

**UNIVERSIDADE FEDERAL DE ALFENAS**

**Bruno Vitorino Barbosa**

**DESENVOLVIMENTO DE UM SISTEMA BASEADO EM REGRAS *FUZZY* PARA  
CLASSIFICAÇÃO DE RISCO DE CRÉDITO**

**Varginha /MG**

**2025**

**BRUNO VITORINO BARBOSA**

**DESENVOLVIMENTO DE UM SISTEMA BASEADO EM REGRAS *FUZZY* PARA  
CLASSIFICAÇÃO DE RISCO DE CRÉDITO**

Trabalho de Conclusão de Curso apresentado  
como parte dos requisitos para obtenção do  
título de Bacharel em Ciências Atuariais pela  
Universidade Federal de Alfenas.

Orientador: Prof. Dr. Leandro Ferreira

**Varginha/MG**

**2025**

Sistema de Bibliotecas da Universidade Federal de Alfenas  
Biblioteca Campus Varginha

Barbosa, Bruno Vitorino.

Desenvolvimento de um sistema baseado em regras fuzzy para  
classificação de risco de crédito / Bruno Vitorino Barbosa. - Varginha, MG,  
2025.

36 f. : il. -

Orientador(a): Leandro Ferreira.

Trabalho de Conclusão de Curso (Graduação em Ciências Atuariais) -  
Universidade Federal de Alfenas, Varginha, MG, 2025.

Bibliografia.

1. Lógica fuzzy. 2. Crédito. 3. Tomada de decisão. I. Ferreira, Leandro,  
orient. II. Título.

**BRUNO VITORINO BARBOSA**

**DESENVOLVIMENTO DE UM SISTEMA BASEADO EM REGRAS *FUZZY* PARA  
CLASSIFICAÇÃO DE RISCO DE CRÉDITO**

O Presidente da banca examinadora abaixo assina a aprovação do Trabalho de Conclusão de Curso apresentado como parte dos requisitos para obtenção do título de Bacharel em Ciências Atuariais pela Universidade Federal de Alfenas.

Aprovada em: 02 de dezembro de 2025

Prof. Dr. Leandro Ferreira  
Universidade Federal de Alfenas

Assinatura:

Prof. Dr. Danilo Machado Pires  
Universidade Federal de Alfenas

Prof.<sup>a</sup> Dr.<sup>a</sup> Patrícia de Siqueira Ramos  
Universidade Federal de Alfenas

## **DEDICATÓRIA**

Dedico este trabalho à minha família, que sempre esteve comigo e me deu o suporte necessário para seguir em frente. Aos amigos que caminharam ao meu lado e torceram pelo meu progresso. Aos que já se foram, mas deixaram lembranças e ensinamentos que continuam presentes. E ao meu orientador, pelo apoio, paciência e contribuição fundamental para a construção deste trabalho.

## **AGRADECIMENTOS**

Agradeço ao meu professor e orientador Leandro que além de ser para mim um grande professor, nunca mediu esforços em me ajudar nessa caminhada, na realização deste trabalho, e se tornou um grande incentivador e amigo. A todos os outros professores da UNIFAL com os quais tive o prazer de conviver, que serão eternizados em minha memória, e espero fazer jus ao conhecimento adquirido.

Aos meus amigos que participaram dessa jornada.

A minha família está ao meu lado, em todos os momentos.

Enfim, agradeço a todas as pessoas que fizeram parte desta jornada da minha vida, com lembranças ao meu pai e minha avó, onde quer que estejam te amo, saudades.

“A longo prazo, todos estaremos mortos.”

(John Maynard Keynes)

## RESUMO

A análise de risco de crédito é um processo central para a sustentabilidade das instituições financeiras, exigindo métodos capazes de lidar com incertezas presentes no comportamento dos clientes e nas condições do mercado. Nesse contexto, modelos baseados em lógica *fuzzy* destacam-se pela capacidade de representar nuances qualitativas de forma estruturada. O objetivo deste trabalho é desenvolver e avaliar um sistema baseado em regras *fuzzy* (SBRF) para calcular o risco de crédito a partir de três variáveis amplamente utilizadas em modelos de *credit scoring*: score de crédito, renda mensal e índice de endividamento. O sistema utiliza funções de pertinência triangulares, inferência de Mamdani e defuzzificação pelo método do centro de gravidade, permitindo gerar uma classificação do risco. A aplicação do modelo a diferentes perfis de clientes demonstrou coerência com práticas de mercado e evidenciou a capacidade do SBRF de incorporar incertezas e subjetividades não capturadas plenamente por técnicas tradicionais. Os resultados confirmam que a lógica *fuzzy* é uma ferramenta flexível e eficaz para apoiar decisões de concessão de crédito, mostrando potencial para ampliação em cenários multicritério e processos mais abrangentes de gestão de risco.

**Palavras-chave:** lógica *fuzzy*; crédito; tomada de decisão.

## **ABSTRACT**

Credit risk assessment is a central process for the sustainability of financial institutions, requiring methods capable of dealing with uncertainties inherent in customer behavior and market conditions. In this context, fuzzy logic–based models stand out for their ability to represent qualitative nuances in a structured manner. The objective of this study is to develop and evaluate a Fuzzy Rule-Based System (FRBS) to estimate credit risk based on three variables widely used in credit scoring models: credit score, monthly income, and debt ratio. The system employs triangular membership functions, Mamdani inference, and defuzzification using the centroid method, allowing the generation of a continuous risk classification. The application of the model to different customer profiles demonstrated consistency with market practices and highlighted the FRBS’s ability to incorporate uncertainties and subjectivities not fully captured by traditional techniques. The results confirm that fuzzy logic is a flexible and effective tool to support credit-granting decisions, showing potential for expansion into multicriteria scenarios and broader risk management processes.

**Keywords:** fuzzy logic; credit; decision-making.

## LISTA DE FIGURAS

|   |    |
|---|----|
| Figura 1 – Módulos de um SBRF .....   | 19 |
| Figura 2 – Representação gráfica das funções de pertinência da variável “Score de crédito” .....        | 24 |
| Figura 3 – Representação gráfica das funções de pertinência da variável “Renda mensal” .....            | 25 |
| Figura 4 – Representação gráfica das funções de pertinência da variável “Índice de endividamento” ..... | 25 |
| Figura 5 – Representação gráfica das funções de pertinência da variável “Risco de crédito” .....        | 26 |
| Figura 6 – Cortes nos conjuntos <i>fuzzy</i> de saída moderado e baixo .....                            | 31 |
| Figura 7 – Conjunto <i>fuzzy</i> de saída .....   | 32 |

## LISTA DE TABELAS

|   |    |
|---|----|
| Tabela 1 – Conjuntos fuzzy das variáveis de entrada e saída.....      | 24 |
| Tabela 2 – Base de regras.....  | 27 |
| Tabela 3 – Conjuntos fuzzy ativados pelos valores de entrada.....     | 29 |
| Tabela 4 – Regras ativadas pelos valores de entrada.....              | 29 |
| Tabela 5 – Aplicação do operador mínimo.....                          | 31 |
| Tabela 6 – Resultados do SBRF para diferentes perfis de clientes..... | 33 |

## Sumário

|          |  |           |
|----------|--|-----------|
| <b>1</b> | <b>INTRODUÇÃO .....</b>                        | <b>12</b> |
| <b>2</b> | <b>REFERENCIAL TEÓRICO .....</b>               | <b>13</b> |
| 2.1      | RISCO DE CRÉDITO.....                          | 13        |
| 2.1.2    | Avaliação Do Risco De Crédito.....             | 14        |
| 2.2      | LÓGICA <i>FUZZY</i> .....                      | 16        |
| 2.2.1    | Sistemas baseados em regras <i>fuzzy</i> ..... | 18        |
| <b>3</b> | <b>METODOLOGIA.....</b>                        | <b>20</b> |
| 3.1      | VARIÁVEIS DE ESTUDO.....                       | 20        |
| 3.2      | CONJUNTOS <i>FUZZY</i> .....                   | 23        |
| 3.3      | BASE DE REGRAS .....                           | 26        |
| 3.4      | DEFUZZIFICAÇÃO.....                            | 27        |
| 3.5      | IMPLEMENTAÇÃO COMPUTACIONAL .....              | 28        |
| <b>4</b> | <b>RESULTADOS E DISCUSSÃO .....</b>            | <b>28</b> |
| <b>5</b> | <b>CONSIDERAÇÕES FINAIS .....</b>              | <b>34</b> |
|          | <b>REFERÊNCIAS.....</b>                        | <b>35</b> |

## 1 INTRODUÇÃO

A concessão de crédito é uma das atividades fundamentais do sistema financeiro moderno, atuando como um pilar para o fomento do consumo, o financiamento de investimentos e o crescimento da economia. Para as instituições financeiras, a análise de crédito representa um processo crítico de tomada de decisão, no qual é preciso equilibrar a oportunidade de negócio com o risco inerente de inadimplência. Uma avaliação de risco imprecisa pode acarretar perdas financeiras significativas, comprometendo a saúde da instituição e, em escala, a estabilidade do mercado.

Diante desse cenário, a busca por métodos cada vez mais acurados e eficientes para calcular o risco de crédito tornou-se uma prioridade estratégica. Tradicionalmente, essa análise baseava-se em modelos estatísticos e na avaliação humana de especialistas. Contudo, com o avanço da tecnologia e o advento da era da *big data*, a inteligência artificial e a ciência de dados emergiram como ferramentas poderosas, capazes de identificar padrões complexos e não-lineares em grandes volumes de dados, que muitas vezes não são perceptíveis por abordagens convencionais.

Dentro deste universo computacional, a lógica *fuzzy* se destaca como uma abordagem particularmente adequada para a análise de risco de crédito. Diferente da lógica clássica, que opera com valores estritamente binários (verdadeiro/falso, 0/1), a lógica *fuzzy* é projetada para lidar com a incerteza e a imprecisão inerentes ao raciocínio humano. Ela permite modelar matematicamente termos linguísticos e conceitos vagos, como um risco "alto" ou um histórico de pagamento "bom", por meio de graus de pertinência. Essa característica é fundamental, pois a avaliação de crédito raramente se baseia em critérios absolutos, mas sim em transições graduais e julgamentos qualitativos que os modelos tradicionais têm dificuldade em capturar.

É precisamente para explorar essa capacidade de modelar a imprecisão da análise de risco que o presente trabalho se propõe a investigar a aplicação de um sistema *fuzzy*. O objetivo principal é apresentar a implementação de um sistema baseado em regras *fuzzy* para realizar a análise do risco de crédito.

A justificativa para a realização deste trabalho reside na relevância acadêmica e prática de se desenvolver e compreender ferramentas mais sofisticadas para a gestão de risco, um tema central para a economia global.

Para alcançar o objetivo proposto, este trabalho foi estruturado em cinco capítulos. O Capítulo 2 apresenta o referencial teórico, abordando os conceitos de risco de crédito. O Capítulo 3 apresenta a lógica *fuzzy* e os sistemas baseados em regras *fuzzy*. O Capítulo 4 expõe e discute os resultados obtidos. Por fim, o Capítulo 5 apresenta as considerações finais, as limitações do estudo e sugestões para trabalhos futuros.

## 2 REFERENCIAL TEÓRICO

### 2.1 RISCO DE CRÉDITO

A definição de crédito no contexto financeiro refere-se essencialmente à confiança de uma instituição financeira ou de um credor em emprestar dinheiro a uma pessoa ou empresa, sob a promessa de que o valor será pago futuramente, geralmente com juros. Esse conceito é fundamental para o funcionamento de economias modernas, onde indivíduos, empresas e governos frequentemente precisam de acesso a recursos além dos que possuem imediatamente. Como o crédito envolve a expectativa de retorno dos recursos emprestados, toda operação desse tipo contém um grau de risco, entendido como a possibilidade de o retorno não ocorrer de forma integral (Schrickel, 1995). Assim, o risco de crédito está presente em qualquer concessão, sendo parte integrante da rotina das instituições financeiras (Camargos et Al., 2010). Para Brito e Assaf Neto (2008), esse risco corresponde à probabilidade de o tomador não honrar suas obrigações conforme pactuado. De modo semelhante, Camargos et al. (2010) definem o risco de crédito como a possibilidade de o tomador não cumprir as expectativas do credor quanto ao retorno acordado, caracterizando-o como inadimplente.

Os modelos de análise para concessão de crédito, conhecidos como *credit scoring*<sup>1</sup>, utilizam dados históricos de clientes para prever se novos solicitantes têm maior ou menor probabilidade de cumprir suas obrigações financeiras. Avaliar

---

<sup>1</sup> De acordo com JusBrasil (2024) no *credit scoring*, a pessoa que está pedindo o crédito é avaliada por meio de fórmulas matemáticas, nas quais são consideradas diversas variáveis como a idade, a profissão, a finalidade da obtenção do crédito etc. Tais variáveis são utilizadas nas fórmulas matemáticas e, por meio de ferramentas da estatística, atribui-se uma espécie de pontuação (nota) para a pessoa que está pedindo o crédito.

corretamente o perfil de crédito dos clientes é crucial para evitar prejuízos financeiros. Uma classificação incorreta, ao identificar um mau pagador como bom ou vice-versa, pode resultar tanto em perdas quanto em perda de oportunidades de ganho para a instituição.

Para Gomes (2010), a precisão dos modelos de *credit scoring* é limitada, mas avanços nas técnicas de modelagem, como o uso de dados mais completos e métodos estatísticos avançados, são fundamentais para aumentar a precisão das previsões e reduzir os riscos associados. Existe um interesse das instituições financeiras em aprimorar esses modelos, que reflete a busca constante por ferramentas analíticas mais eficazes, capazes de maximizar a rentabilidade e segurança nas operações de crédito. Comparar diferentes modelos de score de crédito é, portanto, uma prática estratégica para identificar aqueles que oferecem maior precisão e confiabilidade no contexto da concessão de crédito.

De acordo com Addo et al. (2018), o uso de modelos de aprendizado de máquina para prever risco de crédito tem ganhado destaque, uma vez que essas técnicas conseguem lidar com grandes volumes de dados e detectar padrões não lineares. Além disso, o advento de redes neurais artificiais tem proporcionado avanços significativos na precisão das previsões de crédito, embora desafios como a explicabilidade dos modelos permaneçam uma questão central.

### 2.1.2 Avaliação Do Risco De Crédito

A classificação de risco de crédito envolve uma análise de múltiplos fatores financeiros e não financeiros que podem impactar a capacidade e a disposição de um cliente para honrar suas obrigações financeiras. Esse processo é fundamental para as instituições financeiras, pois possibilita a tomada de decisões mais seguras e informadas na concessão de crédito e na precificação de produtos financeiros. Os critérios utilizados são variados e geralmente personalizados conforme o tipo de cliente (por exemplo, pessoa física ou jurídica) e o tipo de crédito. Os indicadores financeiros são frequentemente o ponto de partida na análise de risco de crédito. Esses indicadores fornecem uma visão objetiva e quantitativa da saúde financeira do cliente.

De acordo com Banco Central do Brasil (2023), a avaliação de risco de crédito é um processo que envolve vários critérios financeiros e não financeiros, para

classificar clientes de acordo com o nível de risco que representam para as instituições financeiras. Esse processo é essencial, especialmente em um cenário econômico marcado por oscilações e pela vulnerabilidade de crédito de alguns segmentos populacionais.

Os indicadores financeiros são frequentemente o ponto de partida na análise de risco de crédito. Esses indicadores, como afirma o Banco Central do Brasil (2023), fornecem uma visão objetiva e quantitativa da saúde financeira do cliente. Entre os principais critérios estão: renda e fluxo de caixa; histórico de crédito; razão de endividamento; emprego e estabilidade profissional e; perfil demográfico e geográfico.

A avaliação de risco de crédito tem sido historicamente baseada em modelos estatísticos tradicionais, como regressão linear, regressão logística e análise discriminante. Ambos os modelos enfrentam desafios, como a limitação imposta pela suposição de linearidade entre as variáveis preditoras e a resposta, o que pode restringir sua precisão e aplicabilidade em cenários de dados mais complexos ou não lineares.

O desenvolvimento e a melhoria de modelos mais sofisticados, como modelos baseados no aprendizado de máquina, exigem investimentos em infraestrutura e alterações profissionais, o que pode representar um obstáculo para pequenas instituições financeiras. Em resumo, enquanto os modelos tradicionais ainda desempenham um papel importante na análise de risco de crédito no Brasil, os modelos baseados em aprendizado de máquina, como redes neurais artificiais, estão sendo progressivamente adotados para enfrentar as limitações dos modelos convencionais e atualizar a previsão de inadimplimento. Com a evolução das tecnologias e o aumento da disponibilidade de dados, espera-se que os modelos de risco de crédito continuem a evoluir, tornando-se cada vez mais precisos e adaptados às especificações. Nos últimos anos, os modelos baseados em aprendizagem de máquina têm ganhado destaque na análise de risco de crédito no Brasil.

Gouvêa, Gonçalves e Mantovani (2013) analisaram o risco de crédito por meio da aplicação e comparação entre regressão logística e redes neurais, utilizando dados de uma grande instituição financeira brasileira. Os autores verificaram que ambos os modelos apresentaram desempenho satisfatório para distinguir bons e maus pagadores, podendo apoiar decisões de concessão de

crédito.

A lógica *fuzzy* tem se destacado como uma ferramenta útil na análise de risco de crédito por permitir tratar a incerteza e a imprecisão inerentes ao comportamento dos tomadores de decisão (Syau; Hsieh; Lee, 2001; Freitas; Tavares; Montini, 2008). Diferentemente dos modelos tradicionais, que exigem fronteiras rígidas entre classes e variáveis, a abordagem *fuzzy* admite graus de pertencimento, possibilitando representar nuances e interpretações mais próximas do raciocínio humano. Dessa forma, características como perfil financeiro, histórico de pagamentos e condições cadastrais podem ser avaliadas de maneira mais flexível, permitindo que a decisão de crédito incorpore informações qualitativas e quantitativas de forma integrada. Isso torna a lógica *fuzzy* especialmente adequada para ambientes em que o risco não pode ser perfeitamente capturado por modelos puramente estatísticos.

A adoção de modelos de risco de crédito no Brasil enfrenta desafios, incluindo a necessidade de dados de qualidade e a conformidade com regulamentações, como a Lei Geral de Proteção de Dados (LGPD), que regula o uso de dados pessoais e impõe limites sobre as informações que podem ser utilizados (Ferreira, 2020). Com o avanço da tecnologia, algumas instituições financeiras passaram a considerar também o comportamento online do cliente, incluindo interações em redes sociais e atividades digitais. Embora o uso desses dados seja um tema controverso e regulado pela LGPD, esse tipo de análise pode fornecer insights adicionais sobre o perfil do cliente e seu comportamento de consumo.

## 2.2 LÓGICA FUZZY

A lógica *fuzzy*, desenvolvida por Lotfi Zadeh em 1965, trata de informações imprecisas por meio da teoria dos conjuntos *fuzzy*. Diferentemente da lógica clássica tradicional, a lógica *fuzzy* permite que as variáveis assumam graus de pertinência a um determinado conjunto, com valores variando entre 0 e 1. Dessa forma, a teoria dos conjuntos *fuzzy* possibilita o tratamento matemático de termos linguísticos associados a variáveis, como “muito baixo”, “aproximadamente” ou “em torno de”.

A lógica *fuzzy* é uma abordagem que lida com a incerteza e a ambiguidade, possibilitando a modelagem de sistemas em que as fronteiras entre categorias — como bom e mau pagador — não são rigidamente definidas. No contexto da avaliação de risco de crédito, sistemas baseados em lógica *fuzzy* permitem

incorporar o conhecimento especializado de forma flexível e intuitiva, por meio de regras capazes de representar as nuances do comportamento dos clientes.

Segundo Zimmermann (2010), desde sua criação em 1965, a teoria dos conjuntos *fuzzy* tem evoluído continuamente, ampliando seu campo de aplicação em diversas áreas do conhecimento. Essa teoria tem sido utilizada em domínios como inteligência artificial, ciência da computação, medicina, engenharia de controle, apoio à tomada de decisão, sistemas especialistas, lógica, administração, pesquisa operacional, reconhecimento de padrões e robótica etc.

Os conjuntos *fuzzy* permitem modelar a imprecisão presente em variáveis relevantes para a análise de risco de crédito, como renda, valor do empréstimo, tempo de serviço, risco e histórico de crédito. Esses conjuntos podem ser representados por diferentes tipos de funções de pertinência, sendo as formas triangular e trapezoidal as mais utilizadas devido à sua simplicidade e eficiência computacional (Barros; Bassanezi, 2015).

A função de pertinência triangular é uma das formas mais simples e amplamente utilizadas para representar conjuntos *fuzzy*. Ela descreve o grau de pertencimento de um elemento  $x$  a um conjunto *fuzzy*  $A$  por meio de uma função, definida pelos parâmetros  $a$ ,  $u$  e  $b$ , onde a base do triângulo é o intervalo  $[a, b]$  e, como único vértice fora desta base, o ponto  $(u, 1)$ , sendo  $u$  o valor de  $x$  que admite pertinência máxima ( $\mu_A(u) = 1$ ) ao conjunto *fuzzy*  $A$ . Matematicamente, a função de pertinência triangular  $\mu_A(x)$  é expressa como:

$$\mu_A(x) = \begin{cases} 0, & \text{se } x \leq a \\ \frac{x-a}{u-a}, & \text{se } a < x \leq u \\ \frac{b-x}{b-u}, & \text{se } u < x < b \\ 0, & \text{se } x \geq b \end{cases} \quad (1)$$

As funções triangulares permitem transições suaves entre categorias linguísticas e são facilmente parametrizáveis por especialistas (Zadeh, 1965).

### 2.2.1 Sistemas baseados em regras *fuzzy*

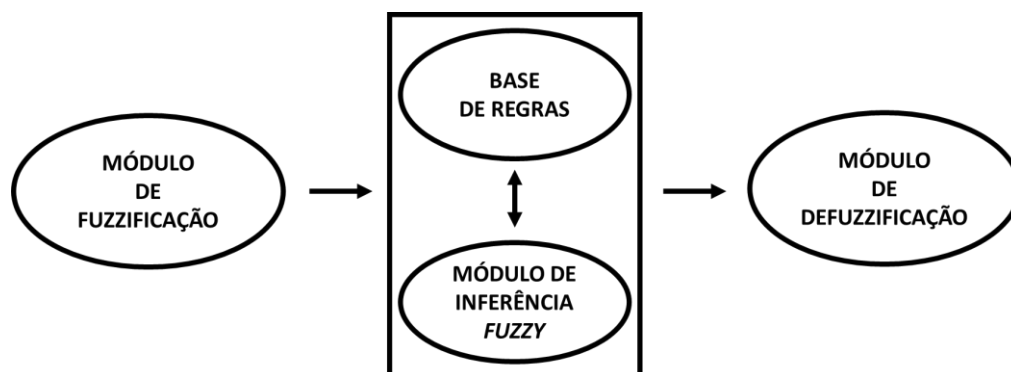
Os sistemas baseados em regras *fuzzy* (SBRF), ou sistemas de inferência *fuzzy*, constituem uma das principais aplicações da teoria dos conjuntos *fuzzy*. Esses sistemas permitem representar e manipular conhecimento impreciso ou incerto por meio de regras linguísticas, aproximando o raciocínio computacional da forma como os seres humanos tomam decisões em situações ambíguas.

Os SBRFs têm sido amplamente empregados em diversas áreas, como controle de processos, diagnóstico médico, previsão de demanda, avaliação de risco e apoio à tomada de decisão multicritério. Sua principal vantagem está na capacidade de integrar conhecimento especializado e raciocínio aproximado, proporcionando soluções flexíveis, robustas e interpretáveis para problemas complexos, incertos ou mal definidos.

Em um sistema *fuzzy*, o comportamento do modelo é definido por um conjunto de regras do tipo “Se... então...” que relacionam variáveis de entrada e saída. Por exemplo: “Se a renda é alta e o histórico de crédito é bom, então o risco é baixo”. Cada variável é representada por conjuntos *fuzzy* e suas respectivas funções de pertinência, que permitem traduzir valores numéricos em termos linguísticos, como “baixo”, “médio” ou “alto”. O mecanismo de inferência *fuzzy* combina essas regras e determina o grau de ativação de cada uma delas, produzindo uma saída também *fuzzy*, que posteriormente pode ser convertida em um valor numérico por meio de um processo de defuzzificação.

De acordo com Barros & Bassanezi (2015), um SBRF é composto, essencialmente, por quatro módulos interligados: fuzzificação, base de regras, inferência *fuzzy* e defuzzificação (Figura 1). Cada módulo desempenha um papel específico no processo de transformação de informações numéricas em decisões baseadas em conhecimento linguístico.

Figura 1 – Módulos de um SBRF



Fonte: Elaborado pelo autor, 2025.

1. Fuzzificação: é a etapa em que os valores numéricos das variáveis de entrada são convertidos em graus de pertinência a conjuntos *fuzzy*. Em outras palavras, esse módulo transforma dados quantitativos (como renda, tempo de serviço ou valor de crédito) em descrições qualitativas (como “baixo”, “médio” ou “alto”). Para isso, utilizam-se funções de pertinência, geralmente de formato triangular, trapezoidal, gaussiano, entre outros. O resultado é uma representação *fuzzy* das entradas, adequada ao raciocínio aproximado que caracteriza o sistema.

2. Base de regras: contém o conhecimento especializado do sistema, expresso por meio de proposições linguísticas do tipo “Se... então...”. Por exemplo: “Se a renda é alta e o histórico de crédito é bom, então o risco é baixo”. Cada regra reflete uma relação entre variáveis de entrada e saída, construída a partir da experiência de especialistas ou de análises empíricas dos dados. Essa base forma o núcleo do raciocínio *fuzzy*, pois define como as diferentes condições são combinadas para gerar conclusões.

3. Inferência *fuzzy*: realiza o processamento das regras, determinando o grau de ativação de cada uma delas de acordo com as entradas *fuzzy*. Nessa etapa, aplicam-se operadores lógicos (como “e”, “ou”, “não”), que combinam os graus de pertinência das variáveis para calcular a saída correspondente de cada regra. O resultado é um conjunto *fuzzy* que representa, de forma agregada, a resposta do sistema. Os métodos de inferência mais utilizados são os de Mamdani e Sugeno, que diferem na forma de representar e calcular as saídas.

4. Defuzzificação: é o processo final, no qual o conjunto *fuzzy* de saída obtido na inferência é convertido em um valor numérico. Essa etapa é necessária para que o sistema produza uma saída interpretável e aplicável em contextos reais, como uma classificação de risco, uma taxa de juros ou uma decisão de controle. Entre os métodos de defuzzificação mais comuns estão o centro de gravidade (centroide ou centro de área), a média dos máximos e o centro dos máximos.

### 3 METODOLOGIA

#### 3.1 VARIÁVEIS DE ESTUDO

Propôs-se a construção de um sistema baseado em regras *fuzzy* (SBRF) para a análise do risco de crédito — variável de saída do sistema — a partir das seguintes variáveis de entrada: score de crédito, renda mensal e índice de endividamento.

A seleção das variáveis utilizadas neste estudo segue diretamente as orientações dos principais órgãos reguladores do sistema financeiro brasileiro e de estudos acadêmicos nacionais sobre risco de crédito. Essas variáveis representam os três pilares centrais utilizados, de forma padronizada, por instituições financeiras na avaliação da capacidade e da propensão de pagamento dos clientes.

O score de crédito foi adotado por ser um dos indicadores mais relevantes no processo de concessão de crédito no Brasil. A Lei nº 12.414/2011, conhecida como Lei do Cadastro Positivo, determina que o histórico de adimplência do consumidor deve compor bancos de dados utilizados na construção de modelos de *credit scoring*, reforçando a legitimidade e importância desse indicador (Brasil, 2011). De forma complementar, a Serasa Experian, um dos principais birôs de crédito do país, afirma que o score sintetiza padrões estatísticos de comportamento financeiro e constitui uma ferramenta essencial para estimar a probabilidade de inadimplência de novos solicitantes (Serasa, 2025). O score de crédito é um indicador estatístico cada vez mais utilizado por instituições financeiras para mensurar a probabilidade de inadimplência do cliente, permitindo decisões objetivas e rápidas na concessão de crédito. Ele reflete o histórico de pagamentos, dívidas em aberto e outros dados cadastrais, consolidando uma avaliação quantitativa de risco, conforme destaca o Banco Central do Brasil e a Serasa Experian. O Serasa Score, por exemplo,

promove maior precisão na análise e é citado em manuais, cartilhas e artigos de referência do setor porque auxilia a “apresentar um diagnóstico de reputação no mercado, indicando as ações necessárias para melhorá-la” e permite avaliação padronizada do risco, oferecendo “maior controle da vida financeira” tanto para consumidores quanto para instituições. Dessa forma, o score reúne informação histórica de forma objetiva e padronizada, justificando plenamente sua escolha como variável de entrada no sistema *fuzzy*.

A renda mensal é um dos critérios mais tradicionais e obrigatórios na avaliação de risco. O Banco Central do Brasil estabelece que a análise de crédito deve considerar a capacidade atual e futura de pagamento, o que inclui a verificação da renda e das condições econômico-financeiras do tomador (Banco Central Do Brasil, 2023). Documentos oficiais como o COSIF reforçam essa exigência ao afirmar que a classificação de risco deve refletir a situação financeira do cliente, incluindo sua capacidade de gerar recursos (Banco Central Do Brasil, 2025). A renda mensal é uma das variáveis mais críticas para avaliar a capacidade de pagamento do tomador de crédito, sendo considerada por normativos do Banco Central, pela Febraban e por publicações de pesquisa como ponto inicial da análise. De acordo com a resolução do Banco Central e o COSIF (Classificação das Operações de Crédito), a renda do cliente e seu fluxo de caixa disponível são fatores críticos na avaliação da capacidade de pagamento, servindo como base para estimar a sustentabilidade de novas dívidas e o risco associado à operação. No contexto brasileiro, estudos mostram que consumidores com renda comprometida excessivamente apresentam índices mais elevados de inadimplência, tornando essa variável indispensável e alinhada com as melhores práticas internacionais e nacionais. Em linha com isso, estudos nacionais sobre lógica *fuzzy* aplicada ao crédito também utilizam a renda como variável fundamental, já que ela representa a base da solvência do indivíduo e impacta diretamente sua capacidade de amortizar dívidas (Bueno, 2011; Freitas; Tavares; Montini, 2008).

O índice de endividamento complementa a análise ao indicar o quanto da renda do cliente já está comprometida com outras obrigações financeiras. O índice de endividamento mede o comprometimento da renda do consumidor (ou empresa) com despesas e dívidas já existentes, servindo para identificar situações de sobre-endividamento e risco elevado. Documentos da Febraban e pesquisas do Banco Central frisam que um comprometimento de renda acima de 50% é um dos

principais atributos para classificar clientes em situação de risco, sendo critério objetivo e recorrente em decisões de concessão ou recusa de crédito. Trabalhos acadêmicos e relatórios financeiros recentes reforçam que esse índice é fundamental para uma análise robusta, pois aponta se a empresa (ou indivíduo) é financiada por capitais de terceiros e indica a capacidade real de honrar obrigações futuras. A Febraban (2021) orienta que o comprometimento da renda é um dos principais indicadores de risco, pois níveis elevados aumentam a probabilidade de inadimplência e reduzem a margem disponível para assumir novas dívidas. Guias técnicos voltados à prática bancária consideram o endividamento um marcador essencial para mensurar o estresse financeiro do consumidor, sendo amplamente utilizado em análises operacionais de crédito em instituições brasileiras. Estudos acadêmicos recentes reforçam essa visão, mostrando que o endividamento é uma das variáveis com maior poder explicativo em modelos de classificação de risco no mercado nacional (Assis; Decoster, 2025).

A variável risco de crédito reflete uma síntese das informações anteriores e está alinhada às normas de classificação de risco previstas pelo Banco Central. O COSIF, que significa Plano Contábil das Instituições do Sistema Financeiro Nacional, é onde se encontra o conjunto de normas e procedimentos contábeis criado pelo Banco Central do Brasil que determina que cada operação deve receber uma classificação baseada no risco efetivo do tomador, considerando fatores como capacidade de pagamento, nível de endividamento e histórico de adimplência (Banco Central do Brasil, 2025). A transformação dessas variáveis em uma medida contínua de risco é especialmente adequada ao ambiente *fuzzy*, permitindo capturar nuances e transições graduais entre níveis de risco, conforme demonstrado em pesquisas nacionais que aplicam sistemas *fuzzy* à análise de concessão de crédito (Bueno, 2011; Freitas; Tavares; Montini, 2008).

Variáveis alternativas como escolaridade, profissão, ou região podem enriquecer o modelo, mas não possuem, por si só, comprovada robustez estatística ou respaldo legal semelhante para uso obrigatório conforme exposto nos normativos do Banco Central, Lei do Cadastro Positivo, *guidelines* da Febraban e publicações científicas nacionais. Por isso, optou-se por priorizar as variáveis que possuem maior poder preditivo, aderência às normas e maior representatividade nos modelos consagrados pela literatura técnica e por órgãos reguladores. Dessa forma, a escolha das variáveis utilizadas neste trabalho não é arbitrária, mas fundamentada

em documentos oficiais, práticas consolidadas do setor financeiro e literatura acadêmica brasileira. Score, renda e endividamento representam os três eixos centrais utilizados pelo mercado e pelos órgãos reguladores para mensurar risco, enquanto a variável de saída traduz de forma contínua a classificação exigida pelas normas vigentes. Esse conjunto de justificativas garante a aderência metodológica e regulatória do sistema *fuzzy* proposto.

### 3.2 CONJUNTOS FUZZY

A variável score de crédito (SC) possui zonas de transição incertas onde um indivíduo pode pertencer parcialmente a múltiplas categorias linguísticas simultaneamente, como por exemplo, "score bom" e "score alto". A variável renda mensal (RM) pode apresentar categorização como "baixa", "média" ou "alta" que depende de fatores geográficos e socioeconômicos que impedem delimitações absolutas. O índice de endividamento (IE) pode apresentar transições suaves entre categorias de avaliação, como por exemplo, a transição entre "baixo" e "alto" endividamento pode ser gradual. A variável risco de crédito (RC) é inerente ao conceito *fuzzy*, não existindo "50% de risco" de forma precisa, mas sim categorias como "baixo", "médio" ou "alto" risco.

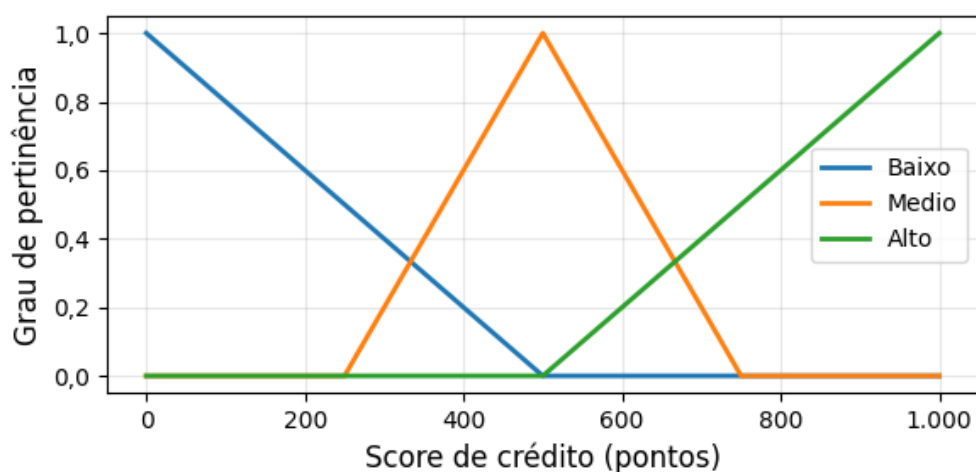
A variável risco de crédito foi representada em uma escala contínua de 0 a 100, o que proporciona maior precisão na estimativa do risco e possibilita análises mais detalhadas do perfil dos clientes. A Tabela 1 apresenta os conjuntos *fuzzy* correspondentes às variáveis de entrada e saída do SBRF, bem como suas respectivas funções de pertinência triangulares. Cabe destacar que os intervalos dos conjuntos *fuzzy* foram definidos de forma a permitir sobreposição, o que garante uma inferência mais suave e evita a criação de limites rígidos e arbitrários entre as categorias. Ressalta-se, ainda, que os parâmetros dessas funções de pertinência são arbitrários, podendo ser ajustados com base em dados históricos reais (como percentis ou distribuições de probabilidade) ou no conhecimento de especialistas da área de crédito. As Figuras 2 a 5 apresentam as representações gráficas das funções de pertinência associadas às variáveis de entrada e de saída do sistema.

Tabela 1 – Conjuntos *fuzzy* das variáveis de entrada e saída

| Variável de entrada                 | Conjunto <i>fuzzy</i>                          | Parâmetro  |
|-------------------------------------|--|--|
| Score de crédito – SC<br>(pontos)   | Baixo<br>Médio<br>Alto                         | (0, 0, 500)<br>(250, 500, 750)<br>(500, 1.000, 1.000)                        |
| Renda mensal – RM<br>(R\$)          | Baixa<br>Média<br>Alta                         | (0, 0, 4.000)<br>(3.000, 4.000, 5.000)<br>(4.000, 15.000, 15.000)            |
| Índice de endividamento – IE<br>(%) | Baixo<br>Moderado<br>Alto                      | (0, 0, 20)<br>(10, 40, 60)<br>(40, 100, 100)                                 |
| Variável de saída                   | Conjunto <i>fuzzy</i>                          | Parâmetro  |
| Risco de crédito – RC<br>(%)        | Mínimo<br>Baixo<br>Moderado<br>Alto<br>Extremo | (0, 0, 25)<br>(20, 30, 50)<br>(45, 60, 75)<br>(70, 80, 90)<br>(85, 100, 100) |

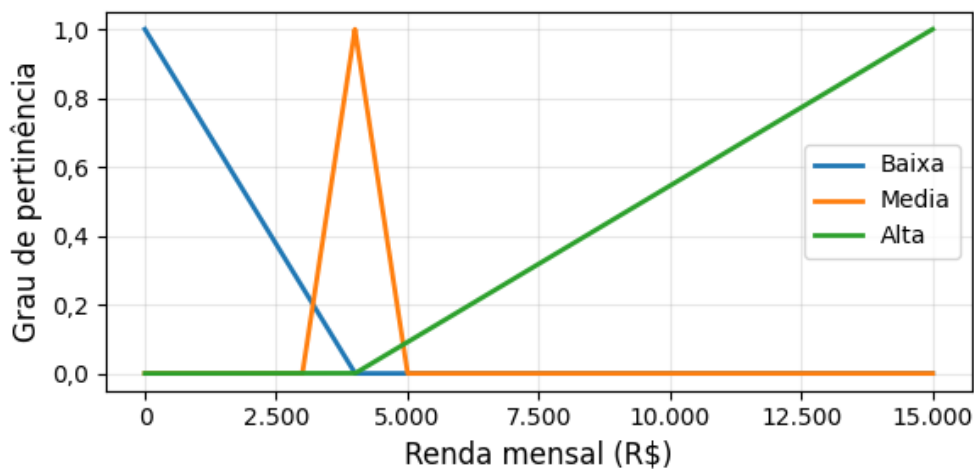
Fonte: Elaborado pelo autor, 2025.

Figura 2 – Representação gráfica das funções de pertinência da variável “Score de crédito”



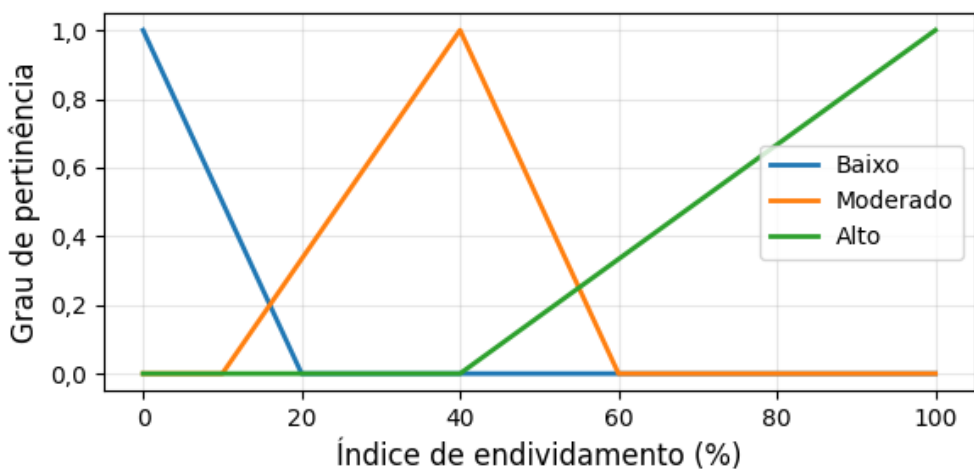
Fonte: Elaborado pelo autor (2025).

Figura 3 – Representação gráfica das funções de pertinência da variável “Renda mensal”



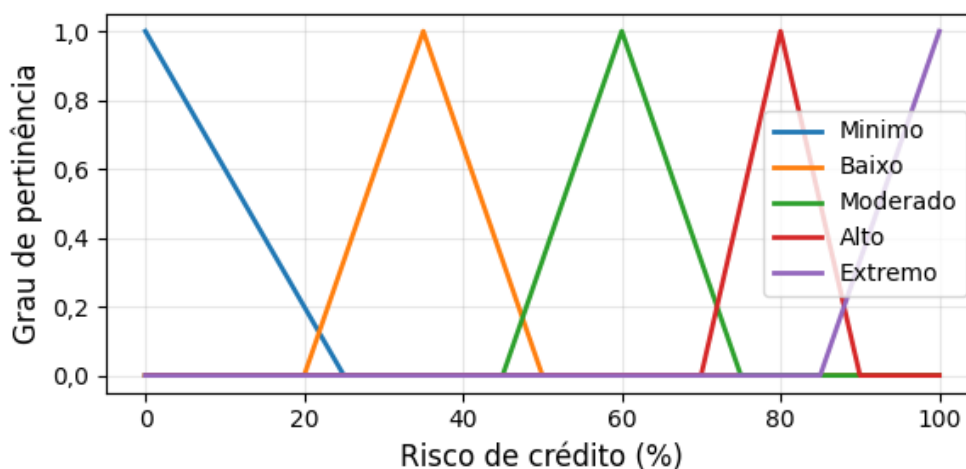
Fonte: Elaborado pelo autor (2025).

Figura 4 – Representação gráfica das funções de pertinência da variável “Índice de endividamento”



Fonte: Elaborado pelo autor (2025).

Figura 5 – Representação gráfica das funções de pertinência da variável “Risco de crédito”



Fonte: Elaborado pelo autor (2025).

### 3.3 BASE DE REGRAS

Adotou-se o método de inferência de Mamdani, no qual o processo de inferência é realizado por meio do operador mínimo ( $\wedge$ ) para o conectivo lógico “e” e operador máximo ( $\vee$ ) para o conectivo lógico “ou”, que conecta as regras *fuzzy* da base de regras. Esse modelo é amplamente utilizado por sua intuitividade e capacidade de representar conhecimento linguístico de forma próxima ao raciocínio humano.

A Tabela 2 apresenta a base de regras construída para o SBRF proposto. Como exemplo, a regra 3 em destaque apresenta risco de crédito “extremo” para score de crédito “baixo”, renda mensal “baixa” e índice de endividamento “alto”. A base de regras atribui ao endividamento “alto” o status de fator crítico na avaliação de risco, com potencial para classificar operações nos patamares “alto” ou “extremo” mesmo quando acompanhado de scores elevados e rendas robustas. Esta abordagem fundamenta-se na premissa de que o comprometimento financeiro excessivo representa um indicador preditivo de insolvência, funcionando como alerta precursor de possíveis inadimplências. A base de regras estabelece ainda que scores favoráveis exercem efeito atenuante no risco de crédito, porém não neutralizante sobre rendas insuficientes ou endividamentos moderados, enquanto a convergência de múltiplos fatores negativos desencadeia mecanismos de

amplificação de risco. Ilustrativamente, a combinação entre score “médio” e endividamento “alto” resulta em risco “alto”, mas quando acrescida de renda “baixa”, evolui para risco extremo, demonstrando a natureza cumulativa das vulnerabilidades. Também um histórico crédito comprometido (score “baixo”) impossibilita a categorização como risco “moderado”, assim como o endividamento “alto” inviabiliza a mesma classificação, preservando a sensibilidade do sistema *fuzzy* a variáveis de alerta crítico.

Tabela 2 – Base de regras

|          | Se | SC           | e | RM           | e | IE          | Então | RC             |
|----------|----|--------------|---|--------------|---|-------------|-------|----------------|
| 1        |    | Baixo        |   | Baixa        |   | Baixo       |       | Alto           |
| 2        |    | Baixo        |   | Baixa        |   | Moderado    |       | Extremo        |
| <b>3</b> |    | <b>Baixo</b> |   | <b>Baixa</b> |   | <b>Alto</b> |       | <b>Extremo</b> |
| 4        |    | Baixo        |   | Média        |   | Baixo       |       | Alto           |
| 5        |    | Baixo        |   | Média        |   | Moderado    |       | Alto           |
| 6        |    | Baixo        |   | Média        |   | Alto        |       | Extremo        |
| 7        |    | Baixo        |   | Alta         |   | Baixo       |       | Alto           |
| 8        |    | Baixo        |   | Alta         |   | Moderado    |       | Alto           |
| 9        |    | Baixo        |   | Alta         |   | Alto        |       | Extremo        |
| 10       |    | Médio        |   | Baixa        |   | Baixo       |       | Alto           |
| 11       |    | Médio        |   | Baixa        |   | Moderado    |       | Alto           |
| 12       |    | Médio        |   | Baixa        |   | Alto        |       | Extremo        |
| 13       |    | Médio        |   | Média        |   | Baixo       |       | Moderado       |
| 14       |    | Médio        |   | Média        |   | Moderado    |       | Moderado       |
| 15       |    | Médio        |   | Média        |   | Alto        |       | Alto           |
| 16       |    | Médio        |   | Alta         |   | Baixo       |       | Baixo          |
| 17       |    | Médio        |   | Alta         |   | Moderado    |       | Moderado       |
| 18       |    | Médio        |   | Alta         |   | Alto        |       | Alto           |
| 19       |    | Alto         |   | Baixa        |   | Baixo       |       | Moderado       |
| 20       |    | Alto         |   | Baixa        |   | Moderado    |       | Alto           |
| 21       |    | Alto         |   | Baixa        |   | Alto        |       | Extremo        |
| 22       |    | Alto         |   | Média        |   | Baixo       |       | Baixo          |
| 23       |    | Alto         |   | Média        |   | Moderado    |       | Moderado       |
| 24       |    | Alto         |   | Média        |   | Alto        |       | Alto           |
| 25       |    | Alto         |   | Alta         |   | Baixo       |       | Mínimo         |
| 26       |    | Alto         |   | Alta         |   | Moderado    |       | Baixo          |
| 27       |    | Alto         |   | Alta         |   | Alto        |       | Alto           |

Fonte: Elaboração própria (2025).

### 3.4 DEFUZZIFICAÇÃO

A defuzzificação foi realizada pelo método do centro de gravidade, que calcula um valor numérico de saída como a média ponderada de todos os elementos

do conjunto *fuzzy* de saída ( $B$ ), onde cada valor  $x_i$  no domínio é ponderado pelo seu respectivo grau de pertinência  $\mu_B(x_i)$ , sendo o resultado final obtido pela soma dos produtos de cada  $x_i$  por  $\mu_B(x_i)$  dividido pela soma de todos os graus de pertinência. Esse método é o mais comum na literatura, por fornecer resultados estáveis e bem interpretáveis.

### 3.5 IMPLEMENTAÇÃO COMPUTACIONAL

Para o desenvolvimento do SBRF, optou-se pela utilização da linguagem de programação Python em virtude de sua versatilidade e ampla adoção na comunidade científica. A implementação foi realizada com o auxílio do pacote *scikit-fuzzy* (Scikit-Fuzzy, 2025), uma biblioteca de código aberto que oferece ferramentas robustas para a modelagem de sistemas *fuzzy*, incluindo a definição de variáveis linguísticas, funções de pertinência e mecanismos de inferência. Esta escolha tecnológica permitiu a construção de um sistema eficiente e transparente para avaliação de risco creditício, alinhando-se às melhores práticas contemporâneas de desenvolvimento de sistemas inteligentes.

## 4 RESULTADOS E DISCUSSÃO

Para demonstrar a operacionalidade do sistema baseado em regras *fuzzy* (SBRF) desenvolvido, foi analisado um cenário (perfil de cliente) com as seguintes características: “score de crédito (SC)” de 650 pontos, “renda mensal (RM)” de R\$ 4.500,00 e “índice de endividamento (IE)” de 35%. A Tabela 3 detalha os conjuntos *fuzzy* ativados por cada variável de entrada e seus respectivos graus de pertinência, evidenciando o processo de fuzzificação dos dados.

Tabela 3 – Conjuntos *fuzzy* ativados pelos valores de entrada

| Valor de entrada | Conjunto <i>fuzzy</i> | Grau de pertinência |
|------------------|-----------------------|---------------------|
| SC = 650 pontos  | Baixo                 | 0,0                 |
|                  | Médio                 | 0,4                 |
|                  | Alto                  | 0,3                 |
| RM = R\$ 4.500   | Baixa                 | 0,0                 |
|                  | Média                 | 1,0                 |
|                  | Alta                  | 0,045               |
| IE = 35%         | Baixo                 | 0,0                 |
|                  | Moderado              | 0,833               |
|                  | Alto                  | 0,0                 |

Fonte: Elaborado pelo autor, 2025.

Com base nos conjuntos *fuzzy* ativados pelos valores de entrada, identificaram-se as regras do sistema que foram acionadas, conforme detalhado na Tabela 4. A partir dos graus de pertinência obtidos na etapa de fuzzificação – score com 0,4 no conjunto “médio” e 0,3 em “alto”, renda com 1,0 em “média” e 0,045 em “alta”, e endividamento com 0,833 em “moderado” – observou-se a ativação paralela de múltiplas regras (14, 17, 23 e 26). As combinações que envolvem renda “média” e endividamento “moderado” destacaram-se como as mais representativas em função dos elevados graus de pertinência associados. Especificamente, as regras 14 e 23 emergiram como as mais relevantes devido aos altos valores de pertinência da renda “média” e endividamento “moderado”, enquanto as regras 17 e 26, que incorporam renda “alta” ou endividamento “alto”, apresentaram influência reduzida em virtude dos baixos graus de pertinência nessas categorias. Este comportamento demonstra a capacidade do sistema de processar múltiplos caminhos de inferência de maneira simultânea antes da aplicação do operador de mínimo pelo Método de Mamdani.

Tabela 4 – Regras ativadas pelos valores de entrada

|    | Se | SC    | e | RM    | e | IE       | Então | RC       |
|----|----|-------|---|-------|---|----------|-------|----------|
| 14 |    | Médio |   | Média |   | Moderado |       | Moderado |
| 17 |    | Médio |   | Alta  |   | Moderado |       | Moderado |
| 23 |    | Alto  |   | Média |   | Moderado |       | Moderado |
| 26 |    | Alto  |   | Alta  |   | Moderado |       | Baixo    |

Fonte: Elaborado pelo autor, 2025.

O próximo passo no processo de inferência *fuzzy* consiste na aplicação do operador mínimo ( $\wedge$ ) pelo Método de Mamdani, onde cada regra terá seu grau de

ativação determinado a partir do menor grau de pertinência entre seus antecedentes. A Tabela 5 apresenta os graus de pertinência de corte aplicados aos conjuntos *fuzzy* de saída após a aplicação do operador mínimo. Dentre as regras ativadas, a regra 14 emerge como a mais influente, apresentando grau de ativação de 0,4 no conjunto *fuzzy* de saída “moderado”. A regra 23 complementa essa tendência com grau de ativação de 0,3 no mesmo conjunto de saída, reforçando a classificação de risco “moderado”. Em contraste, as regras 17 e 26 demonstram influência marginal, com graus de ativação de apenas 0,045, em virtude dos reduzidos valores de pertinência associados à renda “alta”. Cabe destacar que, enquanto a regra 17 corrobora o risco “moderado”, a regra 26 sugere risco “baixo”, porém ambas exercem impacto limitado na decisão final. A análise do padrão de ativação evidencia a preponderância do endividamento “moderado” (0,833 em todas as regras) e da renda “média” (1,0 nas regras 14 e 23) como determinantes centrais, enquanto o score atua como fator modulador entre as categorias “médio” e “alto”.

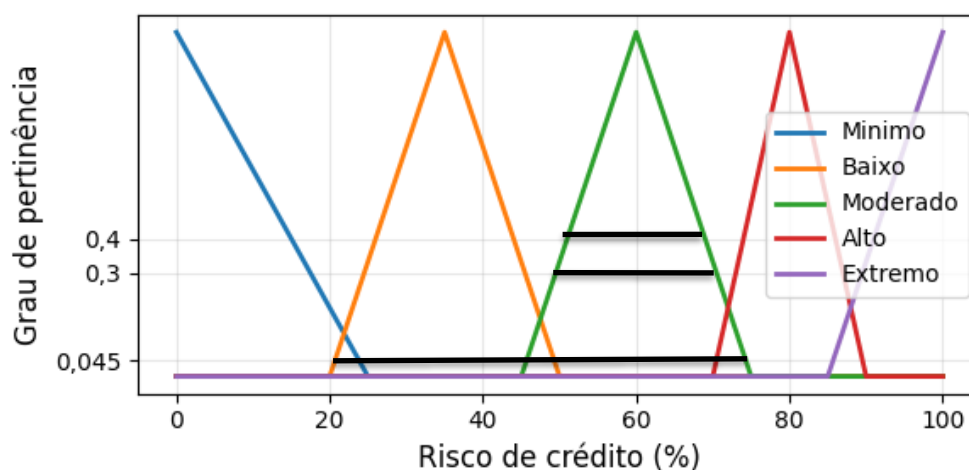
A Figura 6 ilustra os conjuntos *fuzzy* da variável de saída risco de crédito submetidos ao processo de truncamento, evidenciando os cortes aplicados aos conjuntos “moderado” (com níveis de 0,4, 0,3 e 0,045) e “baixo” (com corte em 0,045).

Na etapa subsequente do processo de inferência *fuzzy*, realiza-se a agregação das regras pelo operador máximo ( $\vee$ ), que calcula os graus de pertinência máximos nos conjuntos “moderado” e “baixo”, consolidando as contribuições individuais de cada regra ativada em um único conjunto *fuzzy* de saída. A Figura 7 apresenta o conjunto *fuzzy* de saída após a operação de máximo.

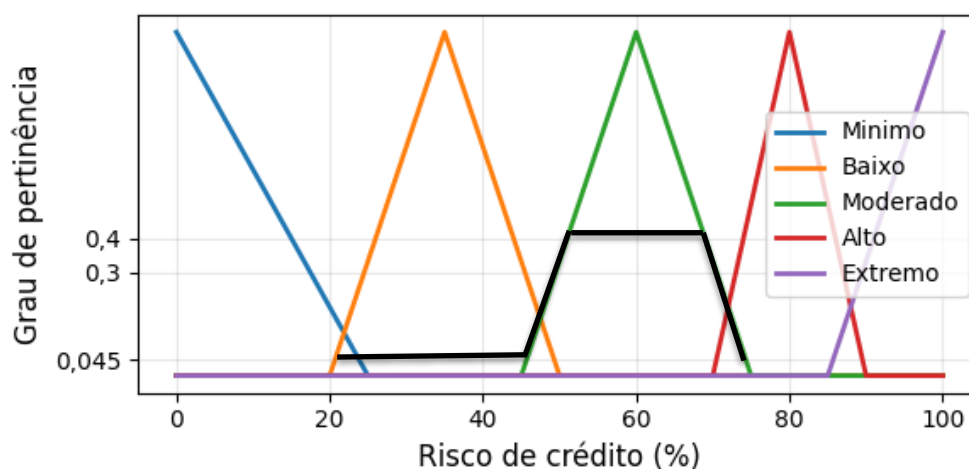
Tabela 5 – Aplicação do operador mínimo

|                     | Se | SC    | e        | RM    | e        | IE       | Então | RC           |
|---------------------|----|-------|----------|-------|----------|----------|-------|--------------|
| 14                  |    | Médio |          | Média |          | Moderado |       | Moderado     |
| Grau de pertinência |    | 0,4   | $\wedge$ | 1,0   | $\wedge$ | 0,833    |       | <b>0,4</b>   |
| 17                  |    | Médio |          | Alta  |          | Moderado |       | Moderado     |
| Grau de pertinência |    | 0,4   | $\wedge$ | 0,045 | $\wedge$ | 0,833    |       | <b>0,045</b> |
| 23                  |    | Alto  |          | Média |          | Moderado |       | Moderado     |
| Grau de pertinência |    | 0,3   | $\wedge$ | 1,0   | $\wedge$ | 0,833    |       | <b>0,3</b>   |
| 26                  |    | Alto  |          | Alta  |          | Moderado |       | Baixo        |
| Grau de pertinência |    | 0,3   | $\wedge$ | 0,045 | $\wedge$ | 0,833    |       | <b>0,045</b> |

Fonte: Elaborado pelo autor, 2025.

Figura 6 – Cortes nos conjuntos *fuzzy* de saída moderado e baixo

Fonte: Elaborado pelo autor, 2025.

Figura 7 – Conjunto *fuzzy* de saída

Fonte: Elaborado pelo autor, 2025.

Para a conversão da saída *fuzzy* em um valor numérico representativo do risco de crédito, aplicou-se o método do centro de gravidade, amplamente reconhecido como uma das técnicas mais robustas e precisas para defuzzificação em sistemas *fuzzy*. No contexto específico deste sistema de avaliação de risco creditício, o método do centro de gravidade demonstra particular adequação por considerar proporcionalmente todas as regiões ativadas da variável de saída, atribuindo maior peso às áreas com maiores graus de pertinência - notadamente a região correspondente ao risco "moderado", que recebeu as contribuições mais significativas das regras 14 e 23. Esta abordagem garante que o valor final reflita o equilíbrio entre todas as regras ativadas, produzindo uma saída suave e contínua que evita transições abruptas entre diferentes níveis de risco.

O cenário apresentado resultou em um valor defuzzificado de 57,12% para o risco de crédito, posicionando o perfil analisado na categoria de risco "moderado". Com base nesta classificação, o sistema pode emitir a recomendação de "crédito aprovado com restrições", consistente com a parametrização estabelecida para o nível de risco identificado. Este resultado demonstra a efetividade do modelo em traduzir entradas *fuzzy* em uma saída numérica precisa, permitindo não apenas a classificação categórica do perfil, mas também uma quantificação que viabiliza comparações entre diferentes cenários. A escolha por este método alinha-se com as melhores práticas da literatura em sistemas *fuzzy*, assegurando precisão computacional e interoperabilidade dos resultados.

Na Tabela 6, são apresentados quatro cenários envolvendo diferentes perfis

de clientes. A seleção dos cenários buscou representar o espectro completo de perfis de clientes encontrados na prática creditícia, permitindo avaliar a sensibilidade e consistência do sistema *fuzzy* proposto. No cenário 1 (cliente ideal), a decisão de "crédito aprovado" justifica-se pelos excelentes indicadores em todas as dimensões: score elevado (800 pontos), renda significativa (R\$ 12.000) e baixo endividamento (15%). O risco calculado de 21,9% situa-se confortavelmente na categoria "baixo", indicando um perfil com alta capacidade de pagamento e baixa probabilidade de inadimplência. O cenário 2 (cliente bom) recebe "crédito aprovado com restrições" em função do risco moderado de 51,6%, que reflete a combinação de um bom score (700 pontos) e renda adequada (R\$ 6.000) com um endividamento elevado (45%). Esta decisão reconhece a qualidade do histórico creditício, mas impõe cautela devido ao comprometimento financeiro significativo, possivelmente sugerindo limites de crédito reduzidos ou garantias adicionais. Os cenários 3 e 4 resultam em "crédito negado" de forma consistente com seus indicadores críticos. O Cenário 3 (cliente médio) apresenta risco extremo de 93,4% devido à combinação de score mediano (550 pontos), renda insuficiente (R\$ 3.000) e alto endividamento (65%), configurando um perfil com múltiplas vulnerabilidades. O cenário 4 (cliente ruim) atinge o maior nível de risco (94,4%), reflexo do agravamento de todos os indicadores: score baixo (450 pontos), renda crítica (R\$ 1.500) e endividamento massivo (75%). A progressão dos resultados – desde o cliente ideal ao cliente ruim – valida a coerência do sistema, que consegue diferenciar nuances entre perfis e atribuir classificações de risco proporcionais às características de entrada.

Tabela 6 – Resultados do SBRF para diferentes perfis de clientes

| Cenário | Perfil        | SC<br>(pontos) | RM<br>(\$) | IE<br>(%) | RC<br>(%) | Decisão                         |
|---------|---------------|----------------|------------|-----------|-----------|---------------------------------|
| 1       | Cliente ideal | 800            | 12.000     | 15        | 21,9      | Crédito aprovado                |
| 2       | Cliente bom   | 700            | 6.000      | 45        | 51,6      | Crédito aprovado com restrições |
| 3       | Cliente médio | 550            | 3.000      | 65        | 93,4      | Crédito negado                  |
| 4       | Cliente ruim  | 450            | 1.500      | 75        | 94,4      | Crédito negado                  |

Fonte: Elaborado pelo autor, 2025.

## 5 CONSIDERAÇÕES FINAIS

O presente trabalho apresentou um sistema baseado em regras *fuzzy* aplicado à avaliação do risco de crédito, demonstrando sua capacidade de lidar com variáveis linguísticas e a imprecisão inerente ao contexto financeiro. Vale destacar que, para fins de demonstração, o sistema foi desenvolvido sem o uso de dados reais, utilizando apenas valores simulados para testar o comportamento das regras e da lógica *fuzzy*.

Destaca-se como ponto forte do sistema *fuzzy* a sua flexibilidade para incorporar conhecimento especializado por meio de regras linguísticas, o que facilita a construção de modelos adaptados às particularidades do setor bancário. O modelo proposto representou adequadamente os diferentes perfis de risco e permitiu a recomendação de ações compatíveis para cada cenário analisado.

Como sugestão para trabalhos futuros, recomenda-se a análise de outras variáveis de saída, como a classificação do cliente ou a probabilidade de inadimplência, permitindo análises multicritério e a personalização de limites de crédito. Além disso, destaca-se o uso de redes neurais artificiais com sistemas *fuzzy*, promovendo maior automação na geração de regras e modelos hierárquicos, tornando o sistema ainda mais robusto e capaz de processar volumes crescentes de dados com maior precisão e adaptabilidade. Dessa forma, o sistema proposto pode ser aperfeiçoado e expandido, contribuindo para decisões mais ágeis, seguras e transparentes.

A lógica *fuzzy* apresenta-se como uma ferramenta promissora para o desenvolvimento de sistemas especialistas na área financeira, podendo ser estendida para outros contextos, como análise de risco em seguros, segmentação de perfis e avaliação de investimentos.

## REFERÊNCIAS

- ADDO, P. M. et al. Credit risk analysis using machine learning. **Applied Economics**, v. 50, n. 13, p. 1373-1384, 2018.
- ASSIS, A. G.; DECOSTER, S. R. A. Gerenciamento de risco de crédito por meio da utilização de aprendizado de máquina: o caso do banco BS2. **Revista Catarinense de Ciência Contábil**. v. 24, p. 1-31, 2025.
- BRITO, G. A. S.; ASSAF NETO, A. Modelo de classificação de risco de crédito de empresas. **Revista Contabilidade & Finanças**, v. 19, n. 46, p. 18–29, 2008.
- BANCO CENTRAL DO BRASIL. **Política de Crédito e Critérios para Concessão de Crédito**. 2023. Disponível em: <https://www.bcb.gov.br/>. Acesso em: 30 out. 2025.
- BARROS, L. C.; BASSANEZI, R. C. **Tópicos de lógica fuzzy e biomatemática**. 3. ed. Campinas: IMECC-UNICAMP, 2015.
- BRASIL. Lei nº 12.414, de 9 de junho de 2011. Disciplina a formação e consulta a bancos de dados com informações de adimplemento de pessoas naturais ou de pessoas jurídicas, para formação de histórico de crédito. **Diário Oficial da União**: seção 1, Brasília, DF, p. 1, 10 jun. 2011. Disponível em: [https://www.planalto.gov.br/ccivil\\_03/\\_ato2011-2014/2011/lei/l12414.htm](https://www.planalto.gov.br/ccivil_03/_ato2011-2014/2011/lei/l12414.htm). Acesso em: 30 out. 2025.
- BUENO, L. M. **Análise de crédito: medidas de avaliação de modelos e aplicação da teoria fuzzy na tomada de decisão**. 2011. Monografia (Graduação em Engenharia) – Universidade de Brasília, Brasília, 2011. Disponível em: <https://bdm.unb.br/handle/10483/3508>. Acesso em: 30 out. 2025.
- CAMARGOS, M. A. et al. Fatores condicionantes de inadimplência em processos de concessão de crédito a micro e pequenas empresas do Estado de Minas Gerais. **Revista de Administração Contemporânea**, v. 14, n. 2, p. 333–352, 2010.
- FEBRABAN. **Guia Prático para Elaboração e Implementação de Políticas de Crédito**. 2021. Disponível em: <https://cmsarquivos.febraban.org.br/Arquivos/documentos/PDF/GUIA%20PRATICO%20PRSA.pdf>. Acesso em: 30 out. 2025.
- FERREIRA, A. C. A Lei Geral de Proteção de Dados (LGPD) e os impactos na análise de crédito. **Revista Jurídica Brasileira**, v. 3, p. 88-105, 2020.
- FREITAS, A. F.; TAVARES, L. S.; MONTINI, A. A. Modelo fuzzy hierárquico para avaliação de risco de crédito pessoal. *In*: ENCONTRO DA ASSOCIAÇÃO NACIONAL DE PÓS-GRADUAÇÃO E PESQUISA EM ADMINISTRAÇÃO, 32., 2008, Rio de Janeiro. **Anais** [...]. Rio de Janeiro: ANPAD, 2008.
- GOMES, J. A. D. S. **Modelos de Credit Scoring: uma aplicação a crédito ao consumidor no Brasil**. São Paulo: Blucher, 2010.

GONÇALVES, E. B.; GOUVÊA, M. A.; MANTOVANI, D. M. N. Análise de risco de crédito com o uso de regressão logística. **Revista Contemporânea de Contabilidade**, v. 10, n. 20, 2013.

SCHRICKEL, W. K. **Análise de crédito: concessão e gerência de empréstimos**. São Paulo: Atlas, 1995.

SERASA. **O que é Score de crédito e para que serve**. 2025. Disponível em: <https://www.serasa.com.br/score/blog/o-que-e-score-de-credito/>. Acesso em: 30 out. 2025.

SCIKIT-FUZZY. **Scikit-fuzzy: fuzzy logic toolbox for Python**. Disponível em: <https://github.com/scikit-fuzzy/scikit-fuzzy>. Acesso em: 15 out. 2025.

SYAU, Y.; HSIEH, H.; LEE, E. S. *Fuzzy number in the credit rating of enterprise financial condition*. **Review of Quantitative Finance and Accounting**, v. 17, n. 4, p. 351–360, 2001.

ZADEH, L. A. *Fuzzy sets*. **Information and control**, v. 8, n. 3, p. 338-353, 1965.

ZIMMERMANN, H. J. **Fuzzy set theory—and its applications**. 4. ed. Boston: Kluwer Academic Publishers, 2010.