

# ARQUIVO 4

# MODELOS PARA ESTIMATIVA DE RISCO DE CRÉDITO

Dimitri Avelar Macedo<sup>1</sup>; Wanyr Romero Ferreira<sup>2</sup>; Mauri Fortes<sup>3</sup>

INDEXADO

## Resumo

*Discutem-se, neste trabalho, os modelos de análise de risco de crédito massificado utilizados pelas empresas, principalmente pelo confronto dos trabalhos de dois autores conhecidos. O crescente aumento de clientes bancários que apresentam situações complexas de débito levou a uma crescente necessidade de implementação de sistemas de análise de risco de crédito mais seguros e rápidos. Apresentam-se alguns modelos estatísticos que permitem transformar as informações qualitativas sobre o cliente em números. Estes modelos de pontuação de crédito, ao contrário dos sistemas tradicionais, geram um custo menor para o credor e possibilitam maior rapidez na avaliação de uma proposta de crédito. Sua utilização varia de acordo com as estratégias da empresa e a base de análise pode ser facilmente modificada em função de alterações na política de crédito da empresa, ou mesmo, nos cenários externos. Os modelos de pontuação de crédito evoluíram dos modelos de credit scoring para os modelos comportamentais tais como o behavioral scoring, data mining e redes neurais. Concomitantemente, a análise de crédito mudou de uma análise de cadastro no ato do pedido de crédito, para análises de comportamento durante a utilização do crédito, permitindo maior precisão na medida do risco de crédito que o cliente representa para a empresa.*

**Palavras-chave.** pontuação de crédito, risco de crédito, análise de risco

<sup>1</sup> MBA, Centro Universitário UNA, Rua dos Aimorés, 1451, Bairro Lourdes, Belo Horizonte - MG, dimitri.macedo@mercantil.com.br

<sup>2</sup> Dra, Pesquisadora ID do CNPq, Centro Universitário UNA, Rua José Cláudio Resende, 80, Bairro Buritis, CEP 30455-590, Belo Horizonte - MG, fone:(31) 3379-1257, wanyr@terra.com.br

<sup>3</sup> PPhD, Pesquisador 1A do CNPq, Centro Universitário UNA, Rua José Cláudio Resende, 80, Bairro Buritis, CEP 30455-590, Belo Horizonte - MG, fone:(31) 3379-1220, mauri@una.br

## Abstract

*In this work, models of credit risk analysis are discussed, based mainly on the supplementing works of two well-known authors. Recently, the growth of consumers' debt generated a stronger need for implementing safer and faster credit risk analysis models. Statistical models that change client data into scores are the bases for credit scoring systems. These models, unlike traditional systems, lead to lower cost for the creditor and accelerate the evaluation of credit proposals. Their usage varies according to company strategies and the fundamental aspects of the analysis can be easily modified with given alterations in the credit policies of the company, or even, within the context of external sceneries. Credit scoring models have evolved to behavioral scoring, data mining and neural network systems. At the same time, the credit analysis procedures changed from a simple file investigation as of the credit request to behavioral analyses during the credit duration, allowing a more precise credit control.*

**Keywords.** Credit score, credit risk, risk analysis

## Introdução

O crédito é uma forma de criação de moeda e seu controle e seleção são instrumentos de política monetária que podem expandir ou restringir o volume e o preço do crédito. As instituições financeiras que concedem crédito estão sempre em busca de uma melhor gestão do risco envolvido na concessão de crédito. O desafio para os credores é conseguir prever e mensurar a probabilidade de ocorrência de não pagamento, no futuro, por parte do cliente tomador de empréstimo (VICENTE, 2001).

Existem vários critérios utilizados pelas instituições financeiras para tentar quantificar o risco de crédito. Dentre os mais usados, encontram-se os sistemas de pontuação de crédito. Estes sistemas podem ser utilizados sozinhos ou como parte de um sistema maior, adequando-se às estratégias da empresa e ao ambiente geográfico, sendo utilizados de forma descentralizada quanto ao uso e centralizada quanto ao controle dos processos.

O primeiro dos sistemas de crédito massificado foi o modelo de *credit scoring* e, após sua implantação, vários outros modelos foram implementados, constituindo, assim, uma evolução constante e integrada para a determinação do risco de crédito (CAOINETTE et al., 1999). Variações dos métodos estatísticos e novas tecnologias, como algoritmos genéticos, também passaram a ser largamente utilizados na concepção de sistemas de análise de crédito, colocando hoje, um grande leque de opções tecnológicas à disposição de quem vai implementá-los.

O objetivo deste trabalho foi efetuar uma revisão crítica sobre credit score, mostrar como surgiram as técnicas de crédito massificado, e discutir a evolução destas técnicas como ferramentas de análise de risco de crédito. Utilizaram-se, como referência básica para a revisão crítica, os trabalhos de BLATT (1995 e 1999) e de CAOINETTE et al. (1999), além de outras fontes.

## Modelos Subjetivos de Crédito ao Consumidor

Os sistemas de administração de risco de crédito são hoje aplicados a vários produtos de varejo e empregam uma grande variedade de técnicas que são utilizadas sozinhas ou em conjunto, com a finalidade de reduzir o risco nas propostas de crédito. No caso de empréstimos de pequeno valor, as empresas utilizam sistemas de crédito ao consumidor, porém, quando os empréstimos são de valor mais elevado, elas utilizam um híbrido de sistemas quantitativos de crédito e sistemas subjetivos de crédito, com um sobrepondo ao outro, quando apropriado.

Os bancos utilizam sistemas subjetivos de crédito que, na verdade, são regras criadas internamente na própria empresa para o julgamento de crédito. CAOINETTE et al. (1999) afirmam que estes sistemas lembram os sistemas especialistas usados em empréstimos comerciais, e citam como exemplo os critérios usados por duas empresas de empréstimos, uma japonesa e uma norte-americana, apresentados a seguir:

A. De acordo com os critérios usados por uma Empresa Japonesa, o cliente deve

- Apresentar um índice máximo de 60% entre dívida e salário;
- Ter 25 anos ou mais;
- Trabalhar há dois anos no mesmo lugar.

Ademais, o tipo de setor no qual o cliente trabalha é analisado e pode desclassificar o cliente para a concessão do empréstimo (por exemplo: pessoas do show-business e taxistas, não são aceitos).

B. De acordo com os critérios usados por uma Empresa norte-americana de empréstimos automotivos, o cliente deve

- Residir, no mínimo, por um ano na mesma residência (três anos de histórico de residência averiguável em casos limitados);
- Trabalhar, no mínimo, um ano no mesmo lugar;
- Comprovar três anos de histórico de trabalho em casos limitados (abre-se mão da exigência de permanência no emprego para solicitantes recentemente formados em nível universitário);
- Comprovar renda mínima de US\$ 1.500 por mês;
- Apresentar um índice de dívida de 50% baseado em pagamento de automóveis, hipoteca, seguro, empréstimos atuais e outros fixados;
- Apresentar boa ficha em *credit bureau*.

As decisões de crédito normalmente são tomadas em função da avaliação da capacidade de pagamento do proponente, refletida em características como: casa própria, renda, categoria de emprego e histórico de crédito, ao invés de garantias oferecidas, a não ser em casos especiais em que o valor avaliado da razão do empréstimo tenha maior importância, como é o caso de empréstimos para compra de imóveis.

## Sistemas Quantitativos de Seleção de Crédito

Uma grande variedade de métodos quantitativos vem sendo utilizada por instituições financeiras no auxílio à avaliação de risco de crédito com o objetivo de minimizar as perdas ocorridas devido a decisões equivocadas na concessão de crédito. Segundo ROSENBERG & GLEIT (1994) há muitas vantagens na utilização de métodos quantitativos em gerenciamento de crédito, destacando-se os benefícios resultantes da otimização no processo de tomada de decisão: fornece-se crédito (ou crédito adicional) aos melhores clientes (mais confiáveis), gerando aumento dos lucros e nega-se (ou diminui-se) o crédito aos piores clientes (menos confiáveis), resultando na diminuição das perdas. Além disso, políticas ótimas de cobrança minimizam os custos de administração e maximizam o montante recuperado do mal pagador.

De acordo com SANTOS (2000), o desenvolvimento ou aquisição de modelos de análise de risco de crédito é um facilitador para a tomada de decisão e permite que ela seja descentralizada dentro da organização através da padronização, da maior agilidade e objetividade na mensuração do risco de crédito. Porém, ter um modelo não significa que a empresa fará a escolha dos melhores negócios. O modelo precisa estar adequado às necessidades da empresa e às estratégias estabelecidas pela empresa quanto a produtos, público-alvo e objetivos.

Os modelos de risco de crédito estão em duas categorias: modelos de aprovação de crédito e modelos de pontuação comportamental e ambos os modelos são usados na tomada de decisão sobre a extensão do crédito e normalmente incluem as variáveis mostradas no Quadro 1 (CAQUETTE et al., 1999).

**Modelos de aprovação de crédito** - Os modelos de aprovação de crédito são usados na tomada de decisão para aprovação de um proponente, utilizando o cadastro do cliente, no momento do pedido de crédito. Estes modelos podem ser menos eficientes a longo prazo pois o perfil do cliente é mutável, a não ser que se faça novo cadastro para detectar as mudanças ocorridas no perfil do cliente.

**Modelos de pontuação comportamental** - Estes modelos são usados para maximizar a lucratividade das contas, através do uso de diferentes tratamentos com relação a linhas de crédito oferecidas e métodos de cobrança utilizados, baseando-se na análise estatística do uso da conta e dos hábitos de pagamento do cliente. Podem incluir critérios simples ou detalhados. As variáveis observadas em cada caso podem ser, por exemplo:

### A. Critérios Simples

- Número de consultas de crédito recentes;
- Pior referência de credit bureau.

### B. Critérios Detalhados

- Número de atrasos de 30, 60 ou 90 dias no último ano;
- Número de itens negativos;
- Volume da transação;
- Utilização média da linha de crédito.

Os modelos empregados para geração de listas pré-aprovadas usam itens tanto de modelos para aprovação de crédito, como para pontuação (score) comportamental e também usam dados fornecidos pelos Credit bureaus.

QUADRO 1 - Variáveis de pontuação de crédito e o impacto sobre o score*	
Variável	Impacto
Casa Própria ou Alugada	Própria ==+
Número de anos no endereço atual	Alto ==+
Renda por dependente	Alta ==+
Estado civil (solteiro, casado, divorciado, separado)	Casado ==+
Ocupação	Variável
Consultas a Credit bureau	Menos ==+
Outros cartões de crédito	Sim ==+
Cartões de crédito de redes de postos de gasolina possuídos	Sim ==+
Número de acontecimentos adversos no histórico de crédito	Menos ==+
Número de registros negativos graves	Menos ==+
Número de consultas nos últimos seis meses	Menos ==+
Número de telefone (sim ou não)	Sim ==+
Número de anos no trabalho atual	Alto ==+

\* O sinal + significa impacto positivo - FONTE: CAQUETTE et al. (1999)

## Credit Bureau

Os *credit bureaus* são empresas que coletam e fornecem dados referentes a crédito, para as empresas-membro. Assim, qualquer empresa ligada à centralizadora de informações sobre crédito pode solicitar informações sobre pessoas, ou informar à centralizadora as informações sobre crédito de seus clientes, para que estas informações sejam agrupadas com as informações das outras empresas-membro e fornecidas a quem desejar obter informações sobre esta pessoa (BLATT, 1999).

No Brasil, um sistema de Credit Bureau muito utilizado pelos bancos é o modelo fornecido pelo SERASA, empresa especializada em informações de crédito que presta informações consolidadas dos clientes para pesquisas de (SUN MICROSYSTEMS, 2004):

- Dados cadastrais (dados pessoais, endereços, profissionais, patrimônio);
- Dados comportamentais (compromissos assumidos, comprometimento da renda, hábito de pagamentos, controle de passagem);
- Certidões negativas (protestos, ações, cheques sem fundos, pendências financeiras, cheques sustados);
- Dados complementares (pesquisa de homônimos, grafias distintas por CPF, base da receita federal);
- Scorings, que também podem fornecer dados sintéticos para análise do item no mercado e avaliação do grau de risco, através da análise da quantidade de informações negativas para o CPF e para o mercado ou, até mesmo, a quantidade de consultas de cheques de um CPF nos últimos 30 dias.

Entre as informações comportamentais que constam do Credit Bureau encontra-se o cadastro positivo, que é de suma importância para a economia nacional, pois se refere a uma moderna concepção de serviço de informações, largamente utilizado em países desenvolvidos, e destinado a dinamizar o mercado de consumo. Com a autorização/solicitação prévia do cadastrado, que disponibiliza os seus dados pessoais, o cadastro visa à identificação dos riscos inerentes ao processo de concessão de crédito com o objetivo de beneficiar os consumidores com taxas de juros diferenciadas (COVAS, 2004).

Recentemente, o Conselho Monetário Nacional criou um sistema de gestão de crédito, o Central de Risco de Crédito (CRC), gerido pelo Banco Central que, obedecendo a determinadas condições, permite a troca de informações sobre operações de crédito entre os integrantes do Sistema Financeiro Nacional. O principal objetivo do sistema é prover o Banco Central de informações precisas e sistemáticas sobre as operações de crédito contratadas pelas instituições financeiras, com o propósito de proteger os recursos depositados pelos cidadãos nestas mesmas instituições. Em agosto de 1998, os dados da CRC tornaram-se acessíveis às instituições financeiras para realizar consultas sobre o montante de operações de crédito existentes a partir de janeiro de 1998, desde que com autorização específica do cliente. O valor de quaisquer operações de crédito, em dia ou atrasadas, e os valores referentes aos avais ou às fianças prestadas pelas instituições financeiras a seus clientes devem constar na Central de Risco de Crédito. As instituições financeiras somente são obrigadas a identificar os clientes com operações cuja soma seja igual ou superior a R\$ 5.000,00 (este valor passou a vigorar a partir de janeiro de 2001). Contudo, todas as operações de crédito devem constar na CRC (BACEN, 2004). A criação desta nova central de Risco de Crédito é muito importante para que se tenham informações sobre o real nível de endividamento de um proponente e também para avaliar a situação dos recebimentos de créditos dos bancos (FORTUNA, 1999).

Segundo o SERASA (2004), em economias mais avançadas como dos EUA e da Europa, o consumidor não tem acesso a qualquer modalidade de crédito se não estiver cadastrado em um serviço de Credit Bureau.

### Credit Scoring

A grande maioria das técnicas ou métodos quantitativos utiliza o sistema de pontuação, ou score. Por esse motivo, esses modelos são comumente chamados de modelos de credit scoring. Uma versão simples de um modelo de credit scoring é feita atribuindo-se pesos a algumas medidas, ou índices numéricos, buscando obter um somatório ponderado relacionado a cada solicitação de crédito. Um valor de corte é então especificado como instrumento de decisão, sendo que o crédito será fornecido para os clientes cujas solicitações apresentem um score superior ao valor de corte e negado caso contrário (SCARPEL e MILIONI, 2002).

Os métodos de Credit Scoring podem ser classificados como "estatísticos" ou "determinísticos". Métodos estatísticos caracterizam-se por utilizar técnicas que incluem tecnologias como regressão linear e redes neurais. É importante notar que, para poder implementar estes modelos, é fundamental a existência de dados sobre operações já liquidadas. Assim, de acordo com SIACORP (2004), os modelos determinísticos caracterizam-se por incorporarem o conhecimento a respeito de análise de crédito. Experiências adquiridas por especialistas no tema são traduzidas em bases de

regras de negócio, processadas por um software denominado motor de inferência, que encadeta as regras de acordo o comportamento do usuário.

Logo após a segunda guerra mundial, com a disponibilidade dos computadores para propósitos comerciais, o campo de pesquisa operacional começou a utilizar-se de métodos estatísticos para o exame quantitativo em situações empresariais, entre elas o crédito. Um pioneiro no campo foi Henry Wells, executivo da Spiegel Inc., que construiu um sistema de *credit scoring* durante a Segunda Guerra Mundial para que o modelo fosse usado por pessoas com menos experiência, a fim de substituir os vários analistas que estavam no serviço. Seu trabalho utilizou-se de técnicas estatísticas seguras, sem o poder de computação disponível nos dias de hoje. As metodologias de *scoring* continuaram a ser utilizadas nos anos 50 e o passo seguinte foi transpor as barreiras de aceitação do novo processo pela comunidade de crédito, que se fundamentava em métodos tradicionais (BLATT, 1995).

No Brasil, o uso do *credit score* foi inicialmente implantado em instituições financeiras que, mesmo possuindo modelos de análise bem rigorosos, optaram pelo uso do *credit score* como mais uma opção no processo decisório de crédito. Nos anos 60, o varejo também começou a utilizar o *credit score* que era mais eficiente para empresas que possuíam várias filiais, com processo de análise de crédito informatizado e descentralizado tomando, assim, o crédito centralizado. Por representar vantagem competitiva para as empresas, uma vez que seus custos são mais baixos e o processo de decisão mais rápido, os modelos de *credit score* foram implantados pelas empresas como uma ferramenta de administração básica (BLATT, 1995).

Os cartões de crédito não eram muito utilizados na década de 60 e as empresas de combustíveis começaram a difundir o uso através do envio em massa de cartões para indivíduos e o processo utilizado foi o de *credit scoring*. A partir dos anos 70, os cartões de crédito entraram no mercado em massa, e as administradoras começaram a ofertar seus produtos com isenção de anuidade, fazendo com que as pessoas adquirissem vários cartões ao mesmo tempo, obrigando os bancos a processar os pedidos rapidamente. Uma vez que os modelos tradicionais não poderiam ser efetivos e geravam alto índice de perdas, em função do volume de pedidos, usavam-se os modelos de *credit score*. O processo de *credit scoring* começou a ser utilizado por outros outorgantes de crédito como as empresas de financiamento de automóveis e as linhas aéreas. No final dos anos 70, estes modelos já estavam estabelecidos no mercado e eram utilizados tanto pelas grandes empresas como também pelas pequenas. Nessa época, sistemas baseados em técnicas de regressão linear rodavam em mainframes e já eram capazes de generalizar o comportamento creditício dos clientes de um Banco a partir da análise de suas bases de dados. Mais tarde, na década de 80, a tecnologia de Inteligência Artificial deu origem aos chamados Sistemas Especialistas (hoje re-batizados como sistemas baseados em regras de negócio), que passaram a ser largamente utilizados na implementação de soluções de análise de crédito para pessoa física e jurídica. Na verdade, a tecnologia de regras de negócio é mais indicada para efetuar análise de crédito a empresas, em função do grande número de variáveis que devem ser analisadas em conjunto (SIACORP, 2004).

No desenvolvimento do processo de *credit scoring*, muitas dúvidas dos analistas de crédito ainda não tinham resposta e foram solucionadas através do desenvolvimento contínuo dos sistemas de *credit scoring*. Para tal desenvolvimento, era necessário que



muitas perguntas fossem analisadas e respondidas. BLATT (1995) cita algumas perguntas com suas respectivas respostas:

- a) Quanto tempo dura um sistema de scoring e como avaliar o sistema para poder substituí-lo?
  - O processo vai durar até a degradação de seu desempenho, quando deverá ser substituído por outro sistema com desempenho igual ao do sistema anterior quando de sua instalação, mas que maximize melhor o lucro. Normalmente o substituto terá desempenho até melhor que o original, devido ao maior número de dados disponíveis.
- b) Como se mede o desempenho de um sistema de *credit score*?
  - Através da diferença entre a pontuação comum de contas satisfatórias e a diferença entre a pontuação comum de contas insatisfatórias gerando a "divergência", que é a medida de desempenho do sistema de pontuação. Quanto maior for a divergência, melhor. Também são utilizados outros métodos de análise de desempenho do sistema de scoring, como a comparação de habilidade contínua do sistema a fim de posicionar os pedidos dos proponentes e a análise da população para determinar ou não a substituição de um modelo por outro.
- c) Como o desempenho de uma conta de crédito rotativo pode ser prognosticado, se com o passar do tempo as informações dadas no pedido perdem seu propósito?
  - Através do desenvolvimento de um calculador de risco semelhante ao *credit score*, chamado "behavioral scoring", que utiliza o comportamento atual do tomador de crédito, analisando os dados de como o tomador de crédito usou o seu crédito, quanto ele usou, o que usou, se existe históricos de atrasos, e outras informações disponíveis em sua fatura.

Para montar um modelo de *credit score* é necessário que sejam estabelecidas as estratégias e objetivos da empresa, frente ao perfil de cliente desejado. Um bom modelo segundo CAQUETTE et al. (1999) deve:

- Definir a finalidade a que se aplica, isto é, quais são seus objetos de mensuração;
- Ser aprovado nos testes de validação a serem realizados ao longo do tempo;
- Mostrar-se adequado nos diferentes cenários macroeconômicos;
- Possuir consistência do grau de risco de crédito (*rating*) entre setores, partes de empresas e localizações geográficas;
- Ser sensível às mudanças reais na qualidade de crédito;
- Ser estável na ausência de mudanças;
- Estabelecer os horizontes de tempo ao qual se aplica e que demanda para reconhecer mudanças significativas de qualidade de crédito; e
- Produzir *ratings* objetivos com credibilidade no mercado financeiro.

A eficácia do modelo deve ser revisada periodicamente, para que sejam reavaliadas as premissas do sistema frente às alterações de cenários, evitando o que o mercado chama de risco de modelo (SANTOS, 2000). Estas alterações de cenários podem ser externas quando será exigida uma adequação imediata da política de crédito, para que não haja perdas frente a concorrência, ou até mesmo internas se houver necessidade ou

oportunidade na adequação das políticas e estratégias da empresa, para adquirir vantagens competitivas frente à concorrência.

A montagem de um modelo de *credit score*, através da ficha cadastral, baseia-se nas seguintes informações (BLATT, 1999):

- A) Dados pessoais do proponente e do cônjuge - permitirão um amplo estudo no histórico de crédito do cliente e seus familiares. Jovens entre 16 e 20 anos de idade ou pessoas com mais de 65 anos, em boa parte dos modelos de pontuação, ganham muitos pontos e em outros, o preconceito impede até mesmo que idosos tenham crédito.
- B) Sexo - pode indicar padrões de comportamento. As mulheres costumam zelar mais pelos compromissos assumidos.
- C) Estado civil - um divorciado terá problemas com seu cadastro, já o divorciado rico poderia eventualmente ter as portas abertas. Em diversas modelagens, solteiros perdem ponto.
- D) Dados residenciais - permitem determinar a qual tipo de público ele pertence e através de perguntas simples, pode-se determinar se o proponente possui casa própria ou alugada, ou se mora com os pais.
  - A maior pontuação é dada para o proponente que possui casa própria, porém em alguns modelos ter casa própria é perda de pontos.
  - O número do CEP pode representar pontos para o cliente se mostrar que ele está em uma região valorizada.
- E) Dados profissionais do proponente e do cônjuge - são os dados mais importantes a serem analisados. Através dos dados profissionais pode-se determinar a ocupação do proponente, o tempo em que trabalha na empresa, quanto ganha e qual o seu emprego anterior:
  - Quanto maior o número de anos no trabalho atual, maior será a pontuação.
  - A ocupação ou profissão do proponente também terá uma pontuação atribuída, porém neste item a pontuação pode ser até negativa, dependendo dos históricos negativos da profissão na empresa, ou de estratégias pré-determinadas.
- F) Referências pessoais - funciona como uma fonte alternativa para tentativa de localização do proponente em casos de desaparecimento.
- G) Referências comerciais / bancárias - Um cliente que possui cheque especial e cartão de crédito tem uma pontuação maior do que o cliente que não possui, mesmo que estes produtos também representem uma fonte que inibirá o poder de pagamento do cliente em um novo cartão, por se tratar de produtos de crédito.
- H) Dados complementares - tipos de seguros que possui, se possui plano de saúde, se participa de consórcio e/ou de crediários e para qual tipo de bens e mesmo o valor do patrimônio pessoal, também são utilizados para avaliar o perfil do proponente.

Através da análise de todos os dados de uma proposta de crédito, o sistema de credit score pode determinar a capacidade de pagamento para a proposta de crédito. Através da análise dos dados, é possível determinar a qual classe social e econômica pertence um cliente, podendo então ser mensurado seu gasto médio e quanto lhe pode ser concedido, de forma que ele possa arcar com o pagamento do crédito recebido.

Uma grande fonte de renda para as administradoras de cartão de crédito é formada pelo pagamento de juros sobre atrasos nos gastos rotativos do cliente, e assim, pequenos atrasos são altamente lucrativos para a administradora de cartões, podendo então o crédito oferecido ser um pouco maior do que a capacidade mensal de pagamento do cliente ou, até mesmo, ser oferecido ao cliente aumentos no limite de compras para que este fique em débito (pagando o mínimo da fatura, que é de 20% de seu total) e não ficando inadimplente. Estas contas podem ser gerenciadas por um sistema de crédito massificado.

Em bancos é possível, também, determinar o valor de alguns dos gastos do cliente, como contas de telefone, luz, água, impostos e taxas do governo, através da análise dos dados de pagamentos efetuados via débito automático ou, até mesmo, através da movimentação bancária média do cliente, fazendo com que a análise do valor ideal para empréstimo seja muito melhor apurada.

### Técnicas estatísticas aplicadas ao processo decisório

Os modelos de credit score atribuem pesos às características e atributos do proponente formando uma pontuação que será comparada a uma pontuação de corte para aceitação ou não, da proposta de crédito. Para a montagem do sistema de *credit score*, empregam-se técnicas multivariadas de análise de dados, como análise discriminante ou regressão. O uso destas técnicas deve-se ao desenvolvimento da informática, pois há uma grande quantidade de cálculos envolvidos. A instituição pode comprar um sistema genérico ou desenvolver seu próprio modelo, baseando em sua própria experiência e estratégias, porém se adquirir o modelo genérico, a empresa pode não obter resultados satisfatórios, em função das diferenças entre a demografia utilizada no modelo e a instituição. Este modelo normalmente é utilizado provisoriamente, até a empresa formar seu sistema com base em sua clientela.

### A análise discriminante e a utilização em credit score

A análise discriminante é uma técnica de tratamento estatístico de dados, com a finalidade de determinar quais são os "bons proponentes" e quais são os "maus proponentes". Situações passadas no histórico do proponente são levantadas e tratadas matematicamente, a fim de padronizarem as informações em um modelo para tomada de decisão (VICENTE, 2001).

No processo de decisão, são colhidas informações e forma-se juízo quantitativo ou qualitativo, com base na experiência passada. É o perfil dos clientes passados que determinarão quais são os bons e os maus pagadores. As amostras das fichas cadastrais são estudadas e separadas em dois grupos, o grupo "bom" e o grupo "mau", de acordo com os critérios estabelecidos pela empresa, ou seja, o mesmo grupo "bom" de uma empresa, pode ter elementos que são considerados do grupo "mau" em outra empresa. Todas as características das pessoas são pontuadas positiva ou negativamente, formando

uma pontuação final, que será o score do proponente e determinará a concessão, ou não, do crédito. O modelo de score é um definidor de probabilidades, ou seja, ele define o risco para a empresa, inerente à concessão de crédito para um proponente.

Probabilidade de equilíbrio, conforme destaca BLATT (1999), é a quantidade de contas boas que são necessárias para anular o prejuízo causado por uma conta má. Pode-se decidir conceder crédito a todos os proponentes, esperando a confirmação de quantas são as contas boas e quantas são as más. Apresentam-se, nas Tabelas 1 e 2, dados que exemplificam a análise discriminante. Os dados estão representados na Tabela 1 refletindo o efeito do tempo de emprego sobre a probabilidade de informação. Ressalta-se que, neste exemplo, a probabilidade de equilíbrio é dada por  $3.200/200 = 16/1$ .

Tempo de emprego	Número de bons	% de bons	Número de maus	% de maus	Probabilidades de informação
Até 2 anos	320	10	80	40	1/4
3 a 5 anos	640	20	60	30	2/3
6 a 10 anos	960	30	40	20	3/2
Mais de 10 anos	1.280	40	20	10	4/1
Total	3.200	100	200	100	

FONTE: BLATT, 1999.

A Tabela 2 exemplifica a informação de "Casa Própria/Casa Alugada/outras".

Casa Própria / Alugada / Outras	% de bons	% de maus	Probabilidades de informação
Própria	60	30	2/1
Alugada	30	60	1/2
Outros	10	10	1/1
Total	100	100	

FONTE: BLATT, 1999.

Analisando as Tabelas 1 e 2, pode-se afirmar que:

- A) A probabilidade de se ter um cliente potencial com menos de 2 anos no mesmo emprego, que mora em casa alugada será de  $16/1 \times 1/4 \times 1/2 = 2/1$  contra  $16/1$  da propriedade de equilíbrio, o que seria um grande risco para a empresa.
- B) A probabilidade de se ter um cliente com 12 anos no último emprego e que mora em casa própria, será de  $16/1 \times 4/1 \times 2/1 = 128/1$  contra  $16/1$  da propriedade de equilíbrio, o que certamente será aceito.

## Correlação

Neste estágio, segundo BLATT (1999), tem-se um problema, conforme mostra a Figura 1: ao se multiplicarem as probabilidades associadas a cada característica, presume-se que as variáveis sejam independentes, ou seja, que não haja correlação entre uma e outra. Porém, intuitivamente, sabe-se que os proprietários de imóveis tendem a ser mais velhos que os inquilinos. Idade e tempo de emprego, por exemplo, também são variáveis fortemente correlacionadas. Não se pode dizer que alguém que tenha 24 anos, possa ter residido por 25 anos no mesmo endereço. Existem ferramentas estatísticas que permitem estimar a correlação entre variáveis, evitando a escolha de características inúteis.




FIGURA 1 - Correlação entre idade, tempo de emprego e tempo de residência (BLATT, 1995)

## Técnicas multivariadas

As técnicas multivariadas permitem selecionar, de forma eficiente, dois grupos, segundo critérios pré-definidos. Para CAOUILLE et al. (1999), estas técnicas podem ser a otimização (função objetiva para minimizar o erro de classificação), análise discriminatória, análise logit, análise probit ou análise de sobrevivência. A equação desenvolvida deve ser capaz de separar as boas contas das ruins. Quanto menos superposição houver entre as distribuições de score, melhor o modelo poderá distinguir entre um bom e um mau crédito.

Para BREALEY (1998), a análise discriminante múltipla é uma técnica estatística linear para atribuir um peso a cada variável, a fim de separar os clientes "bons" dos "ruins". Edward Altman, citado por CAOUILLE et al. (1999), usou a análise discriminante múltipla para prever riscos de crédito inaceitável e determinar quais empresas iriam à falência no período de 1946-1965. O cálculo pode ser efetuado por meio da seguinte equação:

$$Z = \frac{RAJI}{ativo\ total} + \frac{vendas}{ativo\ total} + \frac{valor\ de\ mercado\ do\ capital\ proprio}{valor\ contábil\ da\ dívida} + \frac{lucros\ retidos}{ativo\ total} + \frac{ativo\ circulante}{ativo\ total}$$

em que RAJI significa resultados antes dos juros e impostos. Esta equação mostra as diferentes variáveis em jogo.

Segundo BLATT (1999), a medida do poder discriminante de um sistema de score é a divergência, que é a distância entre os "picos" das duas curvas de distribuição de bons e maus. Para CAOUILLE et al. (1999), os modelos de *credit score* pressupõem que exista uma métrica separando os créditos bons dos maus clientes (o ponto de corte), dividindo-os em dois grupos distintos. Poderá ocorrer uma superposição entre os dois universos, conforme mostra a Figura 2. Nestes modelos é importante que os valores sejam transformados em percentuais (normalizados), a fim de se terem curvas de mesmo tamanho.

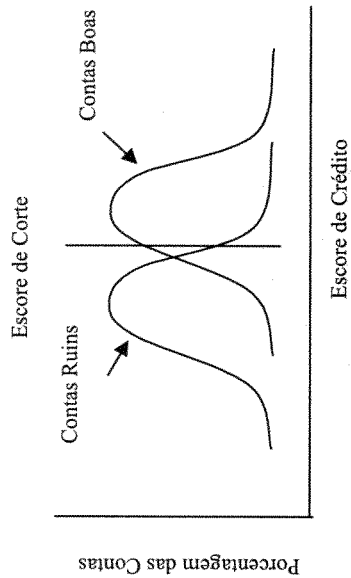


Figura 2 - Distribuição das pontuações de crédito de contas boas e ruins em um Modelo de Pontuação de Crédito (CAOUILLE et al. 1999)

Vê-se que, quanto mais separadas forem as curvas, maior poder de discriminação terá o modelo, conforme mostra a Figura 3. Nesta figura,  $d$  é a distância entre os picos. Observa-se que o sistema 2 é melhor do que o sistema 1, pois, se for traçado um "ponto de corte" arbitrário no sistema 1, será eliminada uma grande parcela de bons clientes para se eliminar uma quantidade significativa de maus clientes, enquanto que no sistema 2, uma menor parcela de bons clientes serão eliminados para se eliminar a maioria dos maus clientes. Dos clientes rejeitados não se pode dizer que são todos maus clientes e existem técnicas que podem separar, dentre os clientes rejeitados, aqueles com probabilidade de ter um bom perfil, sem aumentar o risco da carteira.

Para CAOUILLE et al. (1999), nos sistemas de *credit score*, desenvolve-se uma amostra quantitativa de bons e maus créditos baseada na experiência real de crédito da empresa, e, a partir daí, pode-se criar um projeto de seleção de amostras, a fim de eliminar vícios de amostragem e assegurar a validação do modelo desenvolvido. Alguns grupos podem apresentar diferenças causadas por fatores tais como geografia, idade ou sexo. Devem-se eliminar as variáveis que não podem ser utilizadas em modelos de *credit score*. O tamanho da amostra para cada grupo varia, normalmente, de 1.000 a 3.000 e a amostra deve ser o mais aleatória possível.

Segundo BLATT (1999), as informações coletadas dos clientes no sistema de score são agrupadas normalmente em duas tabelas. Na primeira se aloca de 8 a 12 características do cliente, com dois a seis atributos para cada característica, conforme Tabela 3. Na



segunda tabela, coloca-se a distribuição de *score* para que, através da fixação do ponto de corte, se possa verificar o índice de probabilidade total. Na Tabela 3, as probabilidades foram transformadas em pontos e os pontos foram construídos de maneira que a cada 20 pontos, corresponda a duplicação da probabilidade, ou seja, um proponente que tenha 13 anos no atual emprego é duas vezes melhor do que um proponente com menos de um ano no trabalho. Nesta tabela, das características alocadas, seis foram extraídas da ficha cadastral e duas de acordo com o histórico de crédito do cliente, ou através do próprio cadastro, ou através de empresas especializadas em serviços de informação de clientes.




Figura 3 - Análise do ponto de corte (BLATT, 1999)

Figura 3 - Análise do ponto de corte (BLATT, 1999)

A Tabela 4 mostra a distribuição de *score* em que, através da fixação do ponto de corte, pode-se verificar qual o percentual de candidatos aceitos dentre os bons clientes e os considerados maus clientes, e qual é o percentual de mau desempenho na carteira. O objetivo é ter uma perda menor do que antes da implantação do sistema. Através da Tabela 4, a empresa pode decidir se utilizará o ponto de corte com a função de minimizar as perdas com maus clientes, ou expandir o volume de crédito sem aumentar o nível relativo de perdas.

TABELA 3 - Pontuação de Crédito

Características	Pontos					
	Própria alugada	Alugada	Outros	5-9 anos	10-12 anos	> 13 anos
Casa própria/ alugada	46	19	25			
Tempo de emprego	< 1 ano 16	1-2 anos 22	3-4 anos 26	5-9 anos 28	10-12 anos 30	> 13 anos 36
Cartão de Crédito	Sim 19	Não 0				
Tipo de conta*	Somente c/c 30	c/c e poupança 50	C/c e fundos 55	nenhuma 0	não informou 20	
Profissão	executivo apostentado 40	supervisão gerência 35	Profissional liberal 31	cargo administrativo 25	vendas autônomas 10	outros 20
Idade (anos)	< 25 11	25 a 30 22	31 a 35 29	36 a 40 45	41 a 50 55	> 50 58
Histórico de Crédito	nada consta 25	1 ocorrência 11	1 protesto 5	> 1 protesto -60		

FONTE: BLATT, 1999. \* c/c - conta-corrente

TABELA 4 - Distribuição de score

Score	% Total	% bons	% maus	% maus/total
170	77,4	87,1	31,5	7,1
172	76,4	86,1	30,3	6,9
174	75,0	84,8	28,9	6,7
176	73,4	83,2	27,2	6,2
178	71,9	81,6	25,7	6,2
180	70,5	80,1	24,6	6,1
182	68,2	77,8	22,6	5,8
185	65,4	74,9	20,1	5,4
189	59,9	69,1	16,5	4,8
195	54,6	63,2	13,6	4,4

FONTE: BLATT, 1999.

A Tabela 5 mostra que, na faixa entre 195 e 204 pontos, o sistema aceitará 62,6% dos proponentes. Para os que possuem casa própria, a taxa de aceitação será de 80,4%, contra 32,3% dos que moram em casa alugada e, sendo assim, os clientes com casa própria certamente serão escolhidos para o envio de uma mala direta.

Segundo BLATT(1999), a Tabela 5 também permite que a administração centralize a administração da carteira de crédito por produto. A tabela garante a homogeneidade da aplicação da política de crédito da empresa, em todos os seus pontos de venda e torna menos desgastantes os processos de mudança de política de crédito, pois bastará ajustar o modelo às novas necessidades, sem precisar explicar detalhadamente para os pontos

de venda. Através da análise das estatísticas fornecidas pelo sistema, a empresa pode também determinar se um ponto de venda tem melhor ou pior desempenho em relação à média, levando, portanto, em conta, falhas na administração ou alteração nas condições de mercado diferentes.

TABELA 5 - Taxa de aceitação de acordo com tipo de residência (%)

Score (pontos)	Própria	Alugada	C/parentes	Outros	Total
Menos de 169	100,0	100,0	100,0	100,0	100,0
170 a 184	87,8	58,3	68,5	78,0	77,4
185 a 194	82,9	45,5	52,1	72,8	69,6
195 a 204	80,4	32,3	41,3	64,2	62,6
205 a 219	76,9	25,4	30,7	53,7	55,9
220 a 239	70,4	17,5	19,4	38,6	46,7
240 a 259	55,7	6,2	5,4	18,2	31,4
Mais de 260	31,4	1,6	1,1	6,4	16,2

FONTE: BLATT, 1999.

Uma análise estatística pode estimar a validade do modelo através da verificação de dois tipos de erro de amostragem (CAOJETTE et al., 1999): erro Tipo I (probabilidade de não identificar corretamente maus créditos e, assim, aceitá-los) e erro Tipo II (probabilidade de recusar crédito aos clientes bons).

### Behavioural Scoring

O *Behavioural Scoring* (crédito por comportamento/desempenho) é uma ferramenta para análise de riscos de crédito como inadimplência e pagamentos em dia, entre outras características que tem como base aspectos comportamentais e de atividades de clientes da instituição (VICENTE, 2001). Este sistema é muito utilizado em bancos para o crédito de cheque especial e em administradoras de cartão de crédito.

Segundo BLATT (1995), o *Behavioural Scoring* é um sistema dinâmico de pontuação de crédito que combina as informações de crédito com dados anteriores e desempenho comercial. Este sistema é utilizado para determinar limites de crédito, fornecer subsídios para a tomada de decisão de crédito, priorizar cobranças, padronizar a tomada de decisões creditícias através do incremento da automação, avaliar as estratégias e políticas da empresa na área de crédito e criar critérios de decisões de crédito. O *Behavioural Scoring* traz benefícios para a instituição, através do melhor controle na concessão de crédito, maior flexibilidade nas decisões de crédito, melhor atendimento ao cliente, maior eficiência empresarial e redução de perdas creditícias.

O *Behavioural Scoring* também pode ser usado como parte de um sistema maior. Na área de cartões de crédito, quando da re-emissão de cartões, os fatores a serem mais considerados incluem o uso do cartão e os históricos de atraso, sendo um sistema auxiliar na tomada de decisão na re-emissão de cartões.

O *Behavioural Scoring* utiliza praticamente o mesmo processo matemático que o *Credit score*, porém seus dados são preparados para que a tabela possa ser aplicada às contas todos os meses, a fim de determinar mudanças na posição de risco da conta.

No início do processo, projeta-se um formato de arquivo mestre que guardará as informações necessárias. Os dados devem ser acumulados neste arquivo mestre por, no mínimo, seis meses (BLATT, 1995). Este período será determinado "tempo de observação", no qual será possível identificar algumas contas como Boas e outras como contas Ruins. Quanto houver um bom número de contas boas e ruins, o sistema de *Scoring* será construído baseado nos dados do arquivo mestre. E o resultado será uma tabela de pontuação que poderá ser implantada no sistema de faturamento do usuário, que calculará, de cada vez, o risco futuro para cada conta.

Se as estratégias implementadas no *Behavioural Scoring* mostrarem resultado, o modelo trará, no futuro, resultados mais satisfatórios do que os previstos pelo *Credit score*. Porém, o modelo de *Behavioural Scoring* tem como função a mudança contínua do cálculo inicial para melhor e, sendo assim, o sucesso do sistema não está na precisão da sua medida de risco, mas sim pela melhoria contínua da base de clientes da carteira, através da medida da eficiência de estratégias e políticas adotadas pela administração da empresa.

### Data Mining

A técnica de data mining consiste em extrair informações escondidas em uma grande base de dados, com a finalidade de agilizar a tomada de decisões. Segundo FAYYAD et al. (1996), data mining é o processo não-trivial de identificar, em dados, padrões válidos, novos, potencialmente úteis e ultimamente compreensíveis.

A empresa que emprega a técnica de data mining é capaz de criar parâmetros para avaliação de comportamento, identificar afinidades entre as escolhas de produtos e serviços, prever os hábitos de compras dos clientes e detectar fraudes tendo por base a análise comportamental do cliente. Através da análise de padrão comportamental, o sistema de data mining indica a presença de oportunidades (HIPOLITO, 1997). O processo de funcionamento é dividido em três classes, conforme Figura 4.

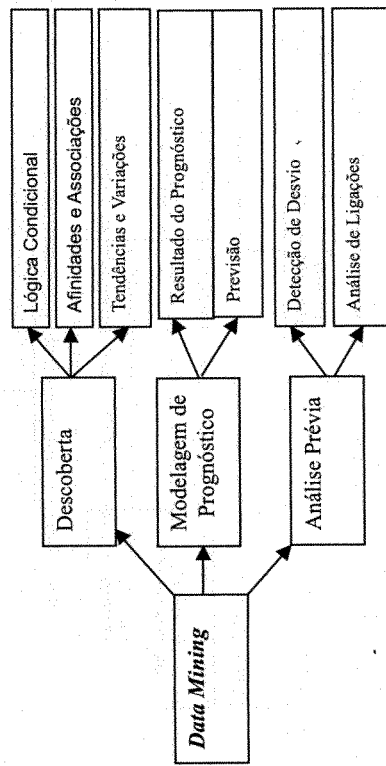


Figura 4 - Funcionamento do sistema de Data Mining (HIPOLITO, 1997)



Na Figura 4, o processo de descobrimento é o processo de análise de um banco de dados, com a finalidade de encontrar padrões escondidos, sem uma idéia ou hipótese pré-determinada sobre o que são esses padrões. O próprio programa encontra padrões sem a ordem do usuário. Os padrões descobertos podem ser ricos em informações que determinarão a qualidade e utilidade da descoberta.

Na modelagem de prognóstico, os padrões descobertos serão utilizados para prognosticar o futuro, permitindo que o usuário submeta valores desconhecidos de campos nos registros, para que o sistema suponha os valores desconhecidos baseando-se em padrões descobertos no banco de dados.

A análise prévia aplica os padrões extraídos para encontrar anomalias ou elementos de dados raros. Para descobrir os dados raros, primeiro encontram-se os dados que seguem uma norma ou os habituais para, posteriormente, detectar os dados que se desviam dos habituais dentro de certo limite.

### Modelos de Árvore de Decisão

Na abordagem de árvore de decisão, os atributos do proponente são analisados sucessivamente do mais importante para o menos importante, como em um organograma. A tomada de decisão de crédito é feita de acordo com a probabilidade de inadimplência em cada nível e, à medida que novos níveis vão sendo criados, a relação de bons / ruins se aproximará de 0 ou de 1, aumentando-se assim a probabilidade da seleção ser eficaz, conforme mostra a Figura 5 (CAOQUETTE et al., 1999).

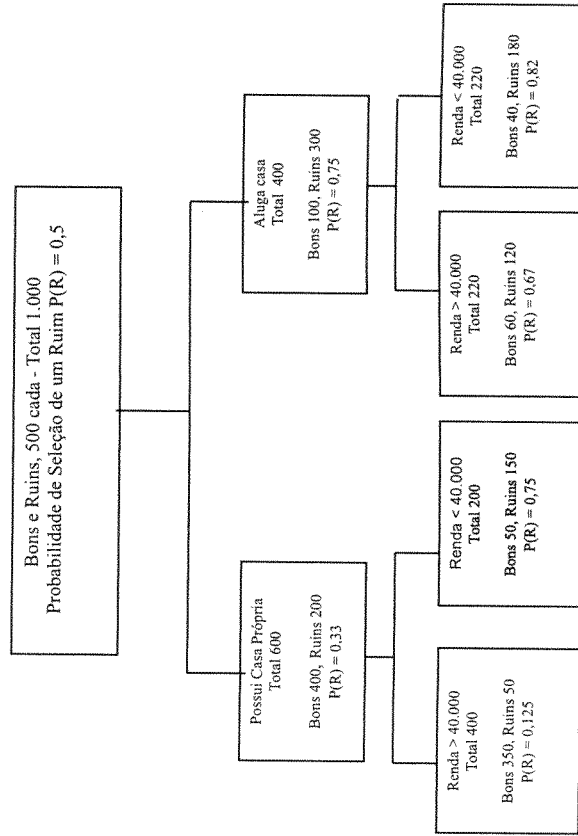


FIGURA 5 - Modelo de Árvore de decisão (CAOQUETTE et al., 1999)

### Redes Neurais

Redes Neurais são sistemas computacionais que apresentam um modelo matemático inspirado na estrutura neural de organismos inteligentes e que adquirem conhecimento através da experiência. Uma grande rede neural artificial pode ter centenas ou milhares de unidades de processamento enquanto o cérebro de um mamífero pode ter muitos bilhões de neurônios. Uma rede neural artificial é composta por várias unidades de processamento, cujo funcionamento é bastante simples. Essas unidades geralmente são conectadas por canais de comunicação que estão associados a determinados pesos. As unidades fazem operações apenas sobre seus dados locais, que são entradas recebidas pelas suas conexões. O comportamento inteligente de uma Rede Neural Artificial vem das interações entre as unidades de processamento da rede. Aplicações da inteligência computacional para o tratamento de problemas de crédito sempre foram alvo de interesse da área financeira. Vários bancos e companhias de crédito internacional, tais como *Mellon Bank* e o *Visa Internacional Inc.*, utilizam Redes Neurais Artificiais (RNAs) para estudar os padrões de comportamento no uso de cartões de crédito pelos clientes e para detectar transações potencialmente fraudulentas (SENGER e CALDAS JUNIOR, 2001)

Os sistemas de redes neurais são usados em problemas de *credit score*, como previsão de falências e detecção de fraudes, pois aprendem por exemplos, possuem grande adaptabilidade, têm tolerância a falhas e permitem implantação rápida (BLATT, 1999). Administradoras de cartões de crédito possuem em seu banco de dados todo o histórico de gastos do cliente, podendo formular com facilidade quais são os padrões de comportamento do cliente, as alterações nos padrões e quando as mudanças desses padrões podem ser perigosas para a administradora. Na análise de crédito tornou-se muito importante a detecção de maus pagadores e os sistemas de redes neurais podem ser utilizados como uma ferramenta inteligente, que aprende de maneira sistemática, detectando novos modelos de fraudes e inadimplências e, assim, mantendo-se constantemente atualizada.

Uma simples mudança brusca de preços em algum item de despesa no orçamento doméstico pode modificar o perfil de um bom pagador. Nos modelos de *credit scoring* esta mudança só seria detectada, se houvesse um novo processamento do cadastro do cliente, mas com o sistema de redes neurais, esta mudança seria instantânea, fazendo com que o sistema identificasse o novo perfil de seus clientes.

Os modelos de redes neurais provaram também ser mais eficientes que os de *Credit score* em níveis de acerto na possibilidade de inadimplência e também na diminuição do universo de "maus" clientes, não prejudicando as vendas das empresas, na formulação do ponto de corte.

A padronização de dados pode, também, ser um ponto positivo para intercâmbio de dados entre empresas, fazendo com que se tenha um universo maior de clientes e de modelos de inadimplência, para a base de dados dos sistemas de redes neurais, diminuindo também o custo do processo. Outra forma de diminuir o custo do processo é adquirir bancos de dados de terceiros ou utilizar-se das informações de empresas especializadas.

## Conclusões

Discutiram-se, neste trabalho, várias ferramentas de análise de risco de crédito massificado utilizadas pelas instituições de financiamento. Mostrou-se que, com a globalização e descentralização das atividades das empresas, tornou-se necessário que os processos de análise de risco de crédito fossem centralizados, para permitir um melhor controle por parte das empresas. Os processos de crédito massificados surgiram para mudar os conceitos da análise tradicional de crédito, que até então formulava "rótulos" para os clientes, de acordo com o seu perfil no momento do pedido de crédito e cuja análise era feita por especialistas em análise de crédito.

Após estudar a evolução dos modelos de análise de crédito massificado, conclui-se que esses modelos constituem uma mudança radical na metodologia de análise de risco de crédito, porém estão longe de atingirem o ideal. Até hoje, estes sistemas, no máximo, aprendem com as mudanças de atitudes. Espera-se que, futuramente, estes sistemas possam formular, de forma automática, as probabilidades de mudança de perfil do cliente frente a mudanças no ambiente tornando-se, assim, um modelo perfeito para análise de risco de crédito.

## Referências

- BACEN. Sistemas de informações de crédito. [on-line] Disponível em: [http://www.bcb.gov.br/pre/bc\\_atende/port/crc.asp#1](http://www.bcb.gov.br/pre/bc_atende/port/crc.asp#1). Acesso em: 20/09/2004.
- BLATT, A. Credit scoring. São Paulo: SCIEQUIFAX, 1995. 52 p.
- BLATT, A. Avaliação de risco e decisão de crédito. São Paulo: Nobel, 1999, 232 p.
- SUN MICROSYSTEMS. Certificação digital, novo alvo da Serasa. [on-line] Disponível em: <http://br.sun.com/ponto-com/cases/serasa.html>. Acesso: 20/09/2004.
- BREALEY, R.A., MYERS, S.C., Princípios de finanças empresariais: 5. ed. São Paulo: McGraw-Hill, 1998, 998 p.
- CAOQUETTE, J.B., ALTAMAN, E.I. & NARAYANAN, P.I. Gestão do risco de crédito: o próximo grande desafio financeiro. Rio de Janeiro: Qualitymark, 1999, 489 p.
- COVAS, S. Credit bureau é importante para ampliar crédito. [on-line] Disponível em: [http://www.serasa.com.br/serasalegal/35-set-04\\_m1.htm](http://www.serasa.com.br/serasalegal/35-set-04_m1.htm). Acesso em: 14/10/2004.
- FAYYAD, U., PIATETSKI-SHAPIRO, G. & SMYTH, P. The KDD Process for Extracting Useful Knowledge from Volumes of Data. In: Communications of the ACM, pp.27-34, nov.1996.
- FORTUNA, Eduardo. Mercado financeiro produtos e serviços. 13. ed. Rio de Janeiro: Qualitymark, 1999.
- HIPOLITO, M. Data Mining. Monografia. Rio de Janeiro: UERJ, 1997, 18 p.
- LOUREIRO, R. Agilize o crédito utilizando o produto de credit bureau, o maior banco de informações positivas do país sobre consumidores, para otimizar o desenvolvimento dos negócios. São Paulo: SERASA, 1998.
- ROSENBERG, E. & GLEIT, A. Quantitative methods in credit management: a survey. *Operations Research*, vol. 42, n.4, p.589-613, 1994.

SANTOS, C. B. Gestão de risco de crédito em instituições financeiras, 2000. 213 p. Tese de Mestrado. São Paulo: USP.

SCARPEL, R. A. & MILIONI, A. Z. Utilização conjunta de modelagem econométrica e otimização em decisões de concessão de crédito. *Pesquisa Operacional*, vol.22, no.1, p.61-72, Jan./June 2002. ISSN 0101-7438.

SENGER, L. J. & CALDAS JUNIOR, J. Análise de risco de crédito utilizando redes neurais artificiais. *Rev. Ccei - Urcamp*, vol.5, n. 8, p. 19-26 - Ago., 2001. ISSN 1415-2061

SERASA. Cadastro Comportamental da Serasa beneficia consumidor. [on-line] Disponível em: <http://www.serasa.com/guia/49.htm>. Acesso em: 14/10/2004.

SIACORP, 2004. Creditflow - Rating 2682. Classificação de Operações de Crédito e Constituição de Provisão para Créditos de Liquidação Duvidosa. [on-line] Disponível em: <http://www.siacorp.com.br/creditflow2682.htm>. Acesso em: 14/10/2004.

VICENTE, E.F.R. A estimativa do risco na constituição da PDD, 2001. 179p. Dissertação de Mestrado. São Paulo: USP.