

## Modelo Inteligente para Avaliação de Risco de Crédito Pessoal Baseado na Lógica *Fuzzy*

**Autoria:** Antonio Airton Carneiro de Freitas, Rosana Tavares, Alessandra Ávila Montini

### Resumo

O objetivo principal deste trabalho é projetar, implementar e testar um modelo para avaliar risco de crédito pessoal baseado no conhecimento de especialistas desta área. Um modelo *fuzzy* hierárquico é apresentado e fornece uma medida de risco de crédito ajustada a partir da *expertise* dos profissionais desta área e de acordo com a política de crédito traçada para atingir os objetivos da empresa. Os resultados demonstram que este modelo é superior ao *credit scoring* tradicional e pode ser ajustado de acordo com a política de crédito da empresa e o conhecimento dos profissionais desta área.

### 1. Introdução

Os sistemas inteligentes, para diferenciá-los da inteligência artificial tradicional, são denominados atualmente como inteligência computacional e são divididos em três grandes áreas. As redes neurais [1] têm capacidade de aprendizagem. Já a lógica *fuzzy* [2, 3] lida com sistemas que envolvem informações imprecisas, vagas e o conhecimento de especialistas. Finalmente, a computação evolutiva [4] faz buscas inteligentes sobre um universo relativamente grande. Como a avaliação de crédito envolve informações qualitativas, imprecisas e o conhecimento de especialistas de crédito, logo a opção foi utilizar conjuntos *fuzzy*. Entretanto, para aplicações na área de detecção de fraudes, as redes neurais são candidatas naturais.

O sucesso das empresas que utilizam modelos de risco de crédito não deve ser medido somente pelo poder discriminante de seus modelos. A métrica mais importante é o tamanho das perdas da carteira de crédito, ou seja, é desejável que seja a menor perda possível [5]. Neste contexto, os modelos baseados em lógica *fuzzy* se diferenciam dos convencionais por ter a flexibilidade de utilizar a *expertise* da equipe de gestão de crédito e ajustar as regras a partir de mudanças que possam ocorrer na saúde financeira dos clientes.

As políticas de crédito são ditadas pelos objetivos de cada empresa. Não existe política certa ou errada. Se o objetivo é ganhar *market share* deve-se aceitar maior risco e adotar uma política mais agressiva de crédito. Já se a empresa tem forte presença no mercado pode optar por gerar mais fluxo de caixa para aumentar o seu valor presente líquido.

As fraquezas geralmente encontradas nas empresas em relação à área de risco de crédito são: decisões subjetivas e sem método; falta de treinamento dos profissionais da área; falta de critérios para resolver conflitos resultantes das avaliações. Uma dificuldade natural decorrente deste tipo de avaliação é o fato de que a saúde financeira dos clientes varia ao longo do tempo.

Os benefícios de se utilizar um método causal objetivo, como o proposto neste trabalho, são: o *staff* respeita os *ratings* de crédito e opera com confiança; *ratings* são facilmente justificados para os clientes e ajudam nas negociações; processo de decisão rápido e consistente; permite a criação de bancos de dados com *ratings* de clientes para a avaliação de políticas de crédito.

Os segmentos de pequenas e micro empresas e de pessoas físicas geralmente utilizam modelos proprietários de *credit scoring* que permitem, inclusive, a definição de limites pré-aprovados para operações de curto prazo, e possibilitam a otimização do processo de crédito por meio da atribuição de classificações em função de faixas de *score*.

Sistemas de *credit scoring* são modelos estatísticos destinados à avaliação de riscos de operações de crédito de menor valor unitário, mas com características de risco muito parecidas, ou seja, certa padronização dos riscos, com baixo valor unitário, para um elevado número de clientes.

No Brasil, os sistemas de *credit scoring* têm sido utilizados para as operações de crédito ao consumidor, para produtos como financiamento de veículos ou limites para cartão de crédito. Os responsáveis pela gestão de riscos de crédito têm reconhecido os benefícios da implantação desses sistemas para a redução de custos, para a consistência das aprovações e para a redução das perdas. Como consequência, a utilização desses sistemas tem crescido como ferramenta para a análise e decisão de crédito.

As características do tomador de crédito normalmente são obtidas por meio da ficha cadastral e do comportamento de crédito anterior. Os modelos partem da premissa de que é possível estabelecer uma métrica que separe bons de maus clientes. A partir das características cadastrais do proponente, os modelos estabelecem uma pontuação – o *score*, que vai refletir o risco esperado para esse crédito. Alguns modelos consideram também os riscos da operação de crédito envolvida, além dos riscos intrínsecos do proponente.

A partir de uma base de dados históricos, os sistemas utilizam técnicas estatísticas multivariadas como, por exemplo, regressão linear, regressão logística, análise discriminante, árvore de decisão e redes neurais. O desenvolvimento dos parâmetros de análise deve partir de uma base de dados própria, ou seja, não devem ser modelos importados de outros usuários.

Entretanto, os modelos de avaliação de riscos de créditos baseados em dados históricos, como o *credit scoring*, têm limitações. Por exemplo: a inadimplência pode ocorrer em função de fatores externos – os chamados riscos sistêmicos; a imperfeição, desatualização ou incorreção das informações que são consideradas pelo avaliador do risco –; a ausência de bancos de dados históricos ou mais abrangentes sobre as informações dos clientes, potenciais tomadores de risco de crédito; a ausência de dados históricos dos registros de inadimplência.

O objetivo deste trabalho é propor um modelo baseado no conhecimento de especialistas para análise e concessão de crédito específico para o segmento de pessoa física e com capacidade para captar as particularidades do contexto de cada empresa. O artigo está organizado como segue: na Seção 2 é apresentada a metodologia; na Seção 3 são apresentados os resultados. As conclusões e pesquisas futuras são apresentadas na Seção 4.

## 2. Metodologia

Dois modelos *fuzzy* (convencional e hierárquico) são propostos para realizar a avaliação do crédito pessoal. Com o intuito de testar a utilidade destes modelos foram coletadas amostras de operações de crédito e também foram convidados dois especialistas em crédito pessoal para avaliar a capacidade de crédito dos clientes relacionados na amostra coletada. Os mesmos clientes são avaliados pelos modelos de *credit scoring*, *fuzzy* convencional e *fuzzy* hierárquico. Os resultados das avaliações fornecidas pelos dois especialistas, pelo modelo *credit scoring* e pelos dois modelos *fuzzy* (convencional e hierárquico) são comparados. O software Matlab/Simulink 14.0 foi utilizado para realizar as simulações.

### 2.1 Modelo *credit scoring*

O sistema de *credit scoring* é um modelo estatístico e, portanto, baseia-se em experiências passadas. Os modelos tradicionais de *credit scoring* atribuem pesos estatisticamente predeterminados a alguns atributos dos solicitantes, para gerar um escore de crédito e, de um modo geral, utilizam-se técnicas de otimização ou técnicas estatísticas multivariadas [6].

Os sistemas podem ser desenvolvidos tanto para a concessão de novas operações, como para a pré-aprovação de limites de crédito. Um sistema de *credit scoring* pode ser desenvolvido também para classificar os clientes como desejáveis ou não desejáveis, sem se limitar ao conceito de inadimplência.

O desenvolvimento de um sistema de *credit scoring* para a avaliação de risco de operações de crédito para a decisão de aprová-las ou não geralmente segue as seguintes etapas [7, 8]: 1) planejamento e definições; 2) identificação das variáveis potenciais; 3) planejamento amostral e coleta dos dados; 4) determinação da fórmula de pontuação; 5) determinação do ponto de corte ou faixas de escores; 6) determinação das regras de decisão; 7) validação do sistema.

Para o desenvolvimento de um modelo de *credit scoring* primeiramente devem ser definidos os conceitos de inadimplência, de intervalo de observação e de período de desempenho. A probabilidade de inadimplência é o que se deseja prever. Esta medida deve ser determinada por quem irá desenvolver o modelo: a partir de que momento será caracterizada a inadimplência para o avaliador de risco. Toda a base de dados estatísticos passará a utilizar essa pontuação para as medidas de probabilidade de inadimplência. O intervalo de observação é o período passado que deve ser considerado para a avaliação das características cadastrais do tomador do risco. O período de desempenho é o período que se deseja prever. O modelo pretende classificar o tomador de crédito como bom ou mal pagador unicamente para esse período previsível.

O desenvolvimento dos modelos também requer a definição de quais características do proponente serão consideradas, como, por exemplo, idade, sexo, ocupação, renda, patrimônio,

histórico das operações anteriores, restrições cadastrais como protestos e cheques devolvidos. As técnicas estatísticas identificarão o conjunto de variáveis que melhor expõe o risco mensurável do proponente. Devem também ser adotados critérios para avaliação da consistência de dados, como o enfoque nas informações não disponíveis – *missing values* e *outliers*.

Os modelos de *credit scoring* devem determinar também o ponto de corte, o valor pré-determinado que separe a aprovação da não aprovação. Há vários critérios para a determinação desse ponto de corte, e isso implica que, em todo o modelo de *credit scoring* podem ocorrer dois tipos de erros: a recusa da operação causaria a perda de um bom negócio ou a aprovação da operação resultaria em um empréstimo problemático. Esse ponto de corte pode ser alterado em função da política de crédito da empresa que pode mudar, por exemplo, de acordo com a conjuntura econômica, por exemplo, reduzindo a faixa de aprovação diante da expectativa de cenário que recomende maior restrição ao crédito.

Há sistemas de *credit scoring* que usam faixas de escores, em que as operações em determinadas faixas ficam automaticamente aprovadas ou recusadas, e as faixas intermediárias podem ser submetidas a uma análise mais detalhada. Ao se desenvolver um maior número de faixas de escores, as instituições podem também desenvolver diferentes estratégias de negociação, quanto ao volume, prazo e garantias exigidas nas operações, de acordo com o grau de risco.

Em alguns casos, o resultado do sistema de *scoring* não é uma escala de pontuação por qualidade do risco, mas um percentual (de 10 a 50%) da renda líquida do cliente que poderia ficar comprometida com as parcelas do financiamento [10]. Dessa forma, o sistema acaba determinando os volumes máximos para as operações.

## 2.2 Modelos *fuzzy*

A teoria dos conjuntos nebulosos (lógica *fuzzy*) foi criada por Zadeh [2, 3] e ainda está sendo constantemente aperfeiçoada [11] para ser uma ferramenta matemática para expressar numericamente características próprias de nossa linguagem.

O desenvolvimento de um modelo *fuzzy* para analisar o risco de crédito requer também a participação de um especialista desta área. Esse profissional vai fornecer as variáveis de entrada e auxiliar o especialista em *fuzzy* na definição das funções de pertinência e na escolha da base de regras, de tal forma que os valores de saída obtidos estejam de acordo com o especificado pelo especialista em crédito do setor de atividade em que vai ser aplicado este modelo. As informações importantes para se definir os parâmetros internos de um modelo *fuzzy* podem ser encontradas em Mendel (1995) [11].

Assim, para o desenvolvimento de um modelo *fuzzy* de risco de crédito, primeiramente definem-se quais serão os dados de entrada, ou seja, as variáveis que influenciarão diretamente na tomada de decisão. Especialistas de crédito, fazendo testes em diferentes situações identificam vários fatores importantes, por exemplo: idade, renda, valor do crédito, tempo em que este crédito será quitado, tempo de emprego e *rating*. Dentre estes fatores, existem aqueles que possuem um grau de importância maior, como é o caso do *rating* de crédito. Outro fator que possui uma importância maior sobre os demais é a idade. Neste trabalho serão consideradas somente essas seis entradas, mas nada impede que o modelo seja adaptado para que sejam acrescentadas outras entradas.

### 2.2.1 Modelo *fuzzy* convencional

Para se projetar um modelo de avaliação de risco de crédito *fuzzy* convencional de acordo com a Figura 2.1, se faz necessário uma quantidade de regras considerável. Os ajustes dos parâmetros tornam-se trabalhosos e consome muito tempo de trabalho. Caso seja necessário um aumento expressivo do número de entradas este tipo de estrutura pode se tornar impraticável, já que o número de regras aumenta exponencialmente [9].

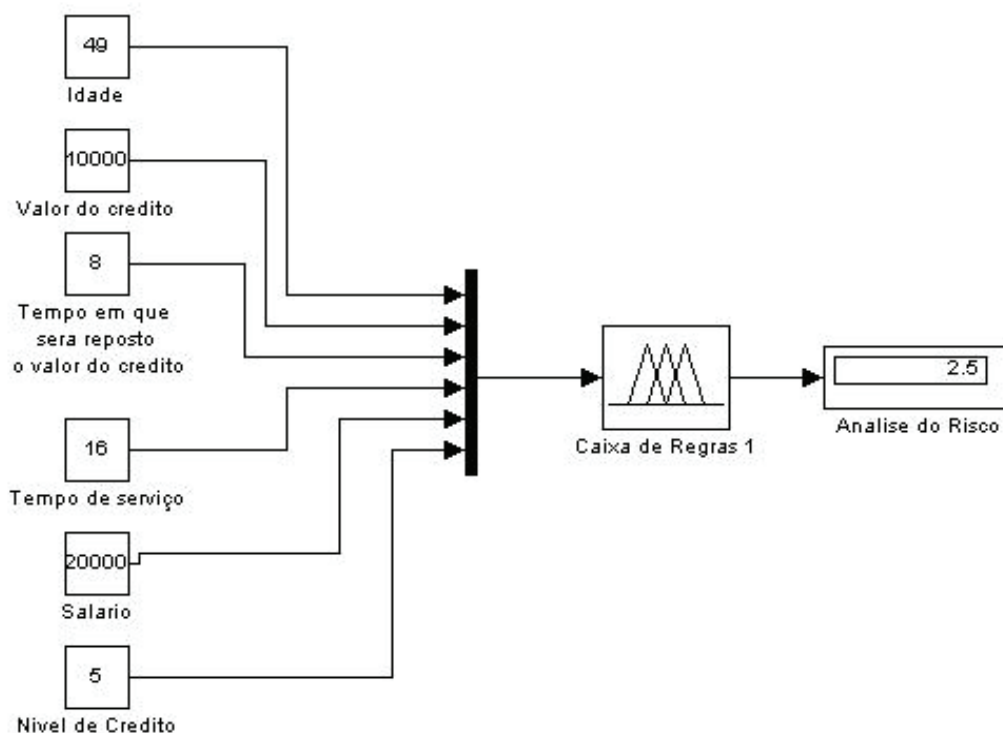
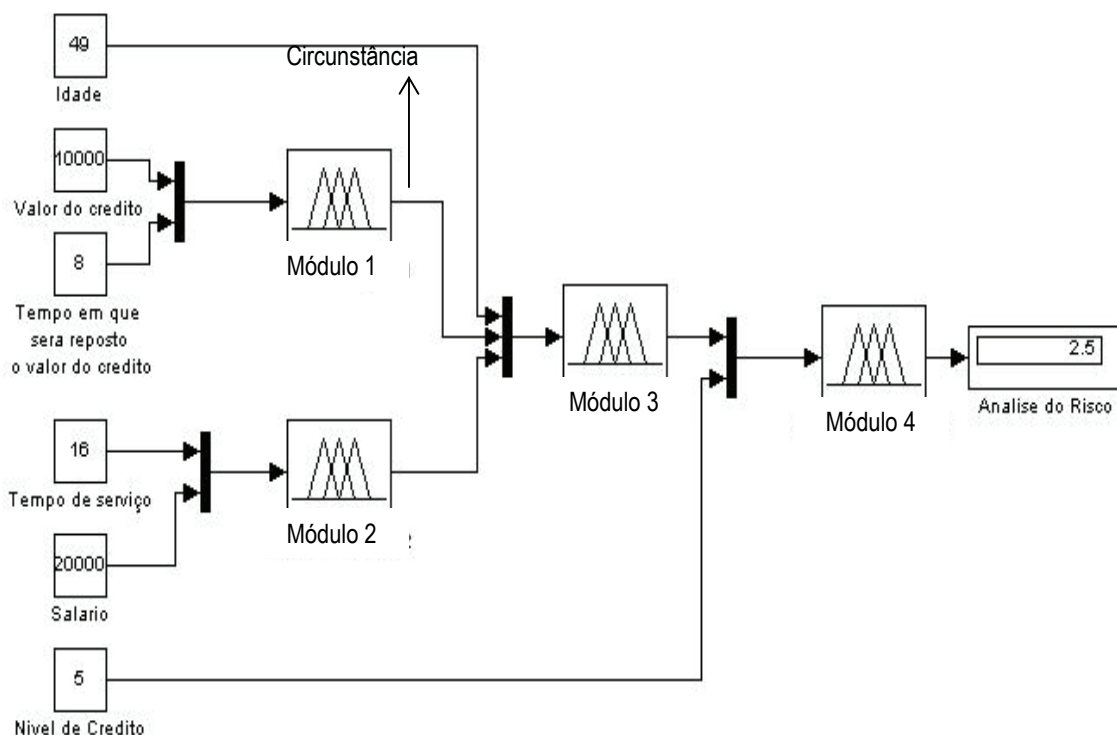


Figura 2.1: Modelo *fuzzy* convencional

### 2.2.2 Modelo *fuzzy* hierárquico

Com o intuito de diminuir o número de regras e atribuir níveis de importância às variáveis de entrada, quebrou-se a estrutura do sistema *fuzzy* convencional de crédito em quatro módulos fuzzy nos quais se têm no máximo três variáveis de entrada e uma de saída. Esta estratégia torna muito mais fácil o trabalho dos especialistas em crédito e *fuzzy*, pois atribui graus de importância às variáveis de entrada e diminui o número de regras do modelo.

A Figura 2.2 apresenta o modelo *fuzzy* de risco de crédito com processamento em estágios inteligentes que permite que o mesmo seja dividido em quatro blocos posicionados de acordo com o grau de importância das entradas.



**Figura 2.2:** Modelo *fuzzy* hierárquico

A variável circunstância surge da interação entre a variável valor do crédito e a variável tempo para quitar o crédito. Para o sistema de risco de crédito, a variável circunstância possui o mesmo nível de importância que a variável idade.

### 2.3.4 Sistema de inferência *fuzzy*

As informações chegam à entrada do modelo na forma de números *crisp*, ou seja, não *fuzzy*, e devem passar por um processo de fuzzificação. Em seguida elas são tratadas por um sistema de inferência *fuzzy* ilustrado pela Figura 2.3, sendo obtido um valor de saída *fuzzy*, que passará por um processo de defuzzificação, para se obter informações compreensíveis e precisas.

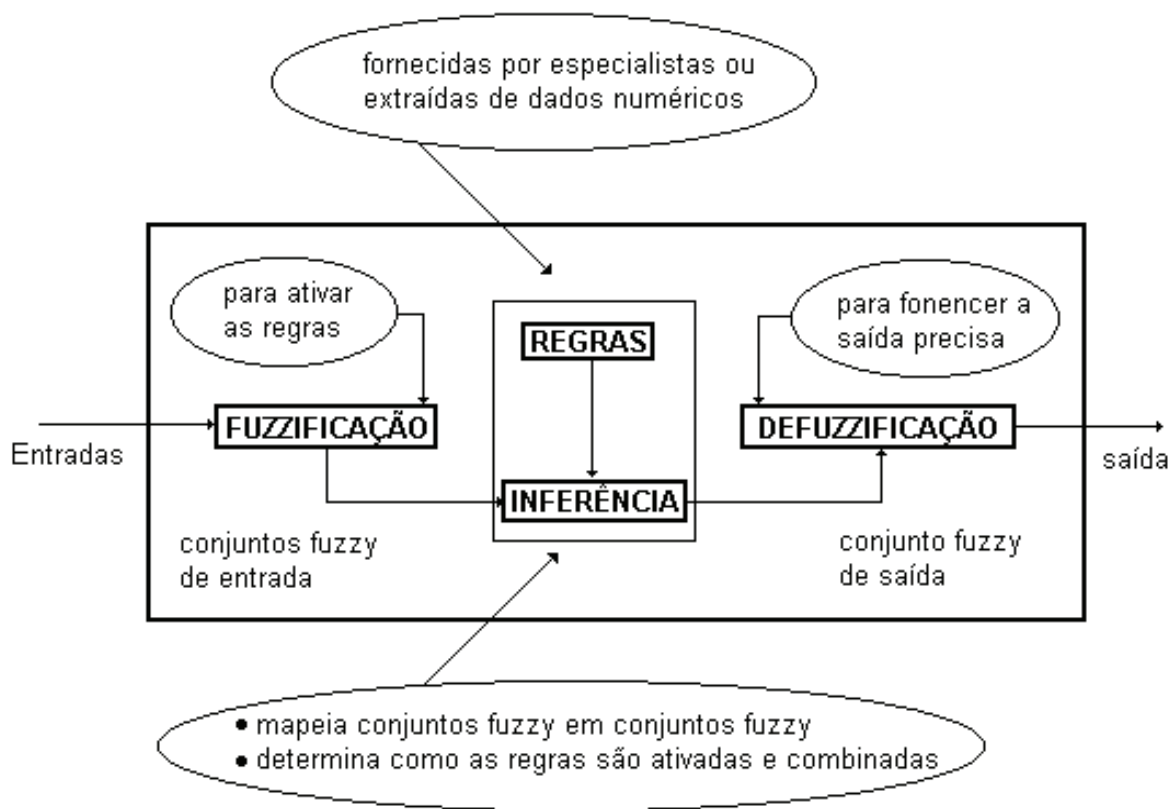


Figura 2.3: Sistema de inferência *fuzzy*

Existem vários métodos de defuzzificação. Neste modelo foi utilizado o método padrão centro de área, o qual calcula aproximadamente o centro de gravidade do conjunto *fuzzy* resultante na saída do sistema de inferência.

As regras foram sugeridas por dois especialistas no assunto, mas também podem ser extraídas de dados numéricos, como por exemplo, via redes neurais artificiais. Cada um dos quatro módulos do sistema *fuzzy* de risco de crédito tem como um número de regras que funcionam de acordo com o operador de implicação da seguinte forma: **Se** “A”, **então** “B”. Como exemplo, a Tabela 2.1 apresenta as regras utilizadas no módulo 4 da Figura 2.2.

Tabela 2.1: Regras utilizadas no bloco 4 da Figura 2.2

Se		Então
Tomador de crédito	Risco de crédito	Rating de Risco
Muito insatisfatório	Muito alto	Muito alto
Muito insatisfatório	Alto	Muito alto
Insatisfatório	Médio	Muito alto
Mediano	Médio	Alto
Satisfatório	Baixo	Baixo
Muito satisfatório	Muito baixo	Muito baixo

Fonte: Elaboração própria

Os ajustes internos do modelo são realizados de acordo com o Manual da *Toolbox Fuzzy* do Matlab 14.0.

### 3. Resultados

Para apresentar o sistema *fuzzy* como uma ferramenta inteligente para a análise e concessão de crédito, foi coletada uma amostra de operações de crédito. A Tabela 3.1 apresenta quinze fichas cadastrais com propostas de limites de crédito. Os pressupostos são: não se trata de operação inicial com o cliente, pois todos já possuem *rating* e um histórico de relacionamento; e as operações não têm garantia, portanto o modelo não se aplicaria a financiamento de bens.

O modelo foi aplicado para uma amostra de operações de crédito a pessoas físicas, porém poderia facilmente ser adaptado para micro e pequenas empresas, com a adoção de variáveis como volume de faturamento, grau de endividamento e retorno sobre o patrimônio líquido. A utilização do sistema *fuzzy* poderia, portanto, abranger todo o segmento de pequenas empresas, além do crédito pessoal.

**Tabela 3.1:** Características das operações de crédito

Pro-posta	Id.	Profissão / Atividade	Tempo de Serviço	Renda em R\$	Patrimônio em R\$	Rating	Limite Em R\$	Parcelas
1	37	Médico	12 anos	4.500	300.000	A	10.000	36
2	32	Professor	5 anos	1.200	50.000	C	3.000	12
3	48	Motorista de taxi	12 anos	900	50.000	A	2.000	12
4	37	Marceneiro autônomo	20 anos	3.500	70.000	B	8.000	12
5	35	Contabilista	3 anos	1.000	50.000	C	3.000	18
6	40	Funcionário Público	12 anos	4.000	70.000	AA	10.000	36
7	26	Técnico de informática	6 meses	1.000	3.000	B	2.000	12
8	33	Construtor autônomo	5 anos	800	40.000	AA	2.000	24
9	29	Bancário	1 ano	700	14.000	A	1.000	12
10	27	Op. de Telemarketing	6 meses	500	5.000	C	1.000	18
11	24	Vendedor industrial	6 meses	1.500	3.000	A	2.000	36
12	25	Garçom	2 anos	500	10.000	B	1.000	12
13	27	Comerciário	2 anos	1.700	10.000	B	4.000	18
14	25	Funcionário Público	1 ano	3.000	33.000	C	6.000	12
15	22	Comerciário	6 meses	1.400	3.000	B	3.000	24

Fonte: elaboração própria

Considerando a descrição dos conceitos de *rating* apresentados na Tabela 3.2, dois especialistas foram convidados a atribuir pontuação que refletisse o grau de risco de crédito de cada caso, considerando tratar-se de operações de crédito sem garantia real e com amortização parcelada.

Os especialistas 1 e 2, considerando que os *ratings* haviam sido atribuídos em função da experiência anterior desses clientes com a instituição, de acordo com a escala apresentada na Tabela 3.2, atribuíram a pontuação apresentada na Tabela 3.3. Os conceitos adotados na avaliação dos especialistas 1 e 2 variam entre 0, o melhor e 5, o pior, por critérios de julgamento pessoal, que contém forte grau de subjetividade, mas embutem a larga experiência acumulada sobre o assunto. Deve-se considerar que esse sistema especialista resulta ser muito dispendioso para a análise de um grande numero de propostas, de baixo valor unitário, com características de risco muito parecidas.



**Tabela 3.2:** Descrição dos conceitos de *rating*

Rating (*)	Conceito
AA	Boa experiência anterior e sem restrições cadastrais
A	Boa experiência anterior e poucas restrições cadastrais, já esclarecidas
B	Existência de restrições cadastrais a regularizar, porém boa experiência anterior
C	Existência de restrições cadastrais a regularizar e experiência anterior não satisfatória
D a H	Registro de atrasos e renegociações nas liquidações das operações anteriores

(\*) Conforme classificação adotada pela Resolução 2682, de 21/12/99 do Banco Central do Brasil

Fonte : Elaboração própria.

Para esse tipo de crédito pulverizado têm sido utilizados os sistemas de *credit scoring*. Para exemplificar o uso de um desses sistemas, os mesmos casos observados pelos especialistas foram submetidos a um sistema de pontuação mais quantitativo, que reduz significativamente o peso da subjetividade no julgamento. Adotou-se o sistema de pontuação para pessoa física apresentado por Securato (2002 : 44) [10]. Para a ponderação, esse sistema não considera as características da operação proposta – volume e número de parcelas, restringindo-se às características do proponente.

A ponderação obtida foi, posteriormente, aplicada à renda líquida do cliente, para determinar o valor máximo da prestação a ser aprovada. Esse sistema também não considera o *rating* do proponente, o que possibilita sua utilização para operações iniciais com os clientes, quando ainda não estão formados um histórico de relacionamento e um conceito de operações anteriores. Utilizou-se então o *rating* disponível nas fichas cadastrais analisadas, como *proxy* para o quesito conceito, que tem peso 30%.

Os resultados apontados pelos dois especialistas e os obtidos pelos modelos *fuzzy* e de *credit scoring* estão apresentados na tabela 3.3.

**Tabela 3.3:** Pontuação de crédito atribuída pelos especialistas, sistemas *fuzzy* e *credit scoring*

Proponente	Especialista 1 0, o melhor e 5, o pior	Especialista 2 0, o melhor e 5, o pior	Fuzzy		Credit Scoring (*) 50%, o melhor e 10%, o pior
			Seqüencial	Estágios	
1	1,0	1,0	1,1	1,1	41%
2	4,3	4,0	4,1	4,0	22%
3	1,5	1,0	1,2	1,2	28%
4	2,0	2,5	2,3	2,2	30%
5	4,5	4,0	4,2	4,3	20%
6	0,8	0,5	0,6	0,5	39%
7	2,5	3,0	2,7	2,8	17%
8	0,5	0,5	0,5	0,6	29%
9	1,2	1,5	1,4	1,3	20%
10	4,0	4,5	4,3	4,3	11%
11	1,5	2,0	1,8	1,9	23%
12	2,0	3,0	2,3	2,4	15%
13	2,5	3,0	2,7	2,8	18%
14	3,8	4,5	4,0	4,0	20%
15	2,5	3,5	3,1	3,0	17%

(\*) refere-se ao percentual da renda líquida que poderia ficar comprometido com a parcela do empréstimo.

Fonte: Elaboração própria.

Observa-se que o modelo *fuzzy* apresenta resultados próximos aos atribuídos pelos especialistas.

Os especialistas e os modelos analisados atribuem os riscos de crédito e, a partir da definição de um ponto de corte, decidem entre aprovação ou não aprovação da operação de crédito. Se, por exemplo, fosse adotado o ponto de corte na pontuação 3,7, as operações números 2, 5, 10 e 14 seriam recusadas pelos especialistas e pelo modelo *fuzzy*. Se esse ponto de corte fosse alterado para 4,1, o especialista 1 recusaria as operações 2 e 5, e o especialista 2 recusaria as operações 10 e 14, o que indica a diferença nos parâmetros adotados para a aprovação, que é resultante do elevado grau de subjetividade desse sistema. Essa elevação no ponto de corte pode ocorrer em função da perspectiva de um cenário de maior restrição ao crédito ou de elevação de taxas de juros na economia.

A aplicação do modelo de *credit scoring* apresentado em Securato (2002: 44) [10] resulta em ponderação de 10% (pior) a 50% (melhor). No sistema, os valores encontrados são os percentuais da renda que podem ser comprometidos com o pagamento das parcelas – prestação máxima. Portanto, o sistema proposto acaba determinando o valor do limite de crédito a ser concedido. Foram consideradas então as quinze propostas em questão, e a partir do comprometimento de renda indicado pelo sistema foram estimados os valores das parcelas em dois cenários: com taxas de juros de 5% ao mês e com taxas de juros de 2% ao mês, uniformes para todo o período das operações. Verificou-se que para taxas de juros de 5% ao mês, as propostas 2, 5, 7, 10, 12, 13 e 14 deveriam ser recusadas. Se as taxas de juros fossem de 2% ao mês, as propostas 2, 7, 10 e 12 deveriam ser recusadas.

Os dois modelos *fuzzy* apresentaram valores próximos, com variações aceitáveis entre os resultados deles e os dos especialistas. Entretanto, o ajuste do modelo *fuzzy* com processamento seqüencial demandou mais tempo. À medida que o número de entradas aumenta, a quantidade de regras e a dificuldade para ajustar o modelo seqüencial aumentam criticamente de forma exponencial.

A Tabela 3.4 apresenta o resumo das avaliações de crédito atribuídas pelos especialistas, os modelos *fuzzy* e de *credit scoring*.

**Tabela 3.4:** Resumo das avaliações de crédito atribuídas por: especialistas, sistema *fuzzy* e *credit scoring*.

	Especialistas	Sistema <i>fuzzy</i>	<i>Credit Scoring</i>	
	Ponto de Corte = 3,7	Ponto de Corte = 3,7	Taxas de juros de 5% ao mês	Taxas de juros de 2% ao mês
Propostas não Aprovadas	2, 5, 10 e 14	2, 5, 10 e 14	2, 5, 7, 10, 12, 13 e 14	2, 7, 10 e 12

Fonte: elaboração própria.

Os resultados dos modelos *fuzzy* são iguais aos dos especialistas em crédito, entretanto dependem da qualidade das informações que estes especialistas passam para o especialista em *fuzzy*. Assim, quanto melhor for a qualidade destas informações, melhor a capacidade de análise do modelo.

#### 4. Conclusões e pesquisas futuras

O modelo *fuzzy* hierárquico com processamento em estágios inteligentes demonstrou ser capaz de reproduzir as características especificadas pelos especialistas em avaliação de risco de crédito. Este tipo de modelo possibilitou atribuir graus de importância às entradas e tornou o ajuste do modelo mais intuitivo e rápido. Entretanto, depende da qualidade da *expertise* dos especialistas.

Este sistema pode fazer a avaliação de crédito de forma automática de acordo com a política de crédito da empresa, ser interligado de forma multiusuário, com controle centralizado, permitindo maior segurança e padronização. Além disso, pode facilitar o armazenamento de informações para estimar o risco de perdas e gerenciamento da carteira de crédito.

As pesquisas futuras serão direcionadas para desenvolver modelos inteligentes híbridos de avaliação de risco de crédito que incluem redes neurais, com capacidade de detectar fraudes, e lógica *fuzzy*, com capacidade de utilizar regras que expressam o conhecimento dos especialistas de crédito.

#### Bibliografia

- [1] Haykin, S. **Neural Networks – A Comprehensive Foundation**. Macmillan, New York. 1999.
- [2] ZADEH, L.A. **Outline of a new approach to the analysis of complex systems and decision processes**. IEEE Trans. Systems, Man & Cybernetics, vol. 3, pp. 28-44, 1973.
- [3] ZADEH, L. A. **Toward a generalized theory of uncertainty (GTU) - an outline**. **Information Sciences**. Elsevier, Vol. 172, 1-40, 2005.
- [4] Bäck, T., Fogel, D.B., Michalewicz, Z. (eds.). **Handbook of evolutionary computation**. 1997.
- [5] McCAHILL, L J. **Organizational issues in building and maintaining credit risk models**. In MAYS, E. (ed.). **Credit risk modeling: design and application**. Amacom, 1998.
- [6] CAOQUETTE, J B., ALTMAN, E I., NARAYANAN, P. **Managing credit risk: the next great financial challenge**. John Wiley & Sons Inc. 1998
- [7] SICSU, A L. **Desenvolvimento de um sistema de credit scoring**. Tecnologia de Crédito. São Paulo: Serasa. Parte I, pág. 63-76. Jan./1998a
- [8] SICSU, A L. **Desenvolvimento de um sistema de credit scoring**. Tecnologia de Crédito. São Paulo: Serasa. Parte II, pág. 57-68. Mar./1998b.
- [9] DAHAL, K., HUSSAIN, Z., HOSSAIN, M. A. **Loan Risk Analyzer based on Fuzzy Logic**. IEEE Computer Society, 2005.
- [10] SECURATO, J R (coord.). **Crédito: análise e avaliação do risco: pessoas físicas e jurídicas**. São Paulo: Saint Paul, 2002.
- [11] MENDEL, J.M. **Fuzzy logic systems for engineering: a tutorial**. Proceedings of the IEEE, vol. 83, no. 3, pp. 345-377, 1995.