no intervalo desejado entre 0 e 1, ou seja:

$$\lim_{Z \rightarrow +\infty} \Phi(z) = 1 \quad \lim_{Z \rightarrow -\infty} \Phi(z) = 0$$

Utilizando estruturas semelhantes os modelos logit e probit, diferem essencialmente quanto a função de distribuição acumulada que utilizam, logística no primeiro caso e normal para o segundo, o que permite aos modelos tenderem a apresentar probabilidades semelhantes. Greene (2002) afirma também que existem razões de conveniência matemática para favorecer um modelo a outro

mas que se torna difícil justificar esta questão numa base teórica, além do mais, este não é um ponto pacífico nos estudos estatísticos.

Sendo assim, o modelo logit será abordado neste trabalho, preferencialmente ao probit, devido a semelhança obtida entre o resultado dos dois métodos e por superar a necessidade da normalidade dos dados, questão que foi percebida na análise dos dados que compõe esta pesquisa.

Todavia, vale ressaltar, que os resultados destes modelos possam apresentar resultados diferentes caso uma das respostas dicotômicas apresente um número muito inferior a outra, ou seja, poucos valores 1 ou 0 (GREENE, 2002).

2.4.3 REDES NEURAIAS

As redes neurais artificiais (RNA) consistem em sistemas paralelos distribuídos de processamento de informações (ZHANG, PATUWO; HU, 1998), capazes de aprender relações entre variáveis apresentadas previamente e generalizar seus resultados para outros conjuntos de dados desconhecidos (CASTRO JR, 2003).

Sua nomenclatura provem da semelhança com a estrutura e conexões do cérebro humano, além da sua capacidade de aprendizado e processamento de fenômenos complexos (SALCHEMBERG et al, 1992). A analogia com o cérebro humano não significa copiar todas suas funções, mas apenas modelá-las de forma simplificada, o que é possível perceber observando que os elementos que compõe a rede artificial desempenham tarefas computacionais simples, e sua complexidade é proveniente de suas interconexões e da capacidade de processamento em paralelo (LACHTERMACHER; ESPENCHITIT, 2001)

A utilização das redes neurais artificiais no contexto financeiro tem tomado crescente importância, uma vez que a utilização da técnica tem proporcionado um diferencial em relação aos mecanismos estatísticos na solução de problemas. Diferentemente das técnicas paramétricas tradicionais, as RNAs não exigem a especificação da relação funcional entre as variáveis dependentes e independentes. As redes neurais são capazes de utilizar a estrutura dos dados para resolver, ou identificar, o relacionamento entre variáveis sem que necessariamente sejam elaborados quaisquer pressupostos sobre a distribuição das variáveis de entrada (SALCHEMBERG et al, 1992).

A aplicação de redes neurais constitui-se em uma abordagem relativamente nova, principalmente em estudos conduzidos no Brasil, e aos poucos vem sendo introduzida no contexto de finanças como nos estudos conduzidos por Freitas e Souza (2003) na precificação de opções, por Almeida e

Dumontier (1996) relacionando-se ao problema da avaliação de inadimplência e por Kimura et al (2005) na classificação do risco de crédito ao consumidor.

O componente básico das redes neurais são os nodos ou unidades de processamento, que devido a semelhança com os neurônios biológicos no desempenho de suas atividades também são denominados neurônios. Esses elementos são os responsáveis pela captação, computação e transmissão de informações (HAYKIN, 2001).

É através da atividade destes nodos que a rede tem a capacidade de assimilar dados fornecidos do ambiente externo e transformá-los em um vetor de respostas. Conforme comenta Dessai et al (1996), o relacionamento entre a entrada de dados e a saída de informações é determinada pela arquitetura da rede e pelo modo como os neurônios estão programados para desempenhar suas tarefas.

A arquitetura da rede neural consiste no estabelecimento da estrutura com que os nodos estão organizados, onde devem ser levados em consideração uma série de fatores como: o número de camadas, a quantidade de nodos em cada camada, a conectividade entre as unidades e a topologia da rede (BRAGA et al, 2000).

As camadas referem-se as diversas etapas de processamento que ocorrem dentro da rede. Segundo Haykin (2001) as camadas são divididas em três categorias; a camada de entrada incumbida da captação de cada uma das variáveis inseridas no modelo, as camadas ocultas, responsáveis pelo processamento dos dados, e a camada de saída responsável pelo cálculo final do processamento e apresentação dos resultados.

O número de nodos em cada camada do processo indica a quantidade de neurônios que foram selecionados para computar os dados recebidos pelas camadas e transmiti-los ao longo da rede.

Em relação a conexão a que Braga et al (2000) se referem, é representada pelo tipo de ligação que os nodos apresentam, podendo ser caracterizados como cíclicos (feed-backward) e acíclicos (feed-foward). Nas conexões cíclicas a informação saída de algum neurônio da camada final é utilizada para alimentar novamente alguma camada anterior. Por sua vez as conexões acíclicas não utilizam o resultado de saída da rede como insumo para as camadas iniciais. As redes cíclicas são mais utilizadas devido a sua capacidade de aprender com os erros obtidos possibilitando um ajuste adequado do resultado apresentado pela rede.

Por fim, as RNAs são classificadas quanto a sua tipologia como: fracamente conectados, onde existem apenas alguns ligações entre os elementos que compõe as camadas, ou completamente conectados,

onde todos os elementos de uma camada se conectam a todos os elementos da camada posterior (HAYKIN, 2001)

Diversos tipos de arquiteturas foram desenvolvidos ao longo da evolução das pesquisas na área das redes neurais, sendo que a perceptron multicamadas apresenta-se como um expoente na utilização de pesquisas empíricas, principalmente em aplicações relacionadas ao credit scoring (WEST, 2000). Baseando-se no desempenho obtido pela arquitetura do perceptron multicamadas em estudos como os de Dessai et al (1996), Salchenberger et al (1992), West (2000), Piramuthu (1999), este foi o tipo de arquitetura escolhido para utilização no presente estudo. Sendo assim o funcionamento e as características das redes neurais artificiais que serão percorridas a seguir privilegiaram explicações voltadas para o perceptron multicamadas, muito embora muitas de suas características são utilizadas em outros tipos de arquiteturas.

Identificados os fundamentos da estrutura da rede, seu funcionamento pode ser melhor compreendido com o auxílio da seguinte figura:




Figura 2(2): Rede neural artificial perceptron multicamadas.

Fonte: Valença (2005, p. 37), adaptado.

Observando a rede representada na figura acima é possível constatar que sua estrutura é composta por três camadas, sendo uma de entrada com quatro neurônios, uma oculta com dois neurônios e uma de saída, percebe-se também que seus neurônios são altamente conectados.

Cada neurônio na camada de entrada é munido com dados referentes a uma variável X_j e é ligado a outro neurônio da camada seguinte através da sinapse w_{ij} . Cada um destes elos representa um peso, ou força própria, que ponderam as informações ao serem repassadas para outros neurônios, e são estabelecidos aleatoriamente (VALENÇA, 2005).

As diferentes informações repassadas para o novo neurônio são reunidas por um integrador, responsável pela soma dos sinais recebido, e já ponderados pelas sinapses, produzindo o chamado nível de atividade. O valor obtido é então utilizado como entrada da função de ativação que tem por finalidade restringir a amplitude de saída do neurônio. Esta função estabelece um limite máximo ou mínimo para reação, baseado no que Valença (2005).

Estabelece como a lei do tudo ou nada, pois o neurônio está programado para só propagar um impulso caso ele atinja o valor pré estabelecido.

Haykin (2001) resalta também a existência de um viés aplicado externamente ao neurônio, representado por b_k , que tem o potencial para aumentar ou diminuir a entrada líquida da função de ativação.

Representando a função exercida dentro do neurônio podemos descrever sua atividade da seguinte maneira:

$$u_K = \sum_{j=1}^m W_{KJ} X_J, \text{ onde:}$$

Os X_j representam os sinais de entrada, os W_{KJ} representam os pesos sinápticos, e o u_k representa a saída do integrador. Este somatório de saída é associada ao viés b_k , que por sua vez é fornecido à função de ativação φ , propiciando a formação do sinal de saída y_k , como apresentado a seguir:

$$y_K = \varphi(u_K + b_K).$$

Uma das principais características das redes neurais artificiais, segundo Cartacho e Souza (2001), é a sua capacidade de aprender. Este aprendizado ocorre através de um processo contínuo de tentativa e erro, onde os pesos atribuídos aleatoriamente as sinapses são ajustados na tentativa de tornar o valor previsto pela rede o mais próximo possível do real (BRAGA et al, 2000). Para Osório e Vieira (1999) o aprendizado fornece à rede a capacidade de generalizações de seus resultados, ou seja, ela é capaz de utilizar o conhecimento adquirido e aplicá-los a dados ainda não apresentados a rede.

Diversos métodos foram desenvolvidos para o treinamento das redes. Conforme Haykin (2001) estes mecanismos podem ser enquadrados em dois grupos principais: o aprendizado supervisionado e o não supervisionado.

No aprendizado supervisionado são fornecidos tanto os insumos de entrada da rede como o resultado de saída esperado. Ao fornecer os insumos para o neurônio é ativado todo o processo de atribuição de pesos das sinapses e computação das funções internas dos neurônios para que ao final seja apresentada a solução obtida. Este resultado é comparado com o valor de saída correto, e a diferença entre os valores encontrados é repassada para o início da rede sendo utilizada como insumo para as alterações nas sinapses, dando início ao processo de aprendizado da rede (SALCHENBERGER et al, 1992).

Todo este processo de interações que ocorre desde a entrada dos dados até a utilização do erro como uma fonte de realimentação da rede é chamado de ciclo ou época, e constitui-se na base do mecanismo de aprendizado supervisionado mais utilizado pelas redes neurais chamado de back-propagation. Neste mecanismo, as épocas ocorrem repetidamente, de modo que os reajustes realizados nas sinapses sejam baseados nas experiências empíricas obtida com os erros e proporcionem a menor diferença possível entre o valor previsto e o esperado (WEST, 2000).

Por sua vez, no aprendizado não supervisionado não são fornecidos os resultados esperados. As informações são apresentadas as redes e espera-se que estas sejam capazes de descobrir agrupamentos naturais existentes na população de dados de entrada (SALCHENBERGER et al, 1992).

Uma questão chave relacionada ao aprendizado é o estabelecimento da estrutura da rede, em relação ao número de camadas e a quantidade de neurônios existentes em cada uma delas. Estes pontos tornam-se críticos para a adaptação da rede, pois como comenta Braga et al (p.56, 2000) a utilização de um grande número de camadas intermediárias e muitos nodos permite que o erro medido durante o treinamento ao ser propagado para as camadas iniciais se torne pouco preciso e menos útil. Ao mencionar a respeito da quantidade de neurônios e camadas os autores supra citados complementam que “Deve-se ter cuidado para não utilizar unidades demais, o que pode levar a rede a memorizar os padrões de treinamento, ao invés de extrair as características gerais que permitem a generalização ou reconhecimento de padrões não vistos durante o treinamento”. Este problema é conhecido como o overffiting (BRAGA et al, p. 56, 2000).

Deste modo o número de camadas e nodos deve ser definido empiricamente, em função de uma inspeção prévia dos dados e da complexidade do problema. Muitas vezes a estrutura final mais

adequada para a modelagem é obtida após um refinamento sucessivo da topologia inicial (BRAGA et al, 2000).

Uma maneira que as redes utilizam para minimizar o problema de overffiting é dividir os dados utilizados para aprendizado em amostras de treinamento e validação (REED, 1993 apud BRAGA et al, 2000). A amostra de treinamento é utilizada na modificação dos pesos e os dados de validação são utilizados como um critério de identificação do ponto de generalização ótimo, evitando que a rede memorize dados de treinamento que não são úteis (WEST, 2000).

Os dados de validação são utilizados como um critério de interrupção da rede, evitando o overffiting, utilizando como gatilho o ponto em que a rede começa a incorporar o ruído presente nos dados, aumentando a taxa de erro.

Outro ponto crucial no aprendizado da rede é o modo como os pesos são atribuídos às conexões entre os neurônios, e a maneira com que estes são ajustados em respostas aos erros. A proporção com que estas sinapses são modificadas é determinada pela taxa de aprendizado, a qual possui a capacidade de interferir no objetivo de atingir o ponto ótimo de previsão da rede (HAYKIN, 2001).

Altas taxas de aprendizado indicam que os pesos sinápticos sofreram modificações intensas, por outro lado, taxas mais baixas propiciam pequenas mudanças ao longo das épocas de aprendizado.

Ao utilizar taxas de aprendizado muito baixas o aprendizado pode se tornar extremamente lento, e caso sejam muito elevados o processo de adaptação não converge adequadamente, e os pesos passam a ser calculados de forma pouco útil para o problema. A especificação destes parâmetros, mais uma vez, devem seguir um processo de averiguação dos dados, dos objetivos da rede e do tempo computacional utilizado (BRAGA et al, 2000).

Segundo West (2000) existe um grande número de pesquisas disponíveis utilizando as redes neurais para a previsão de inadimplência, tanto no nível individual quanto para empresas, e que tem demonstrado que este modelo tem grande potencial para superar as técnicas clássicas.

O fato das redes neurais não apresentarem nenhum tipo de restrição ao formato dos dados, associado a sua capacidade de identificar relações não lineares entre as variáveis, tem sido um fator que tem contribuído para estender sua utilização para diferentes ramos do conhecimento. Deste modo existe uma forte expectativa de que o desempenho da previsão obtida pelas redes neurais possa contribuir de maneira efetiva para a previsão da inadimplência escolar.

3 METODOLOGIA

3.1 TIPO DE PESQUISA

Como ressalta Martins (1994) a metodologia científica apresenta um grande número de diferentes tipologias de estudo, variando conforme o enfoque epistemológico e o objeto em análise.

Esta pesquisa objetiva analisar a possibilidade de se utilizar a metodologia de risco de crédito, mais especificamente o modelo de credit scoring, para avaliar o risco de inadimplência em uma instituição de ensino privado, de nível médio e fundamental, localizada na cidade do Recife. Para operacionalizar este objetivo tornou-se de fundamental importância obter informações a respeito dos indivíduos que dão origem ao risco de crédito nesta instituição, para a partir de então proceder a análise dos dados e posteriormente desenvolver os modelos de risco de crédito. As informações dizem respeito a diversas dimensões pessoais dos clientes que influenciam direta ou indiretamente a sua capacidade de quitar as mensalidades na data de vencimento.

Sendo assim, esta pesquisa pode ser classificada quanto ao método como sendo empírico-analítica, pois como estabelecido por Martins (1994) esta abordagem utiliza-se de técnicas de coleta, tratamento e análise de dados marcadamente quantitativa. O mesmo autor acrescenta que estudos deste tipo utilizam a validação da prova científica através de testes dos instrumentos, graus de significância das variáveis e sistematização das definições operacionais.

Quanto aos objetivos da pesquisa, este trabalho é classificado como explicativo (GIL, 1994), e aplicado (VERGARA, 1997). Explicativo, pois é dedicado a identificar os fatores que determinam ou contribuem para a ocorrência de determinado fenômeno, que neste caso específico é identificado como risco de crédito na instituição de ensino pesquisada. Também é classificado como aplicada, pois é motivada por um problema concreto, diferentemente da pesquisa pura que é motivada basicamente pela curiosidade intelectual do pesquisador.

O primeiro procedimento implementado na elaboração da pesquisa consistiu no levantamento da teoria relacionada ao risco de crédito que possibilitou o embasamento de todo o estudo. Posteriormente foi estruturado o banco de dados referente as características dos clientes da instituição de ensino, baseando-se nos dados que se encontram nos documentos de registros dos alunos. Depois de concluídas estas duas etapas é que existiram subsídios suficientes para o desenvolvimento dos modelos de credit scoring.

Deste modo, quanto às técnicas de investigação abordadas para a elaboração da pesquisa, o estudo pode ser classificado como bibliográfico, referindo-se a elaboração do arcabouço teórico, e documental que é caracterizada como uma investigação em documentos disponíveis na instituição de ensino, para obtenção de dados secundários que inicialmente foram coletados para a construção dos modelos (GIL, 1994).

3.2 HIPÓTESE

Uma vez estabelecido o problema de pesquisa foi formulada uma suposição provisória quanto aos resultados aguardados, a priori, a respeito dos resultados da pesquisa, e que contribuiriam para nortear o trabalho.

- A utilização de uma modelagem estatística de credit scoring constitui-se em um instrumento válido para mensurar o risco de crédito na instituição de ensino médio e fundamental explorada neste estudo.

3.3 POPULAÇÃO E AMOSTRA

Esta pesquisa está direcionada para a elaboração de uma modelagem de credit scoring para o segmento educacional. Sendo assim, a unidade de análise principal utilizada no estudo são os consumidores do serviço de educação, e seu status de adimplente ou inadimplente no que diz respeito a contraprestação pecuniária deste serviço. Entre estes consumidores encontram-se os alunos, como consumidores diretos, e os pais e responsáveis financeiros que estão envolvidos no processo de maneira indireta.

A instituição de ensino utilizada no estudo está localizada na cidade de Recife e presta serviços educacionais para os níveis fundamental e médio para uma população de 303 alunos. A identidade da instituição e de seus clientes é omitida durante toda a pesquisa por solicitação da direção da escola uma vez que aborda uma questão sigilosa e delicada, relativa a inadimplência.

Do total de 303 alunos que constam no registro da ficha cadastral da escola, 25 são contemplados com bolsas de estudo no valor integral da mensalidade por serem filhos de professores ou funcionários administrativos. Deste modo, foram eliminados da pesquisa por não satisfazer o requisito básico da obrigatoriedade em remunerar a escola pela prestação dos serviços educacionais.

Outro grupo de observações que ficou de fora do estudo, representam os alunos que possuíam ficha cadastral incompleta, contabilizando mais 12 indivíduos, além daqueles alunos que ingressaram na instituição após o mês de janeiro ou que saíram antes agosto, período estabelecido para a coleta dos

dados, que totalizam mais 21 alunos. Deste modo, a amostra final utilizada na composição dos modelos é de 245 alunos. Dentre os alunos selecionados alguns deles possuíam irmãos pagantes na instituição e possivelmente teriam os responsáveis financeiros com as mesmas características, o que leva a crer que estes indivíduos estariam sendo considerados duas vezes no mesmo modelo. Porém optou-se por utilizar todos os casos em que existiam irmãos na instituição, pois muitos deles possuíam descontos diferentes e em alguns casos são filhos de pais ou mães diferentes.

Para a seleção da amostra, de maneira representativa as características da população, são encontrados na literatura inúmeros procedimentos estatísticos que levam em consideração as diversas variáveis incluídas no estudo. No entanto, a natureza dos modelos desenvolvidos para a previsão da inadimplência exige a utilização de grandes quantidades de observações para conferir maior confiabilidade aos testes estatísticos (JOHNSTON, DINARDO, 2001; GREENE, 2002).

Sendo assim, devido as características da modelagem utilizada no estudo, do número limitado de indivíduos da população e da disponibilidade da instituição de ensino em ceder o banco de dados completo de seus clientes, optou-se pela utilização de todos os alunos para composição da amostra, sendo descartadas apenas alguns indivíduos conforme os critérios citados anteriormente, totalizando 245 observações.

3.4 COLETA DE DADOS

Os dados utilizados nesta pesquisa referem-se às características dos alunos, pais e responsáveis financeiros que consomem os serviços educacionais da instituição pesquisada. Estes dados encontram-se na forma de ficha cadastral em poder da coordenação pedagógica da instituição, e em planilhas eletrônicas sob responsabilidade do departamento financeiro.

As observações que compuseram os modelos são referentes ao período de janeiro a agosto do ano de 2006. Os dados sobre a situação de inadimplência envolvem também os anos de 2005 e 2004 e foram utilizados como variáveis defasadas nos modelos de escoragem comportamental.

Ao agrupar cada uma das observações em uma base de dados única, procurou-se considerar o maior número possível de informações que pudessem ser quantificadas, uma vez que devido a natureza do estudo não existem muitos indícios de quais variáveis são mais relevantes. Deste modo, a escolha de quais variáveis deveriam realmente compor os modelos foi reservada para os testes de significância estatística.

3.5 DEFINIÇÃO DE INADIMPLÊNCIA

A inadimplência pode ser percebida de maneira ampla como a incapacidade de pagar obrigações financeiras na data de vencimento (BEAVER, 1966). No entanto, existem peculiaridades ligadas a certos ramos de atividade que exigem uma compreensão mais elaborada a respeito deste conceito.

Ao se avaliar a qualidade de crédito no contexto da prestação de serviços educacionais faz-se necessário uma análise prévia do histórico dos atrasos, no intuito de identificar o perfil do atraso no pagamento das mensalidades. Deste modo, é possível estabelecer os limites que caracterizam os atrasos na quitação dos débitos como uma simples demora ou como caso de real incapacidade em arcar com as mensalidades pendentes.

O primeiro ponto que ressalta a necessidade de segregar os tipos de atrasos é o fato encontrado, ao se analisar os dados, de que 86,53% dos alunos, que compuseram a mostra utilizada no estudo, já apresentaram algum atraso durante o período de janeiro a agosto. Entre os que atrasaram, na média, esta situação ocorre pelo menos 5,46 vezes durante o período de 10 meses em estudo.

A tabela 2(3), apresentada em seguida, demonstra mensalmente o percentual de alunos que apresentam o pagamento da mensalidade constando em aberto, separados em categorias de 10 dias, assim como a média de dias em atraso entre os que estão com pagamento pendente.

Tabela 2 (3) - Atrasos ocorridos em 2006.								
	Até 10 dias.	Média de dias em atraso.	De 11 a 20 dias.	Média de dias em atraso.	De 21 a 30 dias.	Média de dias em atraso.	Acima de 31 dias.	Média de dias em atraso.
Jan	38,76%	6,16	27,13%	15,57	24,81%	25,09	9,30%	76,50
Fev	56,07%	3,15	8,41%	15,00	4,67%	26,40	30,84%	151,12
Mar	57,27%	2,24	8,18%	14,56	1,82%	28,50	32,73%	158,78
Abr	49,60%	2,76	6,40%	13,00	8,00%	27,50	36,00%	152,18
Maio	56,30%	2,32	3,70%	18,00	2,96%	23,25	37,04%	121,74
Jun	36,63%	2,89	3,96%	13,50	6,93%	25,29	52,48%	99,62
Jul	43,75%	2,54	5,47%	15,14	10,16%	24,23	40,63%	95,37
Ago	21,43%	3,06	4,76%	15,00	7,14%	26,50	66,67%	71,84
Set	35,58%	3,43	5,77%	15,00	7,69%	27,13	50,96%	48,40
Out	54,81%	2,32	13,33%	14,61	31,85%	25,88	0,00%	0,00 ²
Média	45,02%		8,71%		10,60%		35,67%	

Fonte: Elaborado pelo autor.

Observando a tabela 2 (3) é possível perceber que a maior parte dos atrasos, 64,34% dos casos, em média, ocorrem de 1 a 30 dias, com uma predominância dos casos onde a pendência na quitação leva de 1 a 10 dias (Este dado é obtido ao somar as médias de atrasos de 1 a 30 dias). Este fato demonstra que estes pequenos atrasos são freqüentes, mas que brevemente são solucionados.

Superando 30 dias entre a data de vencimento e o não pagamento da dívida uma nova mensalidade entra em vigor, praticamente duplicando o valor a ser pago, o que reduz a capacidade de pagamento daqueles que já demonstravam dificuldade em quitar uma única mensalidade. Suscita-se então a possibilidade de utilizar atrasos acima de 30 dias para indicar a situação de crédito como inadimplente. No entanto, os dados revelam que 86,53% dos alunos apresentam em algum momento um ou mais atrasos superiores a 30 dias, demonstrando ser uma situação que ocorre ao menos eventualmente com a grande maioria dos indivíduos.

Outro ponto que pesa contra a utilização de atrasos acima de 30 dias como critério para definição de inadimplência é que apenas 13,47% dos alunos seriam considerados adimplentes causando pouca variabilidade na variável dependente que compõe os modelos utilizados, comprometendo uma das premissas básicas para sua utilização (JOHNSTON; DINARDO, 2001).

Deste modo, diante do padrão natural de atraso encontrado ao se observar os dados, faz-se necessário flexibilizar ainda mais o conceito de inadimplência, dilatando o prazo de tolerância entre a data de vencimento da mensalidade e a data de sua quitação, de modo que seja possível separar os indivíduos que apresentam uma real dificuldade em arcar com os custos da mensalidade, daqueles que eventualmente apresentaram alguma dificuldade de pagamento durante o período de análise.

Sendo assim, para neste estudo serão considerados como indivíduos inadimplentes aqueles que apresentam mais de 60 dias de atraso no pagamento da mensalidade pelos serviços educacionais, observando como referência a data para quitação estabelecida em contrato. Ao utilizar este critério foram identificados 62 indivíduos indicando que 25,31% dos alunos ficaram devendo mais de 2 meses a mensalidade, pelo menos uma vez dentro do período de janeiro a outubro de 2006. Dentre estes alunos que ultrapassavam o prazo de 60 dias a média de atraso é de aproximadamente 5 meses.

Vale ressaltar que a condição de inadimplência assumida neste trabalho não indica necessariamente que são débitos que a empresa deverá assumir como perdas, pois existe a possibilidade de estes créditos sejam quitados posteriormente através da renegociação da dívida, ou até mesmo através de ações judiciais.

3.6 DEFINIÇÃO DAS VARIÁVEIS

A questão chave na seleção da qualidade de crédito foi estabelecida na seção anterior quando foi determinado que neste estudo serão considerados como indivíduos com baixa qualidade creditícia, ou inadimplentes, os indivíduos cujo débito supera mais de sessenta dias de atraso. Por sua vez os indivíduos que possuem mensalidades em atraso com menos de sessenta dias ou que pagam na data correta de vencimento são considerados como adimplentes. Estes critérios estabelecem a variável chave na criação dos modelos de credit scoring, identificada como a variável dependente ou a ser explicada.

O procedimento seguinte foi a identificação das variáveis independentes, ou explicativas, que são relacionadas às características dos indivíduos que consomem os serviços educacionais da instituição em análise.

O processo de identificação das variáveis explicativas que estão fortemente ligadas ao fenômeno da inadimplência deve seguir uma composição de variáveis relatadas na literatura e em estudos anteriores, assim como na experiência adquirida pelo pesquisador ao se envolver com o tema pesquisado (HAIR et al, 2002).

Estudos prévios sobre a inadimplência indicam que não existe um consenso na literatura sobre concessão de crédito, quanto as variáveis que melhor identificam o fenômeno em questão. Muitos estudos apontam para características explicativas específicas ao contexto de cada pesquisa.

Uma vez que as pesquisas sobre inadimplência no segmento de serviços são escassas, e não conclusivas quanto a determinação das variáveis independentes que melhor identificam indivíduos inadimplentes, procurou-se levar em consideração não só as características encontradas nos trabalhos pesquisados, como as que serão apresentados no quadro 2 (3), mas o maior número possível de informações disponíveis nos registros da instituição de ensino pesquisada. Reservando, assim, a função de identificar quais variáveis são efetivamente preditoras da inadimplência para os testes estatísticos realizados no desenvolvimento dos modelos.

No quadro 2(3) são apresentadas todas as características obtidas no arquivo de cadastros dos alunos fornecido pela instituição pesquisada, assim como as informações sobre inadimplência obtidas no setor financeiro da instituição e que foram selecionadas a princípio para compor a base de dados utilizada neste estudo.

Variável	Código da variável.	Natureza/ Formato	Pesquisas que utilizaram a variável
1. Reside em casa ou apartamento.	APTO	Qualitativa (dicotômica).	-
2. Bairro	BAIRROCAT	Qualitativa (categorias).	Kimura et al, (2005).
3. Telefone residencial.	FONEC	Quantitativa.	West, (2002).
4. Instrução do pai	INSTPAI	Qualitativa (categorias).	Roveda, (2002); Guimarães e Chaves Neto (2002).
5. Função exercida pelo pai.	FUNCPAI	Qualitativa (categorias).	Sugerido por Rosembeg e Gleit (1994).
6. Empresa que o pai trabalha	EMPPAI	Qualitativa (categorias).	Kimura et al, (2005); Thomas (2000); Vasconcellos, (2002).
7. Natureza da empresa empregadora do pai.	PUBP	Qualitativa (categorias).	Vasconcellos, (2002); Guimarães e Chaves Neto (2002).
8. Telefone celular do pai.	CELP	Quantitativa.	West, (2002); Guimarães e Chaves Neto (2002).
9. Instrução da mãe.	INSTMAE	Qualitativa (categorias).	Roveda, (2002); Guimarães e Chaves Neto (2002).
10. Função exercida pelo mãe.	FUNCM	Qualitativa (categorias).	Sugerido por Rosembeg e Gleit (1994).
11. Empresa que a mãe trabalha.	EMPRM	Qualitativa (categorias).	Kimura et al, (2005); Thomas (2000); Vasconcellos, (2002)
12. Natureza da empresa empregadora da mãe.	PUBM	Qualitativa (categorias).	Vasconcellos, (2002); Guimarães e Chaves Neto (2002).
13. Telefone celular da mãe.	CELM	Quantitativa.	West, (2002); Guimarães e Chaves Neto (2002).
14. Possui contrato assinado com a escola.	CONTRATO	Qualitativa (dicotômica).	-
15. Possui irmão na instituição.	IRMAOS	Qualitativa (categorias).	Vasconcelos, (2002); Desai et al, (1996); Thomas, (2000).
16. Plano de saúde.	PSAUDE	Qualitativa (categorias).	-
17. Data de vencimento da mensalidade.	DATA CAT	Quantitativa.	Kimura et al, (2005).
18. Valor pago pela mensalidade.	DESCP	Quantitativa.	Kimura et al, (2005); Vasconcellos, (2002); West, (2000).
19. Débitos no ano de 2004.	DUMMY 2004	Quantitativa.	Desai et al, (1996); West, (2000).
20. Débitos no ano de 2005.	DUMMY 2005	Quantitativa.	Desai et al, (1996); West, (2000).

Quadro 2 (3) Lista inicial de variáveis consideradas no estudo

Fonte: Elaborado pelo autor.

Como é possível observar, algumas destas características são de natureza qualitativa, não apresentando, a princípio, uma escala de medida numérica. Deste modo, precisaram receber um

tratamento para que pudessem ser enquadradas dentro de categorias e assim inseridas nos modelos estatísticos.

A seguir são apresentadas as variáveis que puderam ser enquadradas em categorias ordinais e as variáveis quantitativas que sofreram modificações.

Variável	Natureza/ Formato
1. Bairro	Quantitativa (categorias)
2. Instrução do pai	Quantitativa (categorias)
3. Função exercida pelo pai.	Quantitativa (categorias)
4. Instrução da mãe.	Quantitativa (categorias)
5. Função exercida pela mãe.	Quantitativa (categorias)
6. Quantidade de irmãos na instituição.	Quantitativa
7. Data de vencimento da mensalidade.	Quantitativa
8. Desconto oferecido pela instituição.	Quantitativa

Quadro 3 (3) Lista de variáveis transformadas apresentando categoria ordinal.

Fonte: Elaborado pelo autor.

A variável bairro foi modificada substituindo o nome original por um valor ordinal. Os bairros foram ordenados de modo decrescente seguindo o critério da renda média de cada localidade. Sendo assim foram atribuídos números mais altos para os bairros que possuem os maiores níveis de renda média, em contra partida, os bairros com menor renda receberam valores mais baixos. Os dados sobre renda média foram obtidos através do Instituto Brasileiro de Geografia e Estatística (2006).

O nível de instrução do pai e da mãe apresentado inicialmente, na ficha cadastral, em formato qualitativo, foi enquadrado dentro de categorias, onde para cada grau de instrução foi atribuído um número inteiro passando a apresentar escala ordinal. O maior nível de instrução apresentando foi o de pós graduação, o qual recebeu índice 7. Valores menores foram atribuídos a níveis de instrução mais baixos até atingir o nível 1, o qual identifica os clientes que possuem apenas o primeiro grau.

A variável função, exercida tanto pelo pai como pela mãe, que também apresentavam inicialmente formato qualitativo foi transformada em uma escala ordinal, atribuindo números inteiros para os diferentes níveis hierárquicos ocupados na empresa em que trabalham. O critério utilizado foi atribuir para o nível mais alto, denominado de diretoria, representa os ocupantes dos cargos de direção geral, superintendentes e presidência, indicados pelo valor 1. O segundo nível, representado por gerência ou supervisão, foi composto por ocupantes de chefia de setor ou divisão e direção de departamento, sendo atribuído o número 2. O número 3 foi atribuído para as funções operacionais

exercidas por agentes administrativos e operacionais, secretários, assistentes, auxiliares, atendentes, entre outros.

Em relação aos alunos que possuem irmãos na mesma instituição de ensino foi utilizado o seguinte critério de categorização: 0 para os alunos que não possuem irmãos ou que os demais são bolsistas, 1 para os que possuem mais um irmão pagante e 2 para mais dois irmãos pagantes. A variável inicialmente apresentava o nome dos irmãos e as respectivas series.

A variável data de vencimento da mensalidade já apresenta escala ordinal e foi utilizada na sua forma original. Por sua vez o valor pago na mensalidade foi utilizado para calcular o desconto oferecido, o qual efetivamente entrou no modelo, apresentando também escala de razão.

As variáveis cuja resposta pode assumir apenas dois valores puderam ser artificialmente quantificadas, seguindo procedimento sugerido por Johnston e Dinardo (2001), onde é atribuído o número 1 para indicar a presença de um atributo e 0 quando esta característica não está presente. Os autores estabelecem também que estas duas categorias devem ser mutuamente exaustivas e exclusivas sob pena de inviabilizar a utilização dos modelos que se baseiam na análise de regressão, por tornar a matriz de dados singular. Isto quer dizer que ao criar, por exemplo, uma variável status de pagamento devem ser representadas todas as situações possíveis, neste caso, a inadimplência e a adimplência. Sendo que apenas uma delas pode ser representada no modelo assumindo o valor 1.

As variáveis qualitativas que sofreram o processo de quantificação pela presença ou ausência de um atributo são denominadas de variáveis dummy ou de escolha dicotômica. São apresentadas na tabela 3(3) as características que foram transformadas através do processo descrito acima.

Tabela 3 (3) Lista de variáveis dicotômicas.

Variável	Categoria
1. Residência.	0 – Reside em apartamento. 1 – Reside em casa.
2. Telefone residencial.	0 – Não possui telefone residencial. 1 – Possui telefone residencial.
3. Telefone celular do pai.	0 – Pai não possui celular. 1 – Pai possui celular.
4. Emprego pai.	0 – Desempregado. 1 – Pai está empregado/ autônomo.
5. Emprego público pai.	0 – Pai não possui emprego público. 1 – Pai possui emprego público.
6. Telefone celular da mãe.	0 – Mãe não possui celular. 1 – Mãe possui celular.
7. Emprego mãe.	0 – Desempregada. 1 – Mãe está empregada/ autônoma.
8. Emprego público mãe.	0 – Mãe não possui emprego público. 1 – Mãe possui emprego público.
9. Contrato.	0 – Não possui contrato com a escola. 1 – Possui contrato com a escola.
10. Plano de saúde.	0 – Não possui plano saúde. 1 – Possui plano de saúde.

Dentre as variáveis demonstradas, o contrato apresenta uma interpretação menos intuitiva que as demais, necessitando de uma explicação adicional. A variável contrato foi introduzida para identificar os alunos que possuíam o documento formal de prestação de serviços com a instituição de educação. O contrato é assinado no ato da matrícula e fica arquivado no departamento financeiro, porém alguns representantes dos alunos optam por não assinar o contrato de imediato, sob o pretexto da necessidade de uma análise mais detalhada. Nestas circunstâncias alguns pais e responsáveis finalizam o ano não devolvendo o documento assinado.

Para elaborar os modelos que levam em consideração escoragem comportamental foram abordadas as variáveis que representam o histórico dos alunos no que diz respeito inadimplência. Compõe o modelo comportamental, além das variáveis já apresentadas, duas variáveis referentes ao retrospecto de inadimplência dos anos de 2005 e 2004. Fonte: Elaborado pelo autor.

Tabela 4 (3) Lista de variáveis dicotômicas históricas.

Variável	Categoria
1. Inadimplência 2005.	0 – Não possui mensalidades vencidas em 2005. 1 – Possui mensalidades em 2005.
2. Inadimplência 2004.	0 – Não possui mensalidades vencidas 2004. 1 – Possui mensalidades vencidas em 2004.

Fonte: Elaborado pelo autor.

As duas variáveis representam débitos acima de 60 dias que aconteceram nos dois anos anteriores a este estudo, demonstradas através de uma dummy. Onde 0 foi atribuído a ausência de débitos e 1 indica a existência de mensalidades vencidas a mais de 60 dias.

3.7 MEDIDAS DE AJUSTAMENTO DOS MODELOS E SOFTWARE

A partir do desenvolvimento dos modelos, foram utilizadas medidas de sensibilidade para avaliar o grau de ajustamento dos dados previstos em relação aos fornecidos. Serão demonstrados a seguir os artifícios utilizados para mensurar a precisão dos modelos obtidos na previsão da inadimplência utilizando as técnicas de análise discriminante, regressão logística e redes neurais.

O procedimento mais intuitivo, sugerido por Amemyia (1981), é desenvolver os modelos e verificar na prática quais observações são classificadas corretamente como inadimplentes e adimplentes, e quais delas foram classificadas equivocadamente. De posse destas informações é gerada uma matriz dos resultados, também denominada de matriz de classificação onde é possível identificar a capacidade preditiva do modelo de uma maneira geral, observando o total de dados classificados corretamente, e seu desempenho dentro de cada grupo.

Sendo assim o primeiro passo no desenvolvimento da matriz de classificação foi a separação dos dados em amostras de validação e teste. A primeira é utilizada na modelagem das equações onde os dados contribuem na estimação dos coeficientes. Os dados de teste, por sua vez, são utilizados para verificar a precisão das equações desenvolvidas. Este procedimento, denominado de validação cruzada, propicia uma medida da capacidade de generalização da equação obtida pelo modelo, uma vez que a previsão ocorre sobre um conjunto de dados que não haviam sido apresentados anteriormente.

Após a separação dos dados, o procedimento seguinte foi a multiplicação dos pesos, encontrados nas funções obtidas com os modelos logit e discriminante, sobre as variáveis dependentes que apresentaram poder de previsão estatisticamente significativo.

Ao se atribuir os pesos foram encontrados escores que indicam a situação de inadimplência ou não. Essas previsões foram tomadas como referência e comparadas com os dados originais. Ao obter as informações sobre os percentuais corretamente classificados dentro dos grupos adimplente e inadimplente, foram estruturadas matrizes de classificação que serviram de base para comparação entre os diferentes modelos.

O grau de precisão do modelo baseado nas redes neurais também foi elaborado a partir de uma matriz de classificação. Uma vez que as relações intrínsecas, não lineares, da rede não são apresentadas pelo modelo, o próprio software utilizado no estudo se encarrega de tomar a amostra de teste, atribuir os pesos e estruturar as relações desenvolvidas na fase de aprendizado, apresentando diretamente sua previsão.

O ponto crítico utilizado na avaliação dos modelos é identificar a sua precisão relativa ao acerto obtido por mera aleatoriedade, também denominado de critério por chances. O critério utilizado para verificar se a precisão dos modelos é estatisticamente superior a probabilidade de acerto por mero acaso é o teste Q de Press. Segundo Hair et al (2002) este teste é uma medida que avalia o número de acertos obtidos relativamente ao tamanho da amostra utilizada e o número de grupos a serem alocados. O valor do teste Q de Press é obtido da seguinte maneira:

$$Q \text{ de Press} = \frac{[N - (nK)]^2}{N(K - 1)} \quad , \text{ onde:}$$

N = tamanho da amostra total.

n = número de observações corretamente classificadas;

K = número de grupos.

Esta estatística segue uma distribuição qui-quadrada com K - 1 um graus de liberdade, onde K corresponde ao número de grupos. Deste modo, o valor resultante do teste é comparado com uma distribuição qui-quadrada para 1 grau de liberdade, pois existem apenas dois grupos e um nível de significância de 0,05. Utilizando este procedimento pode-se afirmar que a matriz de classificação é superior ao critério de acerto aleatório, quando o valor do teste é superior ao valor tabelado.

O critério de acerto aleatório, ou critério de chances, é definido como a possibilidade de se obter um percentual de classificação correta sem a utilização dos modelos (Hair et al, 2002).

O critério por chances pode ser calculado sob duas perspectivas, a de chance máxima e a proporcional. A chance máxima de acerto ocorre quando se possui dois grupos de tamanhos diferentes, sendo designada pelo percentual de acerto que se obteria ao classificar todos os indivíduos como pertencentes ao grupo mais numeroso.

Por sua vez o critério de acerto por chances proporcionais leva em consideração a possibilidade de acerto proporcional ao tamanho dos dois grupos distintos;

A opção por cada um dos critérios cabe aos objetivos pelos quais os modelos estão sendo desenvolvidos. As chances máximas são mais indicadas quando o objetivo da construção do modelos é maximizar o percentual de dados corretamente classificados. Por outro lado, as chances proporcionais são mais indicadas quando existem grupos de tamanhos diferentes e deseja-se identificar corretamente os membros de todos os grupos (HAIR et al, 2002).

Como o objetivo desta pesquisa é voltado para o desenvolvimento de modelos de crédito, tentando identificar os indivíduos quanto a sua perspectiva futura de inadimplência ou adimplência, o critério mais adequado demonstra ser o de chances proporcionais.

Os dados deste trabalho apresentam uma proporção desigual entre inadimplentes e adimplentes, sendo 25% para os primeiros e 75% para o segundo grupo. Deste modo o cálculo do critério de acerto por mero acaso, baseado na proporção dos grupos que compõe a mostra, utiliza o seguinte método:

$$C_{\text{PROPORCIONAL}} = p^2 + (1 - p)^2$$

p = proporção de indivíduos no grupo 1 .

$1 - p$ = proporção de indivíduos no grupo 2.

Sendo assim, a amostra de dados utilizada neste estudo tem um percentual de acerto por mera aleatoriedade de 62,50%. Este percentual será o valor que balizará a sensibilidade preditiva dos modelos desenvolvidos.

Caso o critério por chances máxima fosse adotado o percentual máximo de acerto obtido ao se classificar todos os indivíduos dentro do maior grupo, que neste caso são os adimplentes, seria de 75%

Os softwares utilizados no desenvolvimento dos modelos de regressão logística e análise discriminante, assim como os testes de normalidade, heterocedasticidade e ajustamento dos modelos, foram o SPSS 11 e o Eviews 5.0. Para a operacionalização dos modelos de redes neurais foi utilizado o Statistica 7.0.

4 RESULTADO

4.1 MODELOS DESENVOLVIDOS

Os capítulos anteriores trataram de estabelecer a base teórica das técnicas que serão utilizadas no desenvolvimento dos modelos de credit scoring, além de descrever a variável chave para o estudo, a qualidade de crédito, e os principais atributos das variáveis independentes. Cabe então demonstrar o desenvolvimento dos modelos e discutir seus resultados.

Dentre os 303 casos obtidos junto a instituição pesquisada, foram eliminados 58 indivíduos devido ao recebimento de bolsas de estudo, da inadequação das informações prestadas ou pela sua ausência. Dentre os 245 casos restantes que compuseram a amostra final utilizada no estudo, aproximadamente 25% dos dados, 61 observações, foram reservadas como amostra de teste no intuito de realizar uma validação cruzada. Neste procedimento os 184 casos restantes foram utilizados no desenvolvimento dos modelos e sua capacidade avaliada através do desempenho em prever corretamente os dados contidos na amostra de teste.

Deste modo a equação discriminante é gerada com base em aproximadamente 75% dos casos, sendo aplicada posteriormente nos 25% restante que não haviam sido apresentados na geração dos modelos. Utilizando este artifício, denominado de validação cruzada, é possível ter uma medida da mensuração realista da capacidade preditiva dos modelos.

No intuito de conferir um caráter aleatório aos dados que foram reservados como amostra de testes, e que sua composição possuisse as mesmas características da amostra original, onde 75% dos dados correspondem a adimplentes e 25% a inadimplentes, foram tomadas as seguintes providências.

Foram separados todos os dados dos inadimplentes e atribuídos números pseudo-aleatórios, gerados no SPSS, a cada uma das observações. Ao colocar os números em ordem crescente os primeiros 25% foram selecionados para a amostra de testes e os restantes utilizados no desenvolvimento dos modelos. Procedimento análogo foi elaborado para selecionar os dados de adimplentes que compuseram a amostra de teste.

A literatura financeira direcionada ao risco de crédito não especifica o percentual de dados que devem ser reservados para as etapas de modelagem e teste. A escolha que foi utilizada neste estudo está baseada nas mesmas proporções apresentadas pelo conjunto inicial de variáveis.

Outro fator que motivou esta segregação das amostras foi o fato de que a quantidade de casos utilizados na modelagem devem ser em número suficiente para incluir operações de crédito representativas de todas as operações, ou seja, preferencialmente que o maior número possível de informações sejam abarcadas durante a modelagem (VASCONCELOS, 2002).

É necessário enfatizar que abranger o maior número possível de observações é a opção mais interessante ao se utilizar a ADL e regressão logística, pois estas técnicas não dispõem da mesma capacidade de aprendizado das redes neurais, a qual tem o poder de extrapolar sua previsão para dados nunca vistos.

4.1.1 ANÁLISE DISCRIMINANTE

4.1.1.1 ANÁLISE DISCRIMINANTE – APROVAÇÃO DE CRÉDITO

Ao analisar os modelos ADL é necessário realizar uma prévia averiguação quanto ao cumprimento de seus pressupostos.

A análise discriminante é um dos métodos mais utilizados na avaliação do potencial uso de credit scoring na análise de risco de crédito. No entanto, sua utilização deve-se muito menos a sofisticação da técnica e mais ao fato de ter sido uma das primeiras técnicas utilizadas no estudo do risco creditício, e responsável por impulsionar o desenvolvimento da análise de risco chamando a atenção para seu grande potencial de utilização prática.

O primeiro pressuposto analisado é quanto a normalidade das variáveis. Para esta averiguação foram utilizados os testes de Kolmogorov Smirnov e Jarque Berra. Vale ressaltar que dentre as 20 variáveis utilizadas algumas delas são de natureza dicotômica e não podem assumir distribuição normal. Coube então analisar a gaussianidade das variáveis: INSTPAI, INSTMAE, DESCP, FUNCPAI E FUNCMAE. A seguir são apresentadas as estatísticas obtidas para os dados:

Tabela 5 (4): Teste de normalidade.

Variável	Kolmogorov-Smirnov.	Probabilidade K - S.	Jarque - Bera.	Probabilidade J - B.
DATA CAT	3,40	0,0000	104,32	0,0000
INSTPAI	6,25	0,0000	65,70	0,0000
FUNCPAI	5,47	0,0000	19,92	0,0000
INSTMAE	5,94	0,0000	50,13	0,0000
FUNCM	4,72	0,0000	17,20	0,0001
DESCP	2,97	0,0000	117,98	0,0000
BAIRROCAT	4,32	0,0000	277,90	0,0000

Fonte: Elaborado pelo autor.

O teste de Kolmogorov Smirnov possui uma regra de decisão onde as variáveis cujo valor da estatística que forem inferiores ao valor Z crítico tabelado de 1,96, para um nível de confiança de 95%, podem ser considerados como gaussianas.

Por sua vez, o teste Jarque Berra indica que para uma amostra de tamanho razoável, a estatística segue uma distribuição qui-quadrada com 2 graus de liberdade. A regra de decisão utilizada para identificar a gaussianidade é baseada no valor da probabilidade apresentada pelo teste, onde valores acima de 0,05 levam a não rejeição da hipótese de normalidade.

Como é possível perceber nenhuma das variáveis atingiu níveis críticos em nenhum dos dois testes para que pudessem ser considerados como próximos da normalidade. Conseqüentemente foi necessário implementar transformações sobre as variáveis para que alcançassem o formato gaussiano desejado. A técnica utilizada foi a de Box-Cox, a qual indica um valor ótimo, “lambda”, o qual deve ser elevado a potência da variável para que esta alcance um formato aproximadamente gaussiano.

As variáveis FUNCPAI e FUNCMAE DESCP por assumirem em algumas observações os valores de zero não puderam ser transformadas, pois o método Box-Cox forneceu valores para transformação abaixo de 1 impossibilitando sua utilização nestas variáveis, sendo então descartadas.

Após proceder a transformação Box-Cox nas variáveis BAIRROCAT, DATA CAT, INSTMAE e INSTPAI foram obtidos os seguintes resultados.

Tabela 6 (4): Teste de normalidade das variáveis transformadas .

Variável Transformada	Kolmogorov-Smirnov.	Probabilidade K - S.	Jarque - Bera.	Probabilidade J - B.
BAIROCAT	3,17	0,0000	18,69	0,0001
DATA CAT	4,43	0,0000	18,51	0,0001
INSTPAI	5,75	0,0000	25,85	0,0000
INSTMAE	6,07	0,0000	26,65	0,0000

Fonte: Elaborado pelo autor.

Como é possível perceber nenhuma das duas estatísticas indicou a aproximação da distribuição das variáveis com um formato gaussiano. Eliminando definitivamente a possibilidade de se obter a normalidade dos dados e satisfazer o primeiro pressuposto da ADL. Um fator que possivelmente contribuiu para este resultado foi a escala reduzida em que algumas variáveis estavam estruturadas.

Apesar da não obtenção da normalidade dos dados, procedeu-se com o exame dos pressupostos do modelo, tomando por base o fato que o desenvolvimento do modelo de credit scoring tem com principal foco uma estimativa de ponto. Segundo Gujarati (2000) ao se gerar uma regressão tendo como principal objetivo um estimativa de ponto a não normalidade dos dados não se configura como uma limitação que inviabiliza a modelagem.

O próximo pressuposto a ser observado no intuito de identificar a viabilidade da utilização da análise discriminante é a verificação da igualdade das matrizes de variância e covariância, que indica a presença da homocedasticidade entre os erros da regressão.

Para operacionalizar este teste foi necessário gerar o modelo de análise discriminante preliminar, e posteriormente identificar a presença do viés causado pela não homocedasticidade dos erros da regressão. Sendo assim, procedeu-se com a geração da regressão, onde o método utilizado foi o de mínimos quadrados ordinários, o qual obtém o ajuste da reta de regressão através da minimização do erro quadrático médio. Por sua vez, a seleção das variáveis foi realizada pelo mecanismo stepwise, que, como mencionado anteriormente, seleciona as variáveis de acordo com seu poder de previsão. Os resultados desta regressão preliminar são apresentados a seguir:

Tabela 7 (4): Modelo de aprovação de crédito preliminar - análise discriminante.

Variáveis	Coeficientes	Erros padrão	Estatística t	Probabilidade
INSTMAE	-0,0667	0,0222	-3,0073	0,0030
INSTPAI	-0,0508	0,0225	-2,2581	0,0251
FUNCM	0,1273	0,0444	2,8662	0,0046
BAIROCAT	-0,0044	0,0021	-2,0692	0,0399
CONTRATO	-0,1850	0,0713	-2,5926	0,0103
CONSTANTE	1,2214	0,1905	6,4096	0,0000

Fonte: Elaborado pelo autor.

Para comprovar a presença da heterocedasticidade foi utilizado o teste geral de White. Este teste é indicado para os casos em que não se conhece a variável independente que está causando a heterocedasticidade, além de não ser sensível a hipótese de normalidade. (GUJARATI, 2000).

O teste de White pode ser facilmente obtido após a geração do modelo preliminar de aprovação de crédito, mesmo estando ciente da possibilidade da heterocedasticidade. O resíduo obtido por esta regressão é utilizado como insumo para a realização de uma regressão auxiliar, composta pelos resíduos elevados ao quadrado em função das variáveis independentes, de seus valores elevados ao quadrado e da multiplicação das variáveis duas a duas.

Uma vez realizados estes procedimentos o teste de White indica que o valor do R², obtido na regressão auxiliar, multiplicado pelo número de observações na amostra, segue uma distribuição qui-quadrada com graus de liberdade iguais ao número de variáveis na regressão auxiliar menos o termo constante. Caso o valor obtido pelo teste supere o valor qui-quadrado tabelado ao nível de confiança escolhido de 95% pode-se afirmar que heterocedasticidade está presente na regressão.

Após a realização dos procedimentos explicitados anteriormente foi obtido o seguinte resultado:

Tabela 8 (4): Teste de heterocedasticidade de White, aprovação de crédito - análise discriminante.

Estatística F	2,9971	Probabilidade	0,0000
Estatística White	47,423	Probabilidade	0,0003

Fonte: Elaborado pelo autor.

Comparando o valor encontrado pelo teste de 47,4237 com o valor tabelado qui- quadrado, para 19 graus de liberdade, de 30,1435 é possível confirmar que a utilização da análise discriminante nestas circunstancias produziria resíduos com diferentes variâncias, ou seja, erros heterocedásticos.

A consequência desta heterocedasticidade para a análise de regressão é que os erros padrão, os testes t e suas probabilidades estão viesados e não fornecem estatísticas confiáveis. (GREENE, 2002).

Por outro lado, Johnston e Dinardo (2001) afirmam que a ausência de homocedasticidade na análise de regressão não inviabiliza sua utilização, pois a estimativa dos coeficientes das variáveis independentes continuam sendo não viesadas e consistente, e sugerem o procedimento de correção de White para atingir as ineficiências apresentadas, porém preservando as estimativas pontuais dos parâmetros.

A demonstração matemática da correção de White é bastante complexa, porém Johnston e Dinardo (2001) afirmam, de maneira simples, que este procedimento consiste na utilização de um vetor de erros quadráticos na construção da ponderação da matriz de variância.

Deste modo, a análise discriminante foi elaborada para o modelo de aprovação de crédito baseando-se na correção de White, utilizada para retificar o viés produzido pela heterocedasticidade. Sua operacionalização ocorreu através do software Eviews 5.0, que disponibiliza a opção para a correção de maneira direta. Foram obtidos os seguintes resultados:

Tabela 9 (4): Modelo de aprovação de crédito - análise discriminante.				
Variável	Coeficiente	Erro Padrão	Estatística t	Probabilidade
INSTMAE	-0,0667	0,0243	-2,7440	0,0067
INSTPAI	-0,0508	0,0255	-1,9876	0,0484
FUNCM	0,1273	0,0464	2,7406	0,0068
CONTRATO	-0,1850	0,0795	-2,3272	0,0211
BAIRROCAT	-0,0044	0,0023	-1,9257	0,0557
CONSTANTE	1,2214	0,1950	6,2606	0,0000

Fonte: Elaborado pelo autor.

Tabela 10 (4): Centróides e parâmetros para classificação do modelo de aprovação de crédito - análise discriminante.		
Escores	Clientes inadimplentes	Clientes Adimplentes
Centróides	0,4734	0,2066
Ponto de corte crítico (Critério utilizado na classificação)	Escore > 0,2722	Escore <0,2722

Fonte: Elaborado pelo autor.

Observando o modelo de análise discriminante já corrigido pelo mecanismo de White e comparando com o modelo preliminar apresentado na tabela 8(4), percebe-se que presença da heterocedasticidade subestimou os erros padrão e viesou o resultado dos testes t e sua respectiva probabilidade, o que poderia levar a interpretação equivocada da significância dos coeficientes da regressão.

No entanto, mesmo após corrigir a heterocedasticidade foi possível notar que os coeficientes continuaram significativos para o nível de confiança de 95%, com exceção da variável bairro que tornou-se marginalmente significativa, mas foi mantida no modelo por apresentar um valor muito pouco superior ao limite de 0,05 estabelecido.

Prosseguindo com verificação dos pressupostos da análise discriminante foi analisado suposição da ausência de multicolinearidade entre as variáveis. O critério utilizado foi o fator inflação de variância (FIV), que indica como a variância de um estimador aumenta na presença da multicolinearidade (GUJARATI, 2000). O fator inflação de variância é dado por:

$$FIV = \frac{1}{(1 - r_{12}^2)}, \text{ onde o } r_{12}^2 \text{ indica o coeficiente de correlação entre duas variáveis independentes.}$$

A medida que o r^2 se aproxima de 1, ou seja a colinearidade aumenta, a variância de um estimador aumenta indefinidamente. Como regra prática o Gujarati (2000) sugere a utilização de um limite de 10 para o FIV, onde a partir deste limite a variável é considerada altamente colinear. A seguir são apresentados os valores dos fatores inflação de variância:

Tabela 11 (4): Teste de fator inflação de variância, aprovação de crédito - análise discriminante.		
Variável	VIF	Tolerância
INSTMAE	1,2384	0,8074
BAIRROCAT	1,1027	0,9068
INSTPAI	1,1062	0,9039
FUNCM	1,1758	0,8504
CONTRATO	1,1546	0,8660

Fonte: Elaborado pelo autor

Observando a tabela 11(4) é possível constatar que nenhum FIV aproximou-se do limite de 10. Deste modo, pode-se considerar que nenhuma das variáveis apresentou forte colinearidade.

O modelo final de aprovação de crédito é apresentado na tabela 9(4), e pode ser reescrito na forma da seguinte equação:

$$Z_i = 1,2214 - 0,0667 \times INSTMAE - 0,05085 \times INSTPAI + 0,1273 \times FUNCN - 0,1850 \times CONTRATO - 0,0044 \times BAIRROCAT$$

, onde Z_i indica a pontuação do indivíduo i .

A multiplicação de cada uma das variáveis, referentes às características dos alunos e responsáveis, pelo respectivo coeficiente encontrado na regressão produz a pontuação de cada cliente, apresentada como Z_i . Esta pontuação é utilizada com um indicativo da propensão de que um indivíduo pertença ao grupo de adimplentes ou inadimplentes. Hair et al (2002) sugerem a criação de um escore de corte ótimo, de modo que a partir deste valor crítico os indivíduos possam ser enquadrados em uma das duas categorias.

Uma vez que a quantidade de bons e maus pagadores contidos na amostra não é igual, Hair et al (2002) estabelecem que a estimativa do ponto de corte nestas circunstâncias deve levar em consideração as proporções encontradas na amostra, o que pode ser obtido através da seguinte equação:

$$Z_{corte} = \frac{N_A \times Z_A + N_I Z_I}{N_A + N_B}, \text{ onde:}$$

N_A = Número de indivíduos no grupo de adimplentes;

N_B = Número de indivíduos no grupo de inadimplentes;

Z_A = Centróide do grupo de adimplentes;

Z_B = Centróide do grupo de inadimplentes.

Aplicando esta fórmula aos centróides apresentados na tabela 10(4), e aos percentuais de 25% de inadimplentes e 75% de adimplentes, foi encontrado o valor de corte crítico de 0,2722. Deste modo todo indivíduo analisado que possui um escore acima de 0,2722 é considerado como inadimplente e abaixo deste valor é considerado como adimplente.

O modelo final obtido na análise discriminante contou com as variáveis de instrução do pai e da mãe, a função que a mãe exerce, a presença do contrato e o bairro de residência. A opção por estas variáveis independentes foi estabelecida pela capacidade explicativa, conforme estabelece o método stepwise. São apresentadas a seguir algumas considerações a respeito destas variáveis.

INSTPAI: A variável nível de instrução do pai indica que para cada aumento de uma unidade na categoria de escolaridade do pai há uma redução de 0,05 na pontuação que indica a probabilidade de que o aluno venha a se tornar inadimplente. Este resultado é plausível a medida que espera-se que pessoas com maior nível de instrução sejam melhor remuneradas do que aquelas que possuem baixo nível de escolaridade, e assim obtenham melhores condições de quitar seus débitos sem atrasos. A interpretação deste coeficiente deve ser realizada de modo que se pressuponha que todos as demais variáveis permanecem estáveis (condição *ceteris paribus*).

INSTMAE: da mesma maneira que o nível de escolaridade do pai, o grau de instrução da mãe apresenta-se como um redutor da pontuação de inadimplência, uma vez que o coeficiente apresenta sinal negativo. A medida que aumenta um nível na categoria de instrução da mãe o modelo indica que há uma redução de 0,06 na possibilidade de se incorrer na inadimplência, desde que as demais variáveis permaneçam estáveis. De modo análogo ao pai a instrução da mãe adquiriu sinal negativo, pois se espera que para maiores níveis de instrução as pessoas sejam melhor remuneradas e assim possam arcar com suas despesas.

FUNCM: A variável referente a função que a mãe ocupa dentro da empresa indica que quanto mais operacional o cargo exercido maior é a possibilidade de se tornar inadimplente. É importante ressaltar que esta variável foi estruturada indicando que os funcionários que ocupam funções de cúpula como presidentes, diretores e superintendentes receberam a indicação de nível 1, os chefes de departamento e divisão receberam o nível 2 e as funções mais operacionais receberam nível 3. Deste modo para o aumento de um nível na escala que indica funções mais operacionais, a pontuação indicativa da inadimplência aumenta em 0,127, dado que as demais variáveis permaneçam inalteradas. De modo semelhante ao nível de instrução, espera-se que indivíduos que ocupem cargos mais elevados sejam melhor remunerados do que aqueles que ocupam os cargos operacionais

CONTRATO: esta variável indica os pais ao matricularem seus filhos assinaram e entregaram o contrato de prestação de serviços com a instituição de educação. Segundo os resultados obtidos pelo modelo, este fator lhes confere uma maior propensão a serem bons pagadores. A existência do contrato indica uma diminuição de 0,185 na pontuação que indica a possibilidade de incorrer na inadimplência, dado que todas as outras variáveis permanecem constantes. Como é possível observar na tabela 9(4) o contrato detém o menor coeficiente entre as variáveis apresentadas. Sendo assim, pode-se afirmar que a presença do contrato exerce a influencia mais significativa na redução da pontuação de crédito que identifica os maus pagadores, indicando que os pais que assinaram o

documento assumindo o débito referente aos doze meses de prestação de serviço educacional tem uma maior propensão a quitarem seus débitos em tempo oportuno.

Cabe esclarecer que a existência de um contrato, assumido entre o indivíduo e a instituição de ensino, não é um fato capaz de influenciar a sua disponibilidade de recursos. Porém supõe-se que os pais e responsáveis ao assinarem o contrato demonstram a princípio uma segurança quanto a sua capacidade de arcar com as despesas incorridas. Outro fato que contribui para a explicação desta variável, é que a presença do contrato pode ser percebida como um incentivo adicional para a quitação das mensalidades, uma vez que existe um documento reconhecendo o valor anual a ser pago, e que pode ser utilizado como prova no caso de uma ação judicial.

BAIRROCAT: de acordo com o resultado obtido pelo modelo é possível constatar uma relação inversa entre a renda média dos bairros e a inadimplência, uma vez que o sinal obtido pelo coeficiente da variável foi negativo. Deste modo é possível afirmar que ao progredir em uma unidade na categoria bairro, que foi ordenada pela renda média, a pontuação que indica a inadimplência é reduzida em 0,0044, tomando todas as outras variáveis constantes, ou seja, indivíduos residentes em bairros com maior renda média tem uma menor propensão de se tornar inadimplente.

4.1.1.2 ANÁLISE DISCRIMINANTE – BEHAVIORAL SCORING

O desenvolvimento do modelo de análise discriminante – behavioral scoring seguiu os mesmos procedimentos para seleção de variáveis, verificação de heterocedasticidade e multicolinearidade que foram utilizadas no modelo de aprovação de crédito. A única diferença entre os modelos é a incorporação das variáveis referentes ao histórico de débitos dos anos de 2004 e 2005 pelo modelo comportamental.

O desenvolvimento do modelo de behavioral scoring foi iniciado com a geração do modelo preliminar, a partir do qual foram realizadas as verificações dos pressupostos da análise discriminante.

A opção stepwise foi novamente utilizada para a seleção inicial das variáveis que compõe o modelo com melhor desempenho preditivo sobre a inadimplência, onde a opção pela entrada das variáveis na regressão baseia-se na sua contribuição para a segregação das observações entre os grupos adimplentes e inadimplentes.

Utilizando o método dos mínimos quadrados ordinários foi desenvolvido o seguinte modelo comportamental preliminar:

Tabela 12 (4): Modelo de *behavioral scoring* preliminar - análise discriminante.

Variável	Coefficiente	Erro Padrão	Estatística t	Probabilidade
DUMMY 2005	0,5112	0,0672	7,6016	0,0000
INSTMAE	-0,0636	0,0187	-3,3840	0,0009
FUNCM	0,1196	0,0392	3,0475	0,0027
CONTRATO	-0,1714	0,0635	-2,6985	0,0076
CONSTANTE	0,4987	0,1042	4,7829	0,0000

Fonte: Elaborado pelo autor.

De posse dos resultados do modelo preliminar, procedeu-se então com a verificação do pressuposto da homocedasticidade através do teste geral de heterocedasticidade de White. Os resultados do teste podem ser visualizados na tabela 13(4) a seguir:

Tabela 13 (4): Teste de heterocedasticidade de White, *behavioral scoring* – análise discriminante.

Estatística F	2,721343	Probabilidade	0,0021
Estatística White	29,50427	Probabilidade	0,0033

Fonte: Elaborado pelo autor.

Como comentado anteriormente o resultado do teste de White segue uma distribuição qui-quadrada com graus de liberdade iguais ao número de regressores utilizados na regressão acessória do teste, neste caso 12. O valor qui-quadrado tabelado, referente a 5% de significância e 12 graus de liberdade, é de 21,0261, bem abaixo do valor calculado pelo teste. Este resultado indica que a utilização da regressão das variáveis obtidas pelo procedimento stepwise sobre a variável dependente inadimplência será afetada pela heterocedasticidade, ou seja, as inferências sobre os erros padrão da regressão, assim como o teste t e sua significância possivelmente serão viesados.

Baseando-se nos resultados obtidos pelo teste de heterocedasticidade apresentado anteriormente, optou-se pela utilização da correção de White a qual possibilita a obtenção de erros padrão, estatística t, e sua probabilidade, consistentes mesmo na ausência de homocedasticidade. O resultado da regressão com a correção de White é apresentado a seguir:

Tabela 14 (4): Modelo de <i>behavioral scoring</i> - análise discriminante.				
Variável	Coefficiente	Erro Padrão	Estatística t	Probabilidade
DUMMY 2005	0,5112	0,0827	6,1776	0,0000
INSTMAE	-0,0636	0,0202	-3,1467	0,0019
FUNCM	0,1196	0,0363	3,2954	0,0012
CONTRATO	-0,1714	0,0720	-2,3812	0,0183
CONSTANTE	0,4987	0,1242	4,0129	0,0001

Fonte: Elaborado pelo autor.

Observando a tabela 14(4) é possível perceber o erro padrão de quase todas as variáveis foram superiores em comparação ao modelo provisório, demonstrando que os erros padrão estavam subestimados acarretando níveis mais significativos de probabilidade. Muito embora percebe-se que mesmo após a correção de White o valor das probabilidades continuam muito abaixo dos 5% de significância, demonstrando que a heterocedasticidade, comprovadamente presente, não estava influenciando de forma intensa nos resultados.

O segundo pressupostos analisado foi quanto a colinearidade entre as variáveis explicativas. O teste utilizado na verificação foi o fator inflação de variância (FIV), o qual é capaz de indicar o quanto a variância de um estimador aumenta na presença da colinearidade, sendo obtidos os seguintes resultados:

Tabela 15 (4): Teste de fator inflação de variância para <i>behavioral scoring</i> – análise discriminante.	
Variáveis	VIF
DUMMY 2005	1,0536
INSTMAE	1,1172
FUNCM	1,1558
CONTRATO	1,1524

Fonte: Elaborado pelo autor.

A tabela 15(4) demonstra que as estatísticas obtidas no teste ficaram bem abaixo do valor limite de 10, sugerido por Gujarati (2000) com indicativo da presença de multicolinearidade. Deste modo pode-se afirmar que a utilização das variáveis regressoras: instrução da mãe, a função exercida pela mãe, o contrato e a variável *dummy* 2005 não apresentam indícios de que são afetadas pela multicolinearidade.

Após corrigir a heterocedasticidade e verificar a ausência da multicolinearidade foi possível aplicar o modelo encontrado aos dados referentes as características dos indivíduos pesquisados. O modelo análise discriminante – *behavioral scoring* é apresentado, a seguir, na forma de equação:

$$Z_i = 0,4987 + 0,5112 \times DUMMY2005 - 0,0636 \times INSTMAE + 0,1196 \times FUNCM - 0,1714 \times CONTRATO, \quad \text{onde}$$

Z_i indica a pontuação do indivíduo i .

De modo análogo ao modelo de aprovação de crédito, ao proceder a multiplicação dos coeficientes obtidos no modelo comportamental, pelos respectivos valores das variáveis independentes, referentes as características dos pais e alunos, é obtido uma pontuação de crédito, a qual indica a propensão de que um indivíduo pertença ao grupo de adimplentes ou inadimplentes.

O ponto crítico estabelecido como critério para segmentar os bons dos maus pagadores levou em consideração as proporções de cada grupo na amostra e seu respectivo valor da centróide. Foi obtido então um escore de corte de 0,2861, onde os indivíduos que apresentaram pontuação superior a este valor foram considerados como inadimplentes e adimplentes caso contrário, conforme pode ser observado na tabela 16(4), a seguir:

Tabela 16 (4): Centróides e parâmetros para classificação do modelo de <i>behavioral scoring</i> - análise discriminante.		
Escores	Clientes inadimplentes	Clientes adimplentes
Centróides	0,6496	0,1676
Ponto de corte crítico (Critério utilizado na classificação)	Escore > 0,2861	Escore < 0,2861

Fonte: Elaborado pelo autor.

No modelo *behavioral scoring* as variáveis referentes a instrução da mãe, a função que a mesma exerce e o contrato, apresentaram-se novamente como relevantes na explicação do modelo. Estas variáveis demonstraram os mesmos sinais obtidos no modelo de aprovação de crédito, indicando que possuem os mesmos efeitos sobre a variável inadimplência, sendo assim, podem ser interpretadas de modo análogo ao apresentado anteriormente. Por outro lado, as variáveis referentes ao bairro e ao nível de instrução do pai, que apresentaram significância muito próxima do limite de 0,05 no modelo de aprovação de crédito, não apresentaram significância no modelo comportamental. Dentre as variáveis comportamentais incorporadas ao modelo apenas a variável dummy 2005 apresentou-se estatisticamente significativa ao nível de 95% de confiança. O efeito desta variável sobre a inadimplência é analisado a seguir:

DUMMY 2005: A presença de um histórico de inadimplência, no ano anterior a análise de crédito, demonstra que um indivíduo tem uma forte possibilidade de reincidir na mesma falha. O resultado na análise discriminante apresenta que os alunos inadimplentes no ano de 2005 têm uma pontuação de crédito 0,51 superior em comparação com aqueles que estiveram adimplentes na mesma época, dado que as outras variáveis permaneceram constantes. Sendo assim, este resultado demonstra que existe a possibilidade de aperfeiçoar os padrões estabelecidos na política de crédito, incorporando este tipo de informação, que demonstra ser a variável de maior influência na previsão da pontuação de inadimplência.

Este é um importante ponto para ser reavaliado pela instituição de educação pesquisada, pois os pais que estiveram inadimplentes em 2005 só podem matricular seus filhos no ano subsequente após quitarem seus débitos ou após assinar uma confissão de dívida e renegociar o valor devido. Deste modo, a aceitação dos clientes com histórico de inadimplência demonstra ser o resultado de uma política de crédito inadequada, que não é capaz de absorver informações sobre a real capacidade de geração de recursos utilizados para saldar os débitos vencidos e que estão por vencer.

Uma possível explicação para esta reincidência dos pais na inadimplência é o fato de que os débitos anteriores já demonstram a incapacidade destes responsáveis em arcar com as despesas da mensalidade, e ao renegociarem suas dívidas para serem pagas juntamente com as novas mensalidades, o montante devido provavelmente acaba superando a, já limitada, capacidade de pagamento.

Como demonstrado nos modelos de aprovação de crédito e behavioral scoring, ao avaliar os pressupostos da análise discriminante foi possível constatar que em ambos os modelos as variáveis satisfizeram a restrição quanto a ausência de multicolinearidade. Foi apresentado também que mesmo com a presença intrínseca da heterocedasticidade foi possível obter estimativas confiáveis através da correção de White. Por outro lado não foi verificada a presença da gaussianidade das variáveis, nem foi possível alcançá-la através de transformações, sendo, então, assumida a não normalidade como uma limitação dos modelos. Muito embora, como mencionado, esta limitação não torna a sua utilização inviável. Por fim, mesmo diante das restrições encontradas, os resultados obtidos no modelo de aprovação de crédito com a técnica de análise discriminante apresentaram, sinais e valores coerentes com a realidade.

4.1.2 REGRESSÃO LOGÍSTICA

4.1.2.1 REGRESSÃO LOGÍSTICA - APROVAÇÃO DE CRÉDITO

No desenvolvimento dos modelos de credit scoring baseados no método de regressão logística, a amostra total utilizada foi particionada da mesma maneira apresentada na análise discriminante linear, onde 75% dos casos foram utilizados na modelagem e os 25% restantes reservados como amostra de teste, com o objetivo de realizar validação cruzada.

Operacionalizando a regressão logística foi utilizada a opção stepwise como mecanismo de seleção das variáveis que compuseram a equação final. Dentre as diversas combinações de variáveis independentes elaboradas pelo stepwise as seguintes observações foram selecionadas como as melhores preditoras da inadimplência, baseando-se no poder discriminatório.

Tabela 17 (4): Modelo de aprovação de crédito - regressão logística.				
Variáveis	Coefficiente	Erro padrão	Estatística Wald	Significância.
INSTPAI	-0,3041	0,1305	5,4288	0,0198
INSTMAE	-0,4175	0,1284	10,5702	0,0011
FUNCM	0,8460	0,2814	9,0352	0,0026
CONTRATO	-1,1645	0,4397	7,0142	0,0081
CONSTANTE	2,5446	0,8377	9,2272	0,0024

Fonte: Elaborado pelo autor.

Os resultados apresentados na tabela 17(4) podem ser reescritos na forma de equação, da seguinte maneira:

$Z_i = 2,54 - 1,16 \times CONTRATO + 0,84 \times FUNCM - 0,41 \times INSTMAE - 0,30 \times INSTPAI$, onde Z_i indica o escore do indivíduo i .

A própria estrutura do modelo de regressão logística é voltada para lidar com a variável dependente dicotômica, como no caso em que esta sendo trabalhado. Sendo assim, o próprio valor resultante da multiplicação das variáveis selecionadas pelos seus respectivos pesos discriminantes fornece uma pontuação, que ao ser aplicada a função de distribuição logística fornece a probabilidade da ocorrência do evento.

Função de distribuição logística:

$$P_i = \frac{1}{1 + e^{-z}} \quad \text{onde } z_i \text{ indica o escore de cada indivíduo.}$$

Deste modo o valor resultante da aplicação da equação acima anuncia a probabilidade direta de que determinado indivíduo pertença ou não ao grupo dos inadimplentes.

A previsão da inadimplência, contrariamente a adimplência é resultado da opção por atribuir o valor de 1 aos casos inadimplentes, informando ao modelo a presença deste atributo e atribuindo 0 aos adimplentes informando a ausência de inadimplência.

Sendo assim valores altos da probabilidade indicam que o modelo prevê a situação de indivíduos como inadimplentes. Por outro lado, baixos valores de probabilidade indicam um distanciamento da previsão de inadimplência, que será interpretada como uma aproximação da adimplência.

A questão chave então torna-se decidir o limite a partir do qual a probabilidade é considerada como inadimplente e quando será adimplente. Tomando-se como referência que a probabilidade de 0,5 indica chances iguais de obtenção de um resultado quando se trata de duas escolhas (HAIR et al, 2002), optou-se por atribuir o status de inadimplente as previsões com probabilidade superior a 0,5 e adimplentes caso contrário.

Observando o resultado na tabela 17(4) verifica-se que as variáveis relacionadas ao nível de instrução do pai e da mãe, a função que a mãe exerce, assim como a presença de contrato, apresentaram significância ao nível de 95% de confiança para explicar o modelo.

A interpretação dos coeficientes da regressão logística, de maneira isolada, ocorre de maneira diferente da análise discriminante, uma vez que eles representam o logaritmo da razão de chance de ocorrência de um evento sobre a probabilidade de não ocorrência, como apresentado a seguir:

$$\ln\left(\frac{\text{Pr}_{\text{ocorrência}}}{\text{Pr}_{\text{não_ocorrência}}}\right) = \beta_1 + \beta_2 X_i + \dots + \beta_n X_i$$

Para uma melhor compreensão e interpretação dos resultados são apresentadas algumas considerações acerca das variáveis.

INSTPAI – Como apresentada pela regressão logística, o coeficiente estimado sugere que para o aumento em uma unidade na categoria de instrução do pai indica que o logaritmo da chance a favor de se tornar inadimplente sob a probabilidade de ser adimplente é de -0,3041. Este resultado não é

de interpretação intuitiva por se tratar do logaritmo da variação da razão probabilidade de ocorrência do evento sob a probabilidade da não ocorrência do evento. Para obter a chance no modo percentual é necessário obter o anti-logaritmo de $-0,3041$ e subtrair o valor 1. Utilizando este procedimento é possível estabelecer que a variação da probabilidade é de $-0,2622$, o que significa que para cada aumento, de uma unidade, na categoria de instrução do pai conduz a uma redução de cerca de 26,22% na razão da probabilidade de ser inadimplente sob a probabilidade de ser adimplente. Este resultado é plausível, pois espera-se que quanto maior o nível de instrução do pai maiores sejam suas chances de obter maiores rendimentos e conseqüentemente dispor de mais recursos para saldar suas dívidas.

INSTMAE – A variável instrução da mãe, de modo análogo a instrução do pai, possui sinal negativo indicando que um aumento na categoria de instrução da mãe conduz a uma redução no logaritmo da razão da probabilidade de incorrer em inadimplência sob a probabilidade de ocorrência da adimplência. Aplicando o anti-logaritmo menos 1 ao valor obtido de $-0,4175$ obtido como coeficiente da regressão, é possível afirmar que o percentual da mudança na razão da probabilidade é reduzida em 34,13% para cada aumento em uma unidade na categoria de instrução da mãe.

FUNCMAE - A variável relacionada a função que a mãe desempenha no emprego apresenta um sinal positivo indicando que o logaritmo da razão da probabilidade de inadimplência sob a probabilidade de adimplência aumenta em 0,8460 a medida que aumenta em uma unidade o valor atribuído a categoria da função da mãe. Aplicando o anti-logaritmo menos 1, obtém-se a mudança na razão de probabilidade de 133,03%. Vale ressaltar que as funções de nível estratégico fazem parte da categoria 1, as gerenciais compreendem a categoria 2 e as operacionais a terceira categoria. Deste modo o coeficiente da regressão está indicando que quanto mais operacional for a função exercida pela mãe maior será a mudança na razão da probabilidade de ocorrência da inadimplência.

CONTRATO – O coeficiente apresentado pela regressão logística para a variável contrato indica que sua existência tem efeito negativo sobre a inadimplência. O logaritmo da razão da probabilidade de inadimplência sob a probabilidade de adimplência é de $-1,1645$, em forma percentual obtém-se $-68,79\%$. Vale ressaltar que o contrato é entregue a todos os pais no ato da matrícula, onde alguns são assinados e devolvidos a instituição de imediato, e outros preferem não assinar sob o pretexto da necessidade de realizar uma análise posterior, e não devolvem. A existência ou não do contrato provavelmente não influencia na capacidade de pagamento das mensalidades, mas a julgar pela significância do coeficiente da regressão, a existência do contrato funciona como um motivador para

a quitação dos débitos, ou pelo menos demonstra, a princípio, a intenção de cumprir com os pagamentos assumidos.

Como estes resultados são oriundos da regressão logística é necessário interpretar os coeficientes sob a ótica de que uma variável se modifica em determinada proporção dado que as demais variáveis permaneçam inalteradas.

A modelagem de regressão logística mensura a significância individual das variáveis incluídas no modelo através da estatística de Wald. Este teste, de modo semelhante ao teste t na análise de regressão, indica que os coeficientes são estatisticamente diferentes de 0 para determinado nível de confiança através do valor da significância. Observando a tabela 17(4) com os resultados da regressão é possível perceber que todos os coeficientes possuem uma significância inferior a 0,05, indicando que todos eles são diferentes de 0 para um nível de confiança de 95%.

Comprovada a significância individual de todos os coeficientes foi verificado o ajustamento global do modelo através do teste de Hosmer-Lemeshow. Este teste se baseia na discrepância entre os valores previstos pelo modelo e os valores reais. Ordenando todas as probabilidades previstas em ordem crescente, o teste separa o total de dados em classes, usualmente 10, com aproximadamente o mesmo tamanho. A seguir soma as diferenças entre as probabilidades previstas com o valor real e pondera pela quantidade de casos, assim como pelos percentuais de adimplentes e inadimplentes em cada classe, obtendo uma estatística C (VASCONCELOS, 2002). Esta estatística apresenta uma distribuição qui-quadrada com $g - 2$ graus de liberdade, onde g é o número de classes. Caso o valor tabelado seja maior que o valor obtido pelo teste, e a estatística se apresente insignificante é possível afirmar que existem indícios suficientes para aceitar a hipótese de que a regressão é eficiente ao estimar as probabilidades. O resultado do teste de Hosmer-Lemeshow é apresentado a seguir:

Tabela 18 (4): Teste de Hosmer-Lemeshow , aprovação de crédito - regressão logística.	
Qui-quadrado	Significância.
11,4004	0,1800

Fonte: Elaborado pelo autor.

O valor obtido no teste é inferior ao valor tabelado de 15,5073 obtido pela distribuição qui-quadrada com 8 graus de liberdade e ao nível de significância de 0,05. Deste modo é possível afirmar que o

modelo apresenta baixa discrepância ao realizar as previsões em comparação com os resultados esperados, o que é corroborado pela insignificância apresentada pelo teste.

4.1.2.2 REGRESSÃO LOGÍSTICA – BEHAVIORAL SCORING

No desenvolvimento da regressão logística para a construção do modelo behavioral scoring foi utilizada a mesma partição dos dados, em amostras de modelagem e teste, que foi apresentada anteriormente. O que difere este modelo do anterior resume-se a inclusão das variáveis referentes ao histórico de inadimplência dos anos de 2004 e 2005.

Utilizando mais uma vez a opção stepwise para a seleção das variáveis mais significantes foi obtida a seguinte regressão:

Tabela 19 (4): Modelo <i>behavioral scoring</i> - regressão logística.				
	Coeficiente	Erro padrão	Estatística Wald	Significância
INSTPAI	-0,3176	0,1535	4,2824	0,0385
INSTMAE	-0,3806	0,1460	6,8006	0,0091
FUNCM	0,9875	0,3311	8,8967	0,0029
CONTRATO	-1,4068	0,5220	7,2616	0,0070
DUMMY 2005	2,7873	0,4999	31,0821	0,0000
CONSTANTE	1,7070	0,9892	2,9779	0,0844

Fonte: Elaborado pelo autor.

A equação resultante da geração da regressão logística com dados comportamentais pode ser expressa da seguinte maneira:

$$Z_i = 1,7 + 2,78 \times DUMMY05 - 1,4 \times CONTRATO + 0,98 \times FUNCM - 0,38 \times INSTMAE - 0,31 \times INSTPAI,$$

onde Z_i indica o escore do indivíduo i .

Após a obtenção dos coeficientes demonstrados acima e sua multiplicação pelas variáveis independentes dos dados contidos na amostra, foram obtidos escores de crédito de cada indivíduo. Ao aplicar estas pontuações na função de distribuição logística foram obtidas medidas diretas da probabilidade de inadimplência. Após encontrar a probabilidade referente a todos os indivíduos foi utilizado como ponto de corte o valor de 0,5 para segregar os adimplentes dos inadimplentes.

Para interpretação dos coeficientes apresentados foi utilizado o mesmo procedimento realizado no modelo de aprovação de crédito com regressão logística. Aplicado o anti- logaritmo menos 1 foi possível encontrar o valor da razão de probabilidade de ocorrência da inadimplência pela probabilidade de adimplência.

Dentre as variáveis que compuseram o modelo, a instrução do pai e da mãe, a função da mãe e a presença de contrato se mostraram novamente significantes e apresentaram os mesmos sinais. Deste modo, interpretação análoga ao modelo de aprovação de crédito deve ser atribuída aos seus coeficientes.

Por outro lado, a variável relacionada ao histórico de débitos do ano de 2005 tornou-se significativa, sendo incorporada pelo modelo. Como esperado o coeficiente apresentou sinal positivo, indicando que o logaritmo da razão de probabilidade de tornar-se inadimplente sob a probabilidade de adimplência aumenta em 2,78 no caso da existência de débitos na instituição no ano de 2005. O que significa dizer que os indivíduos que possuem um histórico de débitos no ano de 2005 têm uma forte tendência a incorrer em atrasos no ano subsequente.

Tomando-se o anti-logaritmo e subtraindo 1, foi possível constatar que o valor da probabilidade de que um indivíduo torne-se inadimplente caso haja um histórico de inadimplência em 2005 aumenta em 1.611,90%, desde que as demais variáveis permaneçam constantes.

Em relação a significância do modelo, o teste de Wald demonstrou que todos os coeficientes, tomados de maneira individual, se mostraram significantes ao nível de 5%, com exceção do termo de intercepto que passou a ser significativo apenas ao nível de 10%.

É importante notar que a variável referente ao registro histórico de débitos de 2005 é significativa até mesmo o nível de 99% de confiança, além de possuir o maior valor entre os coeficientes encontrados no modelo final de behavioral scoring. O que significa que esta variável possui a mais alta importância para explicar o modelo quando comparado com as demais variáveis.

A introdução da variável comportamental no modelo fez com que o termo de intercepto, correspondente a soma de todos os outros fatores não presentes na regressão perdesse sua significância ao nível de 5%. O que corrobora com o fato de que a variável contendo os débitos de 2005 é um dos regressores mais importantes para explicar a inadimplência e que havia sido incorporada pelo coeficiente de intercepto no modelo de aprovação de crédito com regressão logística.

A fim de verificar a possível existência de uma diferença significativa entre a previsão feita pelo modelo e a originalmente apresentada pelos dados foi realizado o teste de Hosmer- Lemeshow. O resultado obtido pelo teste é apresentado na tabela 20(4):

Tabela 20 (4): Teste de Hosmer-Lemeshow, *behavioral Scoring* - regressão logística.

Qui-quadrado	Significância.
11,4004	0,1800

Fonte: Elaborado pelo autor.

Comparando o valor obtido pelo teste com o valor tabelado de 15,5073, obtido pela distribuição qui-quadrada com 8 graus de liberdade e 5% de significância, percebe-se que o valor do teste é inferior ao valor de referência. Deste modo é possível afirmar que o modelo apresenta um bom ajustamento, não apresentando diferenças discrepantes entre as probabilidades previstas e as originalmente encontradas nos dados. Este resultado é corroborado pela não significância apresentada pelo teste.

4.1.3 REDES NEURAIAS ARTIFICIAIS

O desenvolvimento dos modelos de credit scoring baseados nas redes neurais artificiais exigiram algumas modificações em relação a seleção da amostra, assim como foram necessários estabelecer novos parâmetros inerentes as redes neurais artificiais e que serão explicitados a seguir.

A operacionalização das RNAs é desmembrada nas etapas de treinamento, validação e teste. Sendo assim foi necessário redimensionar a partição da amostra que havia sido utilizada anteriormente na análise discriminante e na regressão logística. A fim de preservar as características da amostra para efeito de comparação entre os modelos que utilizam diferentes técnicas, os dados resguardados para amostra de testes foram mantidos e os demais dados alocados para treinamento e validação. O resumo da nova partição dos dados é apresentada na tabela 21(4).

Tabela 21 (4): Partição das amostras para RNA.

	% na amostra completa	Casos na amostra completa	Casos reservados para treinamento	Casos reservados para validação.	Casos reservados para teste.
Adimplentes	75%	183	91	46	46
Adimplentes	25%	62	32	15	15
Total	100%	245	123	61	61

Fonte: Elaborado pelo autor.

A amostra de treinamento conta com 50% das observações, pois é uma fase crítica onde os dados estão sendo apresentados pela primeira vez a rede. Os demais 25% foram destinados para a fase de validação dos dados.

Não existe uma regra que estabeleça o limite ótimo de dados que devam constar em cada etapa, sendo assim a opção por esta segregação das observações segue o mesmo padrão observado na composição da amostra completa. Deste modo, a composição de inadimplentes e adimplentes dentro de cada uma das três fases de construção do modelo segue aproximadamente a mesma proporção em cada uma das etapas, onde 25% dos dados referem-se a inadimplentes e 75% a adimplentes.

4.1.3.1 REDE NEURAL - APROVAÇÃO DE CRÉDITO

O modelo desenvolvido a partir da técnica de rede neural baseou-se no mecanismo mais difundido entre os estudos de credit scoring voltados para a previsão da inadimplência, denominado de perceptron multicamadas.

O ponto de partida para a geração dos modelos foi o estabelecimento da quantidade de camadas ocultas a serem utilizadas, e o número de neurônios em cada camada. Objetivando a criação de redes neurais com o maior poder de explicação possível do fenômeno da inadimplência, mas prezando pela parcimônia do modelo, as redes foram desenvolvidas de modo incremental.

A princípio foram desenvolvidas redes com apenas uma camada de entrada, uma oculta e uma de saída, e posteriormente novos testes foram realizados com o acréscimo de mais uma camada oculta. A opção por apenas duas camadas ocultas deve-se ao fato de que estas são suficientes para aproximar qualquer função matemática (Cybenko, apud Braga et al, 2000). Raciocínio análogo foi utilizado para o estabelecimento do número de unidades de processamento. Iniciando com dois neurônios, novas unidades foram acrescentadas na tentativa de identificar modelos que obtivessem melhor desempenho na amostra de teste. A adição dos neurônios ocorreu até que se atingiu o número máximo de 10 nodos. A escolha deste limite baseou-se no fato de que o acréscimo excessivo de neurônios pode causar o problema de overfitting, onde informações imprecisas são assimiladas, prejudicando a capacidade de generalização ou o reconhecimento de padrões não vistos durante o treinamento. Além do mais foi possível notar que o aumento da complexidade da rede, decorrente do crescimento de nodos, não foi capaz de conferir desempenho superior ao obtido pelas redes mais simples.

Seguindo o procedimento sugerido por Desai et al (1996), cada rede foi elaborada 10 vezes, onde a cada uma delas foram atribuídos pesos aleatórios as conexões entre neurônios. O objetivo deste procedimento foi atenuar os efeitos das redes neurais que não convergiram adequadamente. Sendo assim dentre as 10 vezes que cada rede foi gerada apenas aquela que obteve melhor desempenho foi considerada como válida e utilizada na análise comparativa entre modelos.

O aprendizado da rede ocorreu de modo supervisionado, onde foram apresentadas as variáveis de entrada e o respectivo resultado esperado. Deste modo o algoritmo de aprendizado de back-propagation apresentou-se com viável, pois foi possível calcular o erro obtido em cada ciclo e compará-lo com o desejado, permitindo que essa diferença fosse repassada na forma de insumo para as camadas iniciais.

O número de épocas utilizado nas etapas de treinamento e validação foi limitado a mil, e a taxa de aprendizado foi de 0,3, ou seja, todo o processo de entrada dos dados até a realimentação através do erro ocorreu mil vezes e os pesos foram alterados de maneira moderada. A opção por estas escolhas, mais uma vez, esteve baseada na percepção empírica, uma vez que não existem regras estabelecendo limites para a escolha ideal destes parâmetros.

Durante a fase de elaboração das primeiras redes foi possível perceber que o ponto de convergência de menor erro ocorria antes da milésima época, o que demonstrou que a utilização de um número de épocas superior a mil seria improdutivo e consumiria bastante tempo. A tabela a seguir apresenta a síntese dos melhores resultados obtidos na geração das redes.

Tabela 22 (4): Modelo de aprovação de crédito - RNA.

Varáveis incluídas	Camada oculta 1	Camada oculta 2	Treinamento	Seleção	Teste	Erro Treinamento	Erro Seleção	Erro Teste
18	3	9	0,8374	0,6721	0,8197	0,3774	0,4538	0,3787
18	4	0	0,8293	0,8033	0,8689	0,3977	0,4082	0,3503
18	5	7	0,8211	0,7705	0,8361	0,3714	0,4033	0,3950
18	6	4	0,8374	0,7541	0,8033	0,3756	0,4276	0,3994
18	7	8	0,8211	0,7213	0,8525	0,3865	0,4642	0,3851
18	8	3	0,7724	0,7377	0,8197	0,4180	0,4371	0,3983
18	9	9	0,9187	0,7377	0,8361	0,2919	0,4601	0,3637
18	10	5	0,8862	0,7869	0,8197	0,3007	0,4172	0,3978

Fonte: Elaborado pelo autor.

Observando os resultados é possível perceber que a melhor previsão atingiu o nível de 86,89% quando a rede ainda estava sendo construída com uma camada inicial com 18 entradas, relativas as

18 variáveis utilizadas, e apenas uma camada oculta com 4 neurônios. É possível perceber também, que apesar do aumento da complexidade da rede não houve progressos significativos na melhora da performance da previsão que justificasse a inclusão de mais variáveis, em uma contínua busca por novas redes que proporcionassem melhores resultados.

Apesar da simplicidade da rede foi obtido bom desempenho na previsão da amostra de teste como será demonstrado posteriormente. Resultados satisfatórios como este, utilizando redes simples com apenas uma camada oculta, também foram encontrados pelos autores Lee e Jung (2000) e Castro Junior (2003), utilizando 7 e 5 neurônios respectivamente.

Avaliando a contribuição de cada uma das variáveis independentes na explicação da inadimplência, o software Statistica 7.0 fornece uma análise de sensibilidade, identificando quais as variáveis são mais importantes para previsão de uma determinada rede.

Esta análise de sensibilidade é desenvolvida inicialmente gerando a rede com todas as variáveis incluídas, onde são obtidos os pesos de cada neurônio em todas as camadas, obtendo-se ao final uma taxa de erro, correspondente a diferença entre o valor procurado e o previsto. Em uma segunda etapa, a mesma rede é gerada novamente onde os valores das variáveis são retirados, um por vez, e novas taxas de erro são obtidas. Deste modo espera-se que ao se retirar variáveis que forneçam informações importantes para a rede o valor do erro aumente. Sendo assim, a razão entre o erro obtido ao se retirar o valor de uma das variáveis pelo erro original, gerado pela rede completa, é utilizada como um indicador do quanto a previsão da rede é dependente de cada uma das variáveis.

A tabela 23(4) apresenta a análise de sensibilidade obtida para a rede que obteve melhor desempenho.

Tabela 23 (4): Análise de sensibilidade, modelo de aprovação de crédito - RNA.

Variáveis	Razão	Rank
DATA CAT	1,0905	1
BAIROCAT	1,0507	2
FUNCPAI	1,0300	3
FUNCM	1,0245	4
PSAUDE	1,0207	5
INSTPAI	1,0200	6
INSTMAE	1,0134	7
CELP	1,0091	8
EMPRM	1,0074	9
IRMAOS	1,0060	10
APTO	1,0032	11
FONEC	1,0007	12
CONTRATO	1,0002	13
DESCP	1,0000	14
PUBP	0,9980	15
PUBM	0,9968	16
EMPPAI	0,9959	17
CELM	0,9952	18

Fonte: Elaborado pelo autor.

Como é possível observar através da tabela, nenhum dos valores da razão apresentados são muito discrepantes. Muito embora as variáveis PUBP, PUBM, EMPPAI e CELM obtiveram valores abaixo de 1, indicando que o erro obtido com a sua retirada foi inferior ao erro obtido originalmente. Sendo assim, para esta rede especificamente estas variáveis receberam pouca importância na tentativa de explicar a inadimplência. A variável DESC P obteve o valor da razão de 1 indicando que a sua retirada é indiferente para a performance da rede.

Na tentativa de identificar se era realmente possível obter melhor desempenho com menos variáveis, foram geradas novas redes retirando as variáveis com valores de razão de 1, ou mais baixo. Para cada variável retirada foram geradas 10 redes com o objetivo de identificar a de melhor desempenho, evitando a presença das redes que não convergiram adequadamente. As redes que obtiveram melhores resultados são apresentadas a seguir:

Tabela 24 (4): Resultado da RNA com variáveis suprimidas – aprovação de crédito.

Variáveis retiradas	Camada Oculta 1	Camada Oculta 2	Treinamento	Seleção	Teste	Erro Treinamento	Erro Seleção	Erro Teste
DESCP	4	0	0,8780	0,8689	0,8033	0,2877	0,3382	0,3982
PUBP	4	0	0,9187	0,7869	0,8361	0,2947	0,4100	0,3741
PUBM	4	0	0,9268	0,8525	0,8525	0,2702	0,3448	0,3484
EMPPAI	4	0	0,8780	0,8033	0,7705	0,3189	0,3732	0,3956
CELM	4	0	0,8780	0,7541	0,8197	0,3286	0,4385	0,3796

Fonte: Elaborado pelo autor.

Observando o resultado das novas redes percebe-se que a ausência das variáveis não foi capaz de fornecer melhor desempenho ao poder de previsão. O maior índice de acerto ocorreu com a ausência da variável que indica se a mãe possui emprego público ou não (PUBM), onde 85,25% dos casos foram classificados corretamente, mas que não conseguiu superar a previsão feita na presença de todas as variáveis, com apresentado anteriormente.

Hunter (2000) sugere que esta aparente contradição pode ser melhor compreendida através de dois pontos. O primeiro é que o fato destas 5 variáveis terem apresentado baixo valor de razão indicando pouca importância na explicação da variável de saída, não quer dizer que não tenha nenhuma importância, mas que para aquela rede especificamente elas não obtiveram forte poder explicativo. O que foi evidenciado quando a performance da rede foi reduzida ao se retirar as variáveis.

O segundo ponto, e que ajuda a compreender o primeiro, é que a pouca informação que cada uma das 5 variáveis possui, não pode ser suprida pelas outras com maior poder explicativo. Tornando estas informações únicas e responsáveis por influenciar, ainda que de maneira suave, o resultado final da previsão.

4.1.3.2 REDE NEURAL - BEHAVIORAL SCORING

A operacionalização do modelo behavioral scoring com redes neurais artificiais seguiu os mesmos procedimentos utilizados no modelo de aprovação de crédito, no que diz respeito aos critérios de definição do número de neurônios e camadas além dos mesmos dados para as etapas de treinamento seleção e teste. Mais uma vez foi utilizado o algoritmo de back-propagation limitando o número de épocas a 1000 nas etapas de treinamento e validação. A taxa de aprendizado foi mantida em 0,3.

Os melhores resultados obtidos pelas redes são apresentados a seguir:

Tabela 25 (4): Modelo *behavioral scoring* – RNA.

Variáveis incluídas	Camada Oculta 1	Camada Oculta 2	Treinamento	Seleção	Teste	Erro Treinamento	Erro Seleção	Erro Teste
20	3	4	0,7967	0,7541	0,8361	0,3819	0,4454	0,3720
20	4	3	0,9106	0,7869	0,8689	0,2748	0,4075	0,3571
20	5	6	0,7724	0,8525	0,8689	0,4065	0,3703	0,3805
20	6	7	0,9350	0,7869	0,8852	0,2360	0,4141	0,3293
20	6	10	0,8943	0,8361	0,8852	0,2847	0,3733	0,3252
20	7	4	0,9268	0,7705	0,8361	0,2545	0,4070	0,3679
20	8	8	0,9024	0,7541	0,8361	0,2936	0,4203	0,3721
20	9	0	0,8455	0,7869	0,8689	0,3607	0,4251	0,3350
20	10	4	0,9675	0,8197	0,8689	0,1857	0,3927	0,3579

Fonte: Elaborado pelo autor.

Observando os resultados é possível perceber que a melhor previsão atingiu o nível de 88,52% em duas circunstâncias, onde a rede foi construída com uma camada de entrada, duas ocultas e uma de saída. As duas redes de melhor desempenho apresentaram seis neurônios na primeira camada oculta, sendo que uma delas apresentou 10 neurônios na segunda camada oculta, enquanto que a outra apenas 7.

Apesar da semelhança apresentada entre o desempenho obtido na previsão entre as duas redes, a que apresenta 10 neurônios na segunda camada oculta, apesar de ser mais complexa, propicia uma taxa de erro pouco menor que a rede com 7 neurônios, ou seja, ela é capaz de realizar previsões acuradas, onde a diferença entre o valor previsto e o real é menor.

Outro fator que torna a rede mais complexa atrativa, é o fato de que esta foi capaz de obter um desempenho superior ao prever o grupo dos inadimplentes, cuja má classificação potencialmente tende a trazer maiores prejuízos para a instituição.

A tabela 26(4), apresentada em seguida, demonstra os níveis da razão de erro obtidos ao se proceder com a análise de sensibilidade descrita anteriormente:

Tabela 26 (4): Análise de sensibilidade, modelo de <i>behavioral scoring</i> - RNA.		
VARIÁVEL	Razão	Rank
DATA CAT	1,3377	1
DUMMY 2005	1,2727	2
BAIRRO CAT	1,2298	3
INSTMAE	1,2246	4
CONTRATO	1,1374	5
FUNCM	1,1197	6
PUBM	1,1172	7
IRMAOS	1,1156	8
EMPRM	1,1015	9
INSTPAI	1,0914	10
APTO	1,0777	11
FUNCPAI	1,0561	12
DUMMY 2004	1,0452	13
CELP	1,0370	14
PUBP	1,0357	15
EMPPAI	1,0343	16
CELM	1,0195	17
DESCP	1,0042	18
PSAUDE	1,0013	19
FONEC	0,9977	20

Fonte: Elaborado pelo autor.

A análise de sensibilidade do modelo *behavioral scoring* apresentou apenas a variável “telefone residencial” como a única a fornecer pouca contribuição para a previsão da rede neural, como pode ser percebido pela razão do nível de erro da rede completa pelo erro obtido ao se atribuir zeros ao valor da variável. Sendo assim, este resultado indica que a retirada da variável FONEC potencialmente poderia melhorar a previsão da rede ou pelo menos mantê-la no mesmo nível.

Procedendo de modo semelhante ao modelo de aprovação de crédito com redes neurais, a variável FONEC foi suprimida, e a rede gerada dez vezes. A rede que obteve melhor desempenho é apresentada na tabela 27 (4).

Tabela 27 (4): Resultado da RNA com variáveis suprimidas – <i>behavioral scoring</i> .								
Variável retirada	Camada Oculta 1	Camada Oculta 2	Treinamento	Seleção	Teste	Erro Treinamento	Erro Seleção	Erro Teste
FONEC	6	10	0,7398	0,7540	0,7377	0,6415	0,6828	0,7513

Fonte: Elaborado pelo autor.

Como é possível perceber a retirada da variável “telefone residencial” não proporcionou a rede uma melhor previsão na amostra de teste, assim como piorou os resultados obtidos na fase de treinamento e seleção. Deste modo é possível afirmar que apesar da pouca contribuição que a variável conferiu ao modelo inicial, a informação fornecida não pode ser retirada do modelo sem acarretar prejuízos ao poder preditivo da rede.

4.1.4 COMPARAÇÃO ENTRE A CAPACIDADE PREDITIVA DOS MODELOS

A avaliação da capacidade preditiva dos modelos é baseada tanto no percentual de acerto global quanto no seu poder de identificação dos casos dentro dos grupos de inadimplentes e adimplentes de maneira isolada.

Esta separação se faz necessária uma vez que a repercussão dos custos associados a uma má classificação dos clientes inadimplentes é diferente quanto a uma má classificação da inadimplência.

A comparação do poder de previsão de cada modelo será realizada através de matrizes de classificação onde são contrastadas a classificação teórica obtida no estudo e a real situação dos clientes da instituição de educação.

4.1.4.1 MATRIZES DE CLASSIFICAÇÃO DOS MODELOS DE ANÁLISE DISCRIMINANTE

Nas tabelas 28(4) e 29(4), apresentados a seguir, são demonstradas as matrizes de classificação dos modelos de aprovação de crédito e behavioral scoring baseados na análise discriminante:

Tabela 28 (4): Matriz de classificação do modelo de aprovação de crédito - análise discriminante.

	Resultado Original	Previsão do Modelo	%Corretamente classificado
Inadimplentes	15	11	73,33%
Adimplentes	46	33	71,74%
Classificação correta total: 72,13%.			

Fonte: Elaborado pelo autor.

Tabela 29 (4): Matriz de classificação do modelo *behavioral scoring* - análise discriminante.

	Resultado Original	Previsão do Modelo	%Corretamente classificado
Inadimplentes	15	12	80,00%
Adimplentes	46	38	82,61%
Classificação correta total: 81,97%.			

Fonte: Elaborado pelo autor.

O modelo de aprovação de crédito apresentou desempenho na previsão dos dados de maneira satisfatória, onde 72,13% dos casos foram classificados de maneira correta. Este percentual pode ser classificado como suficiente, pois supera o critério de acerto por chances proporcional o qual permite uma classificação correta de pelo menos 62,50%. Muito embora o percentual de acerto fornecido pelo modelo está abaixo do critério de chance máxima de 75%, que indica o percentual de acerto que se pode obter ao classificar todas as observações como pertencentes a um único grupo. De todo modo, a comparação com o critério de chances proporcional é mais indicado para este estudo, pois procura-se um modelo que seja capaz de identificar corretamente o maior número possível de indivíduos dentro dos dois grupos distintos, por isso o modelo pode ser considerado como válido.

Analisando o desempenho do modelo na previsão dos bons e maus pagadores percebe-se que o acerto de 73,33% dos inadimplentes é superior a previsão de 71,74% dos adimplentes. Como poderá ser percebido ao analisar os demais modelos este foi o único a apresentar um percentual de previsão de inadimplência superior em relação a previsão de bons pagadores.

O modelo comportamental obteve um poder de previsão geral de 81,97%, superando tanto o acerto por chances proporcionais como o critério de chances máxima. Seu desempenho ao identificar os alunos adimplentes atingiu 82,61%, ficando pouco acima dos 80% de acertos na previsão dos inadimplentes.

Apesar da aparente superioridade do desempenho dos modelos na previsão do status de pagamento em comparação com a previsão do critério de chances proporcionais, Hair et al (2002) ressaltam a necessidade de verificar se esta superioridade é estatisticamente significativa. Para isto os autores sugerem a utilização do teste Q de Press que, como comentado anteriormente, compara o número de classificações corretas com o tamanho da amostra e o número de grupos.

Considerando que o número de casos previstos corretamente nos modelos de aprovação de crédito e behavioral scoring somam 44 e 50 unidades respectivamente, e que o total de dados utilizados na amostra de teste somam 61 casos, a estatística Q de Press foi calculada da seguinte maneira:

Aprovação de crédito – Análise discriminante.

$$Q \text{ de Press} = \frac{[61 - (44*2)]^2}{61*(2-1)} = 11,95$$

Behavioral scoring - Análise discriminante.

$$Q \text{ de Press} = \frac{[61 - (50 \cdot 2)]^2}{61 \cdot (2-1)} = 24,93$$

O valor encontrado através da utilização do teste Q de Press segue uma distribuição qui-quadrada e deve ser comparada com o valor tabelado da mesma distribuição com graus de liberdade igual ao número de grupos previstos menos 1. Como foram utilizados apenas dois grupos, o número de graus de liberdade que será utilizado como referência é apenas 1.

Utilizando o nível de significância de 5% o valor tabelado encontrado na distribuição qui-quadrada para um grau de liberdade é de 3,84. Comparando este valor com os obtidos pelo testes é possível perceber que os valores calculados são superiores ao tabelado, indicando que o desempenho obtido pelos modelos na previsão do status de pagamento dos clientes é estatisticamente superior ao percentual de acerto previsto no critério de chances.

4.1.4.2 MATRIZES DE CLASSIFICAÇÃO DOS MODELOS DE REGRESSÃO LOGÍSTICA

Nas tabelas 30(4) e 31(4), apresentados a seguir, são demonstradas as matrizes de classificação do modelo de credit scoring baseados na regressão logística.

Tabela 30 (4): Matriz de classificação do modelo de aprovação de crédito - regressão logística.

	Resultado Original	Previsão do Modelo	% Corretamente classificado
Inadimplentes	15	7	46,67%
Adimplentes	46	42	91,30%
Classificação correta total: 80,33%.			

Fonte: Elaborado pelo autor.

Tabela 31 (4): Matriz de classificação do modelo *behavioral scoring* - regressão logística.

	Resultado Original	Previsão do Modelo	% Corretamente classificado
Inadimplentes	15	11	73,33%
Adimplentes	46	43	93,47%
Classificação correta total: 88,52%.			

Fonte: Elaborado pelo autor

O modelo de aprovação de crédito com regressão logística, a exemplo do modelo de análise discriminante, apresentou desempenho na previsão dos dados de maneira satisfatória, onde 75,41% dos casos foram classificados corretamente, superando o percentual de acerto de 62,50% obtido pelo

critério de chances proporcional. e se igualando ao critério de chance máxima de 75,41%, obtido ao classificar todas as observações como pertencentes a um único grupo.

Analisando o desempenho dentro dos grupos, percebe-se que o modelo de aprovação de crédito obteve um fraco desempenho na classificação dos inadimplentes onde apenas 46,67% dos indivíduos pertencentes a este grupo foram identificados corretamente. Em contra partida 91,30% dos casos de adimplentes são classificados corretamente.

Por sua vez, o modelo behavioral scoring apresenta um percentual de acerto global de 88,52% dos casos, superando o critério de acerto por chances máxima e proporcional.

Analisando de maneira mais específica é possível perceber que o percentual de acerto dentro dos grupos é melhor que o modelo de aprovação de crédito obtido com a regressão logística, obtendo 93,47% de acerto no grupo de adimplentes e 73,33% nos inadimplentes.

Para se certificar de que o poder discriminatório da matriz de classificação é estatisticamente superior ao critério por chances, foi empregado o teste Q de Press.

Considerando que o número de observações na amostra de teste somam 61 dados, entre os quais 49 foram classificados corretamente no modelo de aprovação de crédito e 54 no modelo comportamental, e existem apenas os grupos de adimplentes e inadimplentes, o teste Q de Press foi calculado da seguinte maneira:

Aprovação de crédito – Regressão Logística.

$$Q \text{ de Press} = \frac{[61 - (49*2)]^2}{61*(2-1)} = 22,44$$

Behavioral - Regressão Logística.

$$Q \text{ de Press} = \frac{[61 - (54*2)]^2}{61*(2-1)} = 36,21$$

O valor tabelado de 3,84 encontrado para um nível de confiança de 95% é bem inferior aos valores encontrados no teste. Sendo assim, é possível considerar que a matriz de classificação obtida através da regressão logística é estatisticamente superior ao nível de acertos obtidos ao acaso, em ambos os modelos.

4.1.4.3 MATRIZES DE CLASSIFICAÇÃO DO MODELO DE REDE NEURAL

Nas tabelas 32(4) e 33(4) demonstrados a seguir apresentam de maneira resumida os resultados obtidos com a utilização das redes neurais através das matrizes de classificação.

Tabela 32 (4): Matriz de classificação do modelo de aprovação de crédito – redes neurais.			
	Resultado Original	Previsão do Modelo	% Corretamente classificado
Inadimplentes	15	7	46,67%
Adimplentes	46	46	100%
Classificação correta total: 86,89%.			
Fonte: Elaborado pelo autor.			

Tabela 33 (4): Matriz de classificação do modelo <i>behavioral scoring</i> - redes neurais.			
	Resultado Original	Previsão do Modelo	% Corretamente classificado
Inadimplentes	15	11	73,33%
Adimplentes	46	43	93,48%
Classificação correta total: 88,52%.			

Fonte: Elaborado pelo autor.

Como é possível verificar o modelo que abrange variáveis comportamentais obteve desempenho global superior ao apresentado no modelo de aprovação de crédito utilizando a mesma técnica, onde o primeiro atingiu 88,52% contra 86,89% do segundo.

O desempenho superior do modelo comportamental também foi observado na previsão de cliente inadimplentes, atingindo 73,33% contra 46,67% do modelo de aprovação. O modelo de aprovação de crédito mostrou-se superior apenas quanto a classificação dos clientes adimplentes, alcançando 100% de acerto em contra partida o modelo comportamental acertou 93,48%.

Considerando que o custo envolvendo uma má classificação dos clientes inadimplentes é superior a uma má classificação dos adimplentes o modelo *behavioral scoring* pode seguramente ser considerada como detentor de melhor desempenho, pois apresenta melhor poder de previsão global e melhor previsão do grupo inadimplentes.

No intuito de verificar se as matrizes de classificação dos modelos de RNA são significativamente maiores que o critério aleatório de chances foi utilizado o teste Q de Press, resultando nos seguintes valores:

Aprovação de crédito – RNA

$$Q \text{ de Press} = \frac{[61 - (53*2)]^2}{61*(2-1)} = 33,20$$

Behavioral Scoring – RNA

$$Q \text{ de Press} = \frac{[61 - (54*2)]^2}{61*(2-1)} = 36,21$$

Avaliando a significância dos dados a um nível de 95% confiança é possível perceber que o valor obtido no teste é bastante superior ao valor tabelado de 3,84. Deste modo é possível afirmar que ambos os modelos possuem poder de previsão significativamente superior ao critério de chances.

4.1.5 VANTAGENS E DESVANTAGENS DA UTILIZAÇÃO DOS MODELOS DE CREDIT SCORING

Após o desenvolvimento dos modelos e da comprovação de que sua utilização para previsão da inadimplência escolar é viável, faz-se necessário realizar uma discussão apresentando os principais pontos em que a utilização deste tipo de modelagem pode contribuir no gerenciamento do risco de crédito da instituição pesquisada.

Um dos principais benefícios da utilização do credit scoring é a possibilidade de otimizar a decisão de quais créditos devem ser concedidos, aumentando a lucratividade, e quais devem ser negados, reduzindo o percentual de perdas (WEST, 2000).

Deste modo o credit scoring pode ser utilizado como um critério auxiliar na seleção de novos alunos, onde a efetivação da matrícula ficará condicionada ao resultado positivos da aplicação do modelo.

Atualmente a instituição não utiliza nenhum mecanismo de gerenciamento de risco de crédito. Todos os alunos que se candidatam ao ingresso na instituição pesquisada são aceitos, estando condicionados apenas a disponibilidade de vagas. O processo seletivo existente conta apenas com a realização de provas, visando unicamente identificar se o nível de conhecimento do aluno é compatível com a série a qual pretende cursar.

A utilização do credit scoring para a tomada de decisão de aceitação ou rejeição de um potencial aluno é crucial do ponto de vista de leis contra a discriminação, pois a tomada de decisão é feita de maneira objetiva, respaldada pela modelagem estatística, eliminando o potencial viés da subjetividade humana (ROSEMBERG e GLEIT, 1994).

Outro benefício esperado com a utilização do credit scoring é que os modelos forneçam informações importantes para um gerenciamento financeiro eficaz. Ao identificar previamente os alunos que tem alta probabilidade de se tornarem inadimplentes em algum momento dentro do ano letivo, a instituição pesquisada pode ter uma medida do volume de recursos que serão recebidos ao longo dos meses. De posse destas informações a instituição educacional disporia de mais subsídios para equacionar o montante de recursos que se espera receber, com as despesas incorridas no desempenho da atividade educacional.

Por outro lado é necessário perceber que a utilização da modelagem de credit scoring também traz alguns desafios e algumas limitações. Este tipo de modelagem é estática, considerando as condições econômicas e as variáveis que caracterizam os indivíduos pesquisados como estáveis, além de se basear no fato de que as relações passadas sobre a inadimplência são fortes preditoras do comportamento futuro dos clientes.

Ou seja, o modelo é desenvolvido partindo do pressuposto que a relação histórica, obtida entre os dados sobre as características dos clientes e a inadimplência, permanecerá vigente em períodos subseqüentes para que o modelo possa ser aplicado. Sendo assim, o modelo parte do pressuposto que as características que no passado apresentaram forte poder preditivo na identificação da inadimplência podem ser replicadas futuramente a um novo conjunto de clientes.

No entanto a base de clientes muda lentamente ao longo do tempo, o que possivelmente pode alterar o perfil das características que melhor predizem a inadimplência. Muito embora este seja um problema a ser resolvido a médio prazo, uma vez que levaria pelo menos treze anos para alterar toda a base de alunos da escola, considerando que ao final de cada ano apenas uma turma deixa a instituição. Outro ponto que pode promover a alteração desta relação é a mudança no cenário econômico. O perfil do cliente inadimplente possivelmente é influenciado diferentemente em ciclos de expansão e retração econômica.

Todas estas alterações exigem que os modelos de crédito sejam constantemente reavaliados, e refeitos, o que potencialmente seria uma fonte de problemas para a instituição pesquisada. O desenvolvimento de um credit scoring exige o conhecimento das técnicas estatísticas utilizadas e atualmente nenhum dos colaboradores da instituição dispõe de uma formação que lhe permita ter a compreensão deste tipo de informação.

Outro fator que potencialmente pode apresentar-se como uma limitação para a utilização do credit scoring na instituição de educação pesquisada é o impacto que será causado na opinião dos clientes

da instituição. A implantação deste sistema deve ser feita de maneira transparente, onde os pais e responsáveis devem ser informados sobre os objetivos e a imparcialidade do modelo, caso contrário pode causar constrangimento entre os clientes e afastá-los da instituição.

Diante dos fatos expostos é possível perceber os benefícios que potencialmente podem ser auferidos através do modelo de credit scoring. No entanto, sua utilização prescinde de uma cautelosa avaliação dos efeitos diretos e indiretos que podem repercutir de maneira desfavorável a instituição.

5 CONCLUSÕES

5.1 CONSIDERAÇÕES SOBRE OS RESULTADOS OBTIDOS

Esta pesquisa foi desenvolvida em uma instituição de educação voltada para o ensino médio e fundamental, no intuito de verificar a viabilidade da utilização de modelos de credit scoring, como uma ferramenta de gerenciamento do risco, na previsão da inadimplência.

A utilização de modelos como este é bastante difundido em instituições que tem como principal foco de seu negócio a concessão de crédito. Por outro lado, instituições nas quais ainda não existe uma cultura voltada para a minimização do risco de crédito, o credit scoring apresenta-se como uma potencial ferramenta de auxílio na prevenção de perdas com incobráveis.

A pontuação de crédito não é uma modelagem recente, os primeiros estudos datam de 1930, no entanto novas técnicas tem sido desenvolvidas e apresentado bons resultados como é o caso das redes neurais artificiais, permitindo, conjuntamente com o desenvolvimento das técnicas computacionais, a disseminação de sua utilização para segmentos econômicos ainda pouco explorados.

Neste estudo a viabilidade do credit scoring foi testada através de duas técnicas tradicionais, são elas a análise discriminante e a regressão logística, assim como através das redes neurais artificiais.

Os dados utilizados no estudo foram retirados da base de dados concedida pela instituição pesquisada, contando inicialmente com 303 alunos. Realizando uma triagem inicial nos dados, foram excluídos da população inicial aqueles que apresentaram inconsistência nas informações apresentadas sendo reduzida a uma amostra final de 245 indivíduos.

Dentre os dados fornecidos pela instituição educacional foram identificadas 20 variáveis que potencialmente poderiam contribuir na previsão do fenômeno em estudo, a inadimplência.

Após uma revisão das principais obras de referência sobre a inadimplência foi possível constatar que não existe um consenso na literatura quanto as variáveis que melhor contribuem para a previsão dos modelos de credit scoring. Deste modo todas as variáveis disponíveis foram utilizadas no desenvolvimento do estudo, sendo a opção por sua utilização, ou não, no modelo final condicionada a significância em relação ao poder de previsão.

Para verificar o poder de previsão, assim como a capacidade de generalização dos modelos a amostra foi particionada em dados de validação e teste. Os primeiros foram utilizados no desenvolvimento dos modelos enquanto que os últimos utilizados para averiguar o desempenho ao realizar as previsões.

Durante o desenvolvimento da pesquisa a utilização da análise discriminante apresentou algumas limitações ao atender os pressupostos da normalidade das variáveis e homocedasticidade dos erros da regressão. A não gaussianidade dos dados foi assumida como uma limitação da técnica, muito embora, como explicitado, esta deficiência não inviabiliza a sua utilização. Por sua vez, a heterocedasticidade, inerentemente presente na análise discriminante, foi superada pela utilização do mecanismo de White. Após estes ajustes a técnica apresentou bom desempenho ao classificar corretamente 72,13% dos indivíduos no modelo de aprovação de crédito e 81,97% no behavioral scoring, como pode ser percebido na tabela apresentada a seguir onde são resumidos todos os resultados dos modelos desenvolvidos.

Tabela 34 (5): Resumo da capacidade preditiva dos modelos.				
Técnica	Modelo	Acerto Inadimplentes	Acerto Adimplentes	Classificação Correta Total.
Análise Discriminante	Aprovação de Crédito	73,33%	71,74%	72,13%.
	<i>Behavioral Scoring</i>	80,00%	82,61%	81,97%.
Regressão Logística	Aprovação de Crédito	46,67%	91,30%	80,33%.
	<i>Behavioral Scoring</i>	73,33%	93,47%	88,52%.
Redes Neurais	Aprovação de Crédito	46,67%	100%	86,89%.
	<i>Behavioral Scoring</i>	73,33%	93,48%	88,52%.

Fonte: Elaborado pelo autor.

A regressão logística por sua vez mostrou-se mais adequada, pois é uma técnica direcionada para a utilização de dados dicotômicos como variável dependente, além de não estabelecer pressupostos sobre as variáveis explicativas. As observações corretamente classificadas de maneira geral alcançaram 80,33% no modelo de aprovação de crédito e 88,52% no behavioral scoring.

A estrutura flexível subjacente ao modelo de redes neurais também se apresentou como uma técnica com alta capacidade preditiva no desenvolvimento do credit scoring, onde o modelo de aprovação de crédito alcançou 86,89% de acerto em sua previsão geral, enquanto que o behavioral scoring atingiu o patamar de 88,52% de casos identificados corretamente.

Baseando-se nos resultados obtidos é possível afirmar que todos os modelos elaborados apresentaram-se como instrumentos viáveis na previsão de inadimplência, uma vez que seu poder de previsão, quanto ao status de pagamento de clientes, é superior ao critério de identificação baseado em chances proporcionais, o qual permite um acerto mínimo de 62,50%.

Ficou evidente também que todos os modelos que incorporaram a variável comportamental houve um aumento na capacidade preditiva, demonstrando a superioridade do behavioral scoring sobre os modelos de aprovação de crédito.

Analisando separadamente o poder de previsão do status de pagamento dentro dos grupos, é possível perceber que os modelos obtiveram melhor desempenho ao identificar clientes considerados adimplentes em comparação aos inadimplentes, com exceção do modelo de aprovação de crédito com análise discriminante (muito embora seu poder preditivo tenha sido superado por outros modelos).

As redes neurais artificiais e a regressão logística apresentaram a mesma capacidade preditiva geral no modelo comportamental, além de obter os mesmos percentuais de previsão dentro dos grupos, com 73,33% de acerto entre inadimplentes e 93,48% entre os adimplentes.

Por outro lado o modelo comportamental baseado na análise discriminante linear foi superior as demais técnicas ao realizar a previsão dos inadimplentes, obtendo 80% de classificações corretas, porém obteve desempenho inferior ao prever o grupo dos adimplentes, com apenas 82,61% de acerto.

Deste modo fica evidente que, dentre os modelos comportamentais, não há uma supremacia de uma técnica sobre as demais. De todo modo, é importante perceber que apesar da maior precisão do modelo behavioral - ADL ao realizar previsões no grupo dos inadimplentes, a diferença para a previsão dos modelos logístico e de redes neurais é de apenas um indivíduo, enquanto que estes classificaram corretamente 5 indivíduos a mais como pertencentes ao grupo dos adimplentes. O que demonstra que as três técnicas utilizadas na composição dos modelos proporcionam desempenho praticamente equivalentes.

Trazendo a discussão do desempenho dos modelos para a aplicação no contexto da instituição educacional pesquisada, é válido perceber que a possível utilização de cada uma das técnicas deve considerar as limitações presentes na instituição.

O fato das redes neurais não apresentarem nenhum tipo de restrição ao formato dos dados, associados a sua capacidade de identificar relações não lineares entre as variáveis, é um fator que torna sua utilização atrativa. Porém, deve-se ponderar que seu desenvolvimento e utilização por parte da instituição de educação pesquisada exige um maior nível de complexidade, tornando a possibilidade da adoção desta técnica pela instituição mais restrita.

Por outro lado, a análise discriminante linear e a regressão logística possuem mecanismos de elaboração mais difundidos e disponíveis em maior número de pacotes estatísticos. Associado a este fator está a maneira intuitiva com que os resultados podem ser interpretados, onde o logit oferece o percentual direto de probabilidade de inadimplência e a análise discriminante indica uma pontuação referente ao status de pagamento, o que torna estas técnicas mais atraentes. Aliado a este fato está a possibilidade de obtenção de um desempenho preditivo tão bom quanto o modelo de rede neural artificial.

De uma maneira geral é possível perceber, através dos resultados da pesquisa, que diante da existência de uma legislação que protege os que se tornam inadimplentes em relação a contraprestação dos serviços educacionais, e que limita os esforços das instituições de educação em reaver os pagamentos pendentes, os modelos de credit scoring apresentam-se como uma alternativa viável no objetivo de tentar amenizar os efeitos do risco de crédito, inerente ao desempenho da prestação dos serviços educacionais.

Deste modo, os modelos de credit scoring demonstraram ser de grande valia a medida que se apresentaram como instrumento de previsão viável, permitindo sua utilização como instrumento auxiliar na seleção de potenciais clientes ou ainda como uma ferramenta de apoio ao planejamento financeiro.

5.2 LIMITAÇÕES ENCONTRADAS E SUGESTÕES PARA FUTURAS PESQUISAS

A primeira limitação apresentada pela pesquisa foi o tamanho da amostra estudada. Apesar de utilizar toda a base de dados de clientes da instituição pesquisada, retirando apenas os indivíduos não pagantes e aqueles que apresentaram informações incompletas, foram utilizadas apenas 245 observações. Deste total houve ainda a necessidade de segregação dos dados em amostras de

modelagem e teste para a realização da validação cruzada, o que reduziu ainda mais a quantidade de dados utilizados no desenvolvimento dos modelos. Sendo assim, foram utilizadas apenas 184 observações para a modelagem das técnicas de análise discriminante linear e regressão logística. Vale ressaltar que muitos dos testes utilizados nestas técnicas atingem seu ponto ótimo apenas assintoticamente, ou seja, com grandes amostras.

A quantidade restrita de observações constitui-se uma limitação para os modelos, também pela necessidade que existe de se apresentar o maior número possível de exemplos na modelagem, para que se obtenha bom desempenho ao realizar previsões. Ao utilizar apenas

184 dados para a modelagem, possivelmente alguns tipos de clientes deixaram de ser considerados na estimação dos coeficientes.

Outra limitação encontrada foi a utilização das variáveis comportamentais referentes ao histórico de débitos dos anos de 2004 e 2005 para os alunos recém chegados a instituição, uma vez que não haviam referências sobre estes dados.

As variáveis utilizadas nos modelos apresentam-se como mais uma limitação. A pesquisa sobre inadimplência aborda uma questão delicada pela possibilidade de constranger o indivíduo pesquisado, o que levou a instituição pesquisada a não permitir a realização de um pesquisa tipo survey diretamente com os clientes. Um levantamento direto destas informações possivelmente permitiria a obtenção de um maior número de características que pudessem contribuir para a previsão da inadimplência. Muito embora as variáveis presentes no banco de dados da instituição foram suficientes para que os modelos obtivessem desempenhos em suas previsões de até 88,52%.

Os pressupostos apresentadas pela técnica de análise discriminante linear também se apresentaram como uma limitação do estudo, uma vez que não foi possível satisfazê-las integralmente. Os dados utilizados não se ajustaram as hipóteses de homocedasticidade e normalidade das variáveis. A não obtenção da homocedasticidade foi corrigida pelo método de White. Por outro lado a normalidade dos dados não pode ser atingida e foi assumida como uma limitação da técnica, muito embora, como explicitado, não inviabilize a utilização da técnica.

Futuras pesquisas no campo da gestão de risco focado na inadimplência escolar podem averiguar a possibilidade de execução de diferentes arquiteturas de redes neurais, que posam conduzir a melhores resultados ao realizar previsões.

Novas pesquisas neste segmento podem também volta-se para a inclusão de novas variáveis explicativas na composição dos modelos, uma vez que a pesquisa sobre inadimplência escolar ainda está se desenvolvendo e não existe uma clara definição das variáveis que podem apresentar boa capacidade preditora. Sendo assim, existem inúmeras combinações de possibilidade a serem exploradas, e que podem contribuir para o desenvolvimento do conhecimento científico sobre a inadimplência.

REFERÊNCIAS

- ALMEIDA, F. C.; DUMONTIER, P. O uso de Redes Neurais em Avaliação de Riscos de Inadimplência. Revista de Administração FEA/USP, São Paulo, v. 31, n. 1, p.52-63, Março. 1996.
- ALMEIDA, F. C.; SOUZA, PASSARI, F. A. Aplicação de Redes Neurais na previsão de vendas no varejo. In: XXXIV Encontro Anual Da Associação Nacional De Pós-Graduação Em Administração. Anais..., Brasília: ANPAD, 2005.
- ALTMAN, E. I. Financial ratios, discriminant analysis and the prediction of corporate failure. Journal of Finance, n. 23, p. 589-609, 1968.
- HALDEMAN, Robert G.; NARAYANAN, Paul. ZETA Analysis: a new model to identify bankruptcy risk of corporations. Journal of Banking and Finance, n. 1, p. 29-54, 1977.
- AMEMYA, T. Qualitative Response Models : A Survey. Journal of Economic Literature, v. 19, p. 1483-1536, 1981.
- AMORIN NETO, A. Modelagem do Risco de Crédito: Um Estudo do Segmento de Pessoas Físicas de um Banco de Varejo. 2002. 103f. Dissertação (Mestrado em Administração) – Programa de Pós-Graduação em Administração, Universidade Federal de Pernambuco, Recife, 2002
- ASSAF NETO, A. Mercado Financeiro. 5 ed. São Paulo: Atlas, 2003.
- BANCO CENTRAL DO BRASIL. Indicadores de Conjuntura. Disponível em <<http://www.bacen.gov.br>>. Acesso em: 23 jan. 2006.
- BASEL COMMITTEE ON BANKING SUPERVISION. Principles for the Management of Credit Risk. Bank for International Settlements (BIS). July, 1999. Disponível em <<http://www.bis.org>>. Acesso em: 23 jan 2006.
- BEAVER, W. H. Financial Ratios as Predictors of Failure. Empirical research in accounting: selected studies, suplemento do Journal of Accounting Research, autumn, 1966.
- BLATT, Adriano. Avaliação de Risco e Decisão de Crédito: um enfoque prático. São Paulo: Nobel, 1999.
- BRAGA, A. P.;LUDEMIR, T. B.; CARVALHO, A. C. Redes Neurais Artificiais: Teoria e Aplicações. Rio de Janeiro: Livros Técnicos e Científicos, 2000.
- CAOQUETTE, J. ALTMAN, E; NARAYANAM, P. Gestão do Risco de Crédito: o Próximo Grande Desafio Financeiro. Rio de Janeiro: Qualitymark, 1999.
- CASTRO JR, F. H. F. Previsão de Insolvência de Empresas Brasileiras Usando Análise Discriminante, Regressão Logística e Redes Neurais. 2003. 169f. Dissertação (Mestrado em Administração) - Programa de Pós Graduação em Administração, Faculdade de Economia, Administração e Contabilidade, São Paulo, 2003.

CARTACHO, S.C; SOUZA, A.A. A Utilização de um Modelo Composto por Algoritmos Genéticos e Redes Neurais no Processo de Seleção de Carteiras. In: XXXI Encontro Anual da Associação Nacional dos Programas de Pós-Graduação em Administração, Anais..., Salvador: ANPAD, 2002.

CHAIA, A.J. Modelos de Gestão de Risco de Crédito e sua Aplicabilidade ao Mercado Brasileiro. 2003. 93f. Dissertação (Mestrado em Economia) – Faculdade de Economia, Administração e Contabilidade, Universidade de São Paulo, São Paulo, 2003.

CIA, J.C. Propostas de Medidas de Inadimplência para o Mercado Brasileiro. In: XXXII Encontro Anual da Associação Nacional de Pós-Graduação em Administração, Anais..., Atibaia: ANPAD, 2003.

DESSAI, V.S.; CONWAY, J.N.; OVERSTREET, G.A. A comparison of neural network and linear scoring models in the credit union environment. *European Journal of Operational Research*. v. 95, p. 24-37. 1996

FENSTERSTOCK, A. Credit scoring and the next step. *Business Credit*. Mar, p.46-49. 2005

FREITAS, Sander O. De, SOUZA, Antonio A. de. Utilização de um Modelo Baseado em Redes Neurais para a Precificação de Opções. In: XXXIV Encontro Anual Da Associação Nacional De Pós-Graduação Em Administração. Anais..., Brasília: ANPAD, 2005.

GIL, A. C. Métodos e Técnicas de Pesquisa Social. 4. ed. São Paulo: Atlas, 1994. GREENE, W. H. *Econometric Analysis*. 5 ed. New Jersey: Prentice Hall, 2002.

GUIMARAES, I. A.; CHAVES NETO, A. Reconhecimento de Padrões: Metodologias Estatísticas em Crédito ao Consumidor. *RAE-eletrônica*, v. 1, n. 2, art. 15, jul./dez, 2002.

GUJARATI, D. N. *Econometria Básica*. 3 ed. São Paulo: Makron Books, 2000.

HAIR JR., J. F.; ANDERSON, R. E.; TATHAM, R. L.; BLACK, W. C. *Análise*

Multivariada de Dados. 5 ed. Porto Alegre: Bookman, 2002.

HAYKIN, S. *Redes Neurais : Princípios e Prática*. 2 ed. Porto Alegre: Bookman, 2001. HUNTER, A.; KENNEDY, L.; HENRY, J.; FERGUSON, R.I. *Application of Neural*

Networks and Sensitivity Analysis to improved prediction of Trauma Survival. *Computer Methods and Algorithms in Biomedicine*. v. 62, p. 11-19, 2000.

JOHNSTON, J.; DINARDO, J.; *Métodos Econométricos*. 4 ed. Lisboa: McGraw-Hill, 2001.

JORION, P. *A Nova Fonte de Referência para o Controle do Risco Financeiro: Value at Risk*. São Paulo: BM&F, 2003.

KIMURA, H; PERERA, L.C.J; DONZELLI, C. R; SILVA FILHO, A.C; LIMA, F.G.

Aplicação de Redes Neurais na Analise e Concessão de Crédito ao Consumidor. In: XXXIV Encontro Anual da Associação Nacional de Pós-Graduação em Administração, Anais..., Brasília: ANPAD, 2005.

- LACHTERMACHER, G; ESPENCHITT, D.G. Estudo de Generalização de Redes Neurais. In: XXX. Encontro Anual da Associação Nacional dos Programas de Pós-Graduação em Administração, Anais..., Campinas: ANPAD, 2001.
- LEE, T. H.; JUNG, S. Forecasting creditworthiness: logistic vs. artificial neural net. The Journal of Business Forecasting Methods & Systems, 1999/2000, winter, v.18, n. 5, p. 28- 30.
- MADALA, G. S. Introduction to Econometrics. 2 ed. Toronto: Mcmillan Publishing Company, 1992.
- MARTINS, Gilberto de A. Manual para Elaboração de Monografias e Dissertações. 2 ed. São Paulo: Atlas, 1994.
- MARTINS, G. A.; LINTZ, A. Guia para Elaboração de Monografias e Trabalho de Conclusão de Curso. São Paulo: Atlas, 2000.
- MINISTÉRIO DA JUSTIÇA. Disponível em <<http://www.mj.gov.br>>. Acesso em: 06 jan. 2006.
- MOODY'S IVESTOR SERVICE . Disponível em <<http://www.moodys.com>>. Acesso em: 21 fev. 2006
- OHLSON, James A. Financial ratios and the probabilistic prediction of bankruptcy. Journal of Accounting Research, v. 18, n. 1, p. 109-131, spring, 1980.
- OSÓRIO, F.; VIEIRA, R. Sistemas híbridos inteligentes. XIX Congresso da SBC. Tutorial do Encontro Nacional de Inteligência Artificial. Rio de Janeiro, p. 60, Jul.1999.
- PIRAMUTHU, S. Financial credit-risk evaluation whit neural and neurofuzzy systems.European Journal of Operational Research n. 21, p. 112-310, 1999.
- PRADO, R.G. A; BASTOS, N.T; DUARTE JÚNIOR, A. M; Gerenciamento de Risco de Crédito em Bancos de Varejo no Brasil. São Paulo, Tecnologia de Crédito, n.43, p.7-30, Julho. 2000.
- ROSEMBERG, E.; GLEIT, A. Quantitative Methods in Credit Management: a Survey.Operational Research. v. 42, n. 4, p. 589-613, Jul/Aug. 1994.
- ROVEDA, A. O Processo de Concessão de Crédito no Varejo de Eletro-eletrônicos na Cidade de Caxias do Sul. 2002. 119f. Dissertação (Mestrado em Administração) - Programa de Pós Graduação em Administração, Universidade Federal do Rio Grande do Sul, Porto Alegre, 2002.
- SANTI FILHO, A. Avaliação de Risco de Crédito: para gerentes de operações. São Paulo: Atlas, 1997.
- SANTOS, J. O. dos. Análise de Crédito: Pessoas Físicas e Jurídicas. 2 ed. São Paulo: Atlas, 2003.
- SALCHENBERGER, L.M.; CINAR, E. M.; NICHOLAS, A. L.; Neural Networks: A New Tool for Predicting Thrift Failures. Decision Science. v. 23, n. 4, p. 899-916, Jul/Aug. 1992.
- SAUNDERS, Anthony. Medindo o Risco de Crédito – Novas Abordagens para o Value at Risk e Outros Paradigmas. Rio de Janeiro: Qualitymark, 2000.
- SECRETARIA ESTADUAL DE EDUCAÇÃO. Disponível em <<http://educação.pe.gov.br>>. Acesso em: 18 fev. 2006.

SECURATO, J.R. (Coord.) Crédito: Análise e Avaliação do Risco: Pessoas Físicas e Jurídicas. São Paulo: Saint Paul, 2002

SILVA, J. P. Gestão e Análise do Risco de Crédito. São Paulo: Atlas, 1998.

SINDICATO DAS ESCOLAS PARTICULARES DE PERNAMBUCO. Disponível em

<<http://www.sinepe.com.br>>. Acesso em: 11 fev. 2006.

SINDICATO DOS ESTABELECIMENTOS DE ENSINO DO ESTADO DE PERNAMBUCO. Disponível em <<http://www.sinepe.com.br>>. Acesso em: 17 fev. 2006.

THOMAS, Lyn C. A survey of credit and behavioral scoring: forecasting financial risk of lending to consumer. International Journal of Forecasting. n. 16, p. 149-172. 2000.

VALENÇA, M. Aplicando redes neurais: um guia completo. Olinda: Livro Rápido - Elógica, 2005.

VASCONCELLOS, M.S. Proposta de método para análise de concessão de crédito a pessoas físicas. 2002. 142f. Dissertação (Mestrado Economia) – Faculdade de Economia, Administração e Contabilidade, Universidade de São Paulo, São Paulo, 2002.

VERBEEK, M. A Guide to Modern Econometrics. 2 ed. New York: John Wiley Professio, 2004.

VERGARA, Sylvia C. Projetos e Relatórios de Pesquisa em Administração. São Paulo: Atlas, 1997.

ZHANG, G.; PATUWO, B. E.; HU, M.Y. Forecasting with Artificial Neural Networks: the State of the Art. International Journal of Forecasting, v.14, p. 35-62, 1998.

WEST, D. Neural Network Credit Scoring Model. Computers & Operations Research, v.27, p. 1131-1152, 2000.