



Universidade Estadual do Piauí  
Pró-Reitoria de Pesquisa e Pós-Graduação–PROP  
Programa de Mestrado Profissional em  
Matemática em Rede Nacional



Antonio Delon Carvalho Barros

**A LÓGICA FUZZY À LUZ DA LINGUAGEM  
PYTHON COMO CONTRIBUTO PARA  
AUXILIAR NO DIAGNÓSTICO ESCOLAR**

Teresina

2024

Antonio Delon Carvalho Barros

A LÓGICA FUZZY À LUZ DA LINGUAGEM PYTHON COMO  
CONTRIBUTO PARA AUXILIAR NO DIAGNÓSTICO ESCOLAR

Dissertação de Mestrado apresentada à Comissão  
Acadêmica Institucional do PROFMAT-UESPI  
como requisito parcial para obtenção do título de  
Mestre em Matemática.

Área de Concentração: Matemática

Orientador: Prof.Dr.Afonso Norberto da Silva

Teresina  
2024

B2771 Barros, Antonio Delon Carvalho.  
A lógica Fuzzy à luz da linguagem Python como contributo para  
auxiliar no diagnóstico escolar / Antonio Delon Carvalho Barros. – 2024.  
89 p. : il.

Dissertação (mestrado) – Universidade Estadual do Piauí –  
UESPI, Programa de Mestrado Profissional em Matemática em Rede  
Nacional, *Campus* Poeta Torquato Neto, Teresina-PI, 2024.

“Orientador Prof. Dr. Afonso Norberto da Silva.”

“Área de Concentração: Matemática.”

1. Lógica Fuzzy. 2. Python. 3. Diagnóstico escolar.  
I. Título.

CDD: 510.07

ANTONIO DELON CARVALHO BARROS

A LÓGICA FUZZY À LUZ DA LINGUAGEM PYTHON COMO  
CONTRIBUTO PARA AUXILIAR NO DIAGNÓSTICO ESCOLAR

Dissertação de Mestrado apresentada à Comissão Acadêmica Institucional do  
PROF MAT-UESPI como requisito obrigatório para obtenção do título de Mestre.

Área de concentração: MATEMÁTICA

Aprovado por:

Afonso Norberto da Silva

Prof.Dr.Afonso Norberto da Silva - Presidente  
Universidade Estadual do Piauí - UESPI

Pedro Antônio Soares Júnior

Prof. Dr. Pedro Antônio Soares Júnior - Examinador  
Universidade Estadual do Piauí - UESPI

Pablo Roberto de Sousa Neto.

Prof. Dr. Pablo Roberto de Sousa Neto - Examinador Externo  
Instituto Federal do Maranhão - IFMA

Todos os direitos reservados. É proibida a reprodução total ou parcial deste trabalho sem a autorização da universidade, do autor e do orientador.

**Antonio Delon Carvalho Barros** graduou-se em Licenciatura Plena em Matemática pela Universidade Federal do Piauí (UFPI) no ano de 2002

# DEDICATÓRIA

Dedico este trabalho, com imensa honra e profunda alegria, à minha família, alicerce fundamental de minha existência. À minha amada esposa, Julliana Tabatinga, meu porto seguro e eterna fonte de incentivo. Aos meus queridos filhos, Davi Tacb, Filipe Tacb e Liana Tacb, a inspiração mais pura que a vida poderia me conceder. E aos meus queridos pais, Solon Barros e Senhorinha Carvalho, os alicerces inabaláveis na minha vida. Vocês são a prova viva do amor incondicional e da força que me movem. Sem vocês, este trabalho não seria possível, nem teria o mesmo significado. Agradeço do fundo do meu coração por serem a minha família, por me amarem incondicionalmente e por acreditarem em mim.

# AGRADECIMENTOS

Com suor e fé, colhi frutos além do imaginado. Agradeço a Deus e peço sabedoria para honrá-lo.

Agradeço a minha Mãe, Senhorinha Pereira de Carvalho Barros, que sempre me mandou estudar para ser alguém na vida e buscar vencer pelos estudos. E meu Pai, Francisco Solon Barros, obrigado por sempre me colocar no caminho certo. Sou grato por todo o sacrifício e dedicação que tiveram por mim, sou testemunha de tudo que abriram mão na vida para que eu tivesse a oportunidade de estudar em uma boa escola durante a educação básica. Tenho muito orgulho da nossa história. Muito obrigado por tudo, AMO MUITO VOCÊS!

Agradeço a minha esposa amada Julliana Tabatinga A. Barros, Há mais de vinte e três anos, você ilumina meu caminho com amor e incentivo. Desde o primeiro dia, me impulsiona a buscar o melhor de mim, a superar cada obstáculo e a me tornar um profissional exemplar. Te amo mais do que as palavras podem expressar! Aos meus queridos filhos, Davi Tabatinga A. C. Barros, Filipe Tabatinga A.C.Barros e Liana Tabatinga A.C. Barros, vocês são a maior realização da minha vida.e por me proporcionarem a alegria de ser pai. Mais do que meus filhos, vocês são meus amigos, meus confidentes e meus maiores incentivadores. Agradeço por me ajudarem em minha jornada profissional, por me tirarem dúvidas com sua maestria em matemática e por me inspirarem a ser um homem cada vez melhor. Amo vocês incondicionalmente!

Agradeço ao meu irmão Francisco Solon Barros Filho que guiando-me com a sabedoria ímpar de um mestre em computação. Sua generosidade em compartilhar seus conhecimentos foi a bússola que me direcionou na árdua jornada da pesquisa.

Ao meu amigo e eterno aluno, Emmanoel Campelo da Luz, mais do que um amigo, você se tornou um mentor, um guia e um pilar fundamental em minha vida. Desde o início, me acolheu com carinho. Sua fé inabalável em minhas capacidades me impulsionou a superar os desafios e a alcançar meus sonhos. Obrigado por me mostrar que a desistência jamais deve ser uma opção. Emmanoel, você é um amigo excepcional, um professor exemplar e um ser humano extraordinário. Tenho a imensa honra de tê-lo em minha vida, e sou grato por cada momento que compartilhamos.Do fundo do meu coração, muito obrigado por tudo!

Aos meus valorosos companheiros de caminhada, Edvaldo Leandro Lima Monte, Hisley Feitosa Meneses, Francisco Erasmo de Moraes, Lício Lima Medeiros, Lucas Lima Mendes, Paulo Robson Paiva Soares, Vanilson de Paulo Ribeiro dos Santos, Francisco Miranda Barro, José Carlos da Cunha Guimarães Júnior, Ney da Costa Oliveira, Gustavo Vilarinho Rodrigues Neto, Afonso Araujo Sales, Eugênio Pereira Oliveira, dedico estas palavras em profunda gratidão pelos laços que construímos durante o mestrado profissional do PROFMAT/UESPI 2022.1. Juntos, trilhamos um caminho árduo, mas gratificante, em busca do conhecimento e do aperfeiçoamento profissional. Cada encontro, presencial ou virtual, se tornou um oásis de aprendizado mútuo, onde compartilhávamos dúvidas, ideias e experiências, tecendo uma rede de apoio inestimável.

Aos professores, Dr. Arnaldo Brito, Dr. Afonso Norberto, Dr. Pedro Júnior, Dr. Natã Firmino, Dr. Neuton Alves, e Dra. Valdirene por compartilharem conosco seus conhecimentos e suas experiências. Obrigado professores.

Ao Meu orientador Dr. Afonso Norberto da Silva, que por inúmeras vezes discutimos sobre um tema interessante e relevante na lógica fuzzy que poderia ser aplicado aos alunos do ensino fundamental e médio, obrigado pela paciência e por compartilhar comigo seus conhecimentos acadêmicos, sempre disponíveis e pontuais nos esclarecimentos das dúvidas e nas orientações do trabalho. Obrigado Professores.

Por fim, agradeço a todos que de alguma maneira contribuíram de forma positiva para a realização deste mestrado, minha sincera gratidão!

“A pesquisa em matemática é como  
desvendar um quebra-cabeça gigante,  
onde cada peça se encaixa perfeitamente  
para revelar a imagem completa. ”

---

*Elon Lindenstrauss*

## RESUMO

Esta dissertação explora o uso da lógica fuzzy à luz da linguagem Python como contributo para auxiliar o diagnóstico escolar. Ao empregar estratégias práticas baseadas em lógica fuzzy, busca-se otimizar o processo de aprendizado, levando em consideração a complexidade das variáveis envolvidas no ambiente escolar. A análise abrange a personalização de abordagens educacionais, considerando as diferentes necessidades dos alunos, promovendo um ambiente propício para a dedicação e integrando o apoio da família de maneira significativa. Utilizando a linguagem Python, é possível implementar algoritmos baseados em lógica fuzzy para criar um sistema flexível e adaptável. Este sistema pode lidar com as nuances do desenvolvimento acadêmico, melhorando assim o desempenho geral dos estudantes. Por meio de bibliotecas como scikit-fuzzy e numpy, é possível desenvolver modelos que capturam a incerteza e a imprecisão presentes no ambiente educacional. A personalização das abordagens educacionais pode ser implementada por meio de algoritmos que ajustam automaticamente o material didático com base no desempenho e nas preferências individuais dos alunos. A lógica fuzzy proporciona uma estrutura adequada para lidar com a variedade de informações e contextos presentes no processo educacional. Além disso, a integração do apoio da família pode ser facilitada por meio de sistemas que enviam feedbacks personalizados aos responsáveis, destacando o progresso e as áreas de melhoria dos alunos. A linguagem Python oferece ferramentas para a criação de interfaces interativas e relatórios automatizados que tornam a comunicação entre escola e família mais eficiente. Portanto, este estudo não apenas destaca a importância da lógica fuzzy como uma ferramenta eficaz no contexto educacional, mas também propõe a aplicação prática desses conceitos por meio da implementação de algoritmos em Python, promovendo um contributo para auxiliar no diagnóstico escolar.

**Palavras-chave:** Lógica Fuzzy; Python; Diagnóstico Escolar

## ABSTRACT

This dissertation explores the use of fuzzy logic in the light of the Python language as a contribution to assisting school diagnosis. By employing practical strategies based on fuzzy logic, the aim is to optimize the learning process, taking into account the complexity of variables involved in the school environment. The analysis covers the customization of educational approaches, considering the different needs of students, promoting an environment conducive to dedication, and integrating family support meaningfully.

Using the Python language, it is possible to implement fuzzy logic-based algorithms to create a flexible and adaptable system. This system can handle the nuances of academic development, thereby improving overall student performance. Through libraries such as scikit-fuzzy and numpy, it is possible to develop models that capture the uncertainty and imprecision present in the educational environment.

The customization of educational approaches can be implemented through algorithms that automatically adjust educational materials based on the performance and individual preferences of students. Fuzzy logic provides a suitable framework for handling the variety of information and contexts present in the educational process.

Furthermore, the integration of family support can be facilitated through systems that send personalized feedback to guardians, highlighting the progress and areas for improvement of students. The Python language offers powerful tools for creating interactive interfaces and automated reports that make communication between school and family more efficient.

Therefore, this study not only emphasizes the importance of fuzzy logic as a valuable tool in the educational context but also proposes the practical application of these concepts through the implementation of algorithms in Python, promoting an innovative approach to improve academic performance.

**Keywords:** Keywords: Fuzzy Logic; Python; School Diagnosis

## Lista de Figuras

1	Diagrama lógico . . . . .	5
2	Gráficos lógicos . . . . .	7
3	Máquina de lavar . . . . .	16
4	Controles Fuzzy . . . . .	16
5	Condicionador de ar . . . . .	17
6	Controle fuzzy . . . . .	17
7	Aspirador de pó . . . . .	18
8	Microondas . . . . .	18
9	Diagrama de relação entre elementos e conjuntos . . . . .	21
10	Representação gráfica . . . . .	22
11	Gráfico Função Triangular . . . . .	24
12	Gráfico Função Trapezoidal . . . . .	25
13	Gráfico Função Guassiana . . . . .	25
14	Gráfico Função Sino Generalizada . . . . .	26
15	Normalização . . . . .	27
16	Normalização . . . . .	28
17	Normalização . . . . .	29
18	Gráfico trapezoidal . . . . .	30
19	Gráficos de Conjuntos Fuzzy . . . . .	31
20	Sistema de inferência Fuzzy . . . . .	37
21	Funções de pertinência Triangular . . . . .	49
22	Funções de pertinência Triangular . . . . .	50
23	Gráfico de ativação . . . . .	51
24	Identificação dos dados . . . . .	52
25	Cálculo do Centróide . . . . .	53
26	Motivação . . . . .	56
27	Tempo de Estudo . . . . .	57
28	Dedicação . . . . .	58
29	Comunicação . . . . .	61
30	Envolvimento . . . . .	62
31	Recursos Disponíveis . . . . .	63
32	Apoio Familiar . . . . .	64
33	Ambiente apropriado . . . . .	66
34	Má influência . . . . .	69
35	Ociosidade . . . . .	72
36	Chances de Sucesso . . . . .	75

# Sumário

<b>Lista de Figuras</b>	<b>13</b>
<b>1 Introdução</b>	<b>1</b>
1.1 TEMA . . . . .	2
1.2 DELIMITAÇÃO DO TEMA . . . . .	2
1.3 PROBLEMA DE PESQUISA . . . . .	2
1.4 OBJETIVOS . . . . .	2
1.4.1 Objetivo Geral . . . . .	2
1.4.2 Objetivos Específicos . . . . .	2
1.5 JUSTIFICATIVA . . . . .	3
<b>2 Referencial Teórico</b>	<b>4</b>
2.1 Fatores que influenciam no processo de aprendizagem . . . . .	4
2.2 Teoria da Lógica Fuzzy . . . . .	5
2.2.1 Lógica Clássica X Lógica Fuzzy . . . . .	5
2.2.2 Utilização da Lógica Fuzzy . . . . .	7
2.2.3 Desenvolvimentos recentes da Lógica Fuzzy . . . . .	9
2.2.4 Desafios da Lógica Fuzzy . . . . .	12
2.2.5 Aplicações da Lógica Fuzzy . . . . .	14
2.2.6 Conjuntos Fuzzy . . . . .	20
2.2.7 Representação da função de pertinência . . . . .	22
2.2.8 Definições da Lógica Fuzzy . . . . .	27
2.2.9 Operações . . . . .	30
2.2.10 Propriedades . . . . .	31
2.2.11 Produto Cartesiano Fuzzy e Relações Fuzzy . . . . .	34
2.2.12 Composição entre Relações Fuzzy Binárias . . . . .	36
2.2.13 Sistemas Lógicos Fuzzy . . . . .	37
2.3 "Implementação de Lógica Fuzzy em Python . . . . .	39
2.3.1 Avanços e pontos-chave no uso da Lógica Fuzzy em Python . . . . .	41
2.3.2 Desafios e críticas no uso de Python na Lógica Fuzzy . . . . .	42
<b>3 Análise e Discussão de Dados</b>	<b>44</b>
3.1 Fuzzificação, Inferência e Defuzzificação em um Sistema de Controle . . . . .	44
3.2 Descrição das Variáveis em Linguagem Python . . . . .	53
3.2.1 Regras Integradas . . . . .	71
<b>4 Considerações Finais</b>	<b>76</b>
<b>Referências</b>	<b>77</b>

# 1 Introdução

A Lógica Fuzzy, também conhecida como lógica nebulosa ou lógica difusa, representa uma área da matemática que se destaca por sua capacidade de lidar com a incerteza e a imprecisão presentes em muitos problemas do mundo real. Este trabalho de dissertação se propõe a explorar as bases teóricas da Lógica Fuzzy, investigando seus fundamentos matemáticos e destacando suas aplicações práticas.

Segundo Von Altrock (1996) um dos grandes objetivos da Lógica Fuzzy é

o de se estreitar ao raciocínio humano, buscando respostas aproximadas aos problemas associados a eventos naturais, sendo assim, o foco principal da Lógica Fuzzy é a solução de problemas cujas informações são incertas.

No cenário contemporâneo da educação, a busca por métodos inovadores e eficientes para aprimorar o processo de tomada de decisão em ambientes educacionais é uma prioridade constante. Diante dos desafios complexos enfrentados no Ensino Fundamental, onde variáveis multifacetadas impactam diretamente na qualidade do ensino, torna-se imperativo explorar abordagens capazes de lidar com a incerteza e a imprecisão inerentes a esse contexto. A Lógica Fuzzy emerge como uma ferramenta promissora para modelar a ambiguidade e a subjetividade inerentes à tomada de decisões educacionais.

O Ensino Fundamental desempenha um papel crucial no desenvolvimento cognitivo e social dos alunos, e a eficácia do processo educacional está intrinsecamente ligada às decisões tomadas por educadores, gestores e demais envolvidos. Além disso, BNCC (2017) “ênfatiza a importância de criar um ambiente de aprendizado estimulantes e acolhedor que promova o engajamento e desenvolvimento holístico dos alunos” Contudo, as decisões nesse ambiente são frequentemente desafiadoras devido à complexidade das variáveis envolvidas, como desempenho acadêmico, características individuais dos alunos, dinâmicas de sala de aula e recursos disponíveis.

A aplicação prática da Lógica Fuzzy na tomada de decisão tem sido amplamente explorada em diversas áreas, mas sua utilização específica no contexto educacional do Ensino Fundamental ainda carece de uma investigação aprofundada. Este estudo procura preencher essa lacuna ao examinar como os princípios da Lógica Fuzzy podem ser adaptados e aplicados de maneira eficaz para lidar com a incerteza e a subjetividade presentes na tomada de decisões educacionais.

Para realizar essa análise, será explorada a implementação prática desses conceitos por meio da linguagem de programação Python. A utilização de Python permitirá desenvolver modelos e algoritmos baseados em Lógica Fuzzy que podem ser aplicados para otimizar a tomada de decisões no ambiente educacional. Essa abordagem integrada entre a teoria da Lógica Fuzzy e a implementação prática em Python oferecerá uma visão mais abrangente e aplicável, proporcionando soluções eficientes para os desafios específicos enfrentados no Ensino Fundamental.

A presente dissertação de mestrado tem como objetivo principal investigar a aplicação da lógica fuzzy em sistemas de controle utilizando a linguagem de programação Python. O estudo abrange desde os fundamentos da lógica fuzzy, incluindo sua comparação com a lógica clássica, até a implementação de sistemas fuzzy em Python, com foco na fuzzificação, inferência e defuzzificação.

Tema

## **1.1 TEMA**

Lógica Fuzzy em Python.

## **1.2 DELIMITAÇÃO DO TEMA**

Aplicação da Lógica Fuzzy em Python para auxiliar no diagnóstico escolar.

## **1.3 PROBLEMA DE PESQUISA**

Como a aplicação da lógica fuzzy em Python pode contribuir para auxiliar o diagnóstico escolar?

## **1.4 OBJETIVOS**

### **1.4.1 Objetivo Geral**

Investigar como a lógica fuzzy, implementada em Python, pode ser utilizada como ferramenta para aprimorar o processo de diagnóstico em ambientes escolares.

### **1.4.2 Objetivos Específicos**

Analisar as bases teóricas da lógica fuzzy e sua aplicação em sistemas de diagnóstico.  
Desenvolver um modelo fuzzy em Python para avaliar o desempenho acadêmico dos alunos.

Coletar dados sobre as atitudes, crenças e experiências dos profissionais em ambiente escolares, que possibilite a avaliação e eficácia do modelo proposto.

## 1.5 JUSTIFICATIVA

Como professor de matemática e apaixonado por tecnologia e inovação educacional, durante minha trajetória profissional, percebi desafios persistentes relacionados ao rendimento escolar de meus alunos. Sempre tive interesse na área de lógica e acredito que essa abordagem pode oferecer soluções flexíveis e adaptáveis para melhorar o rendimento escolar. Diante dos desafios observados em sala de aula, decidi embarcar em uma jornada de pesquisa e inovação. Minha experiência como professor de matemática me proporcionou insights valiosos sobre as complexidades do processo de aprendizado e as diversas variáveis que influenciam o desempenho dos alunos. Ao longo dos anos, meu interesse pela área de lógica e minha paixão por tecnologia e inovação educacional cresceram em paralelo com a busca por soluções práticas e eficazes. A lógica fuzzy, em particular, emergiu como uma abordagem intrigante, oferecendo a promessa de flexibilidade e adaptabilidade que eu acreditava serem essenciais para enfrentar os desafios educacionais contemporâneos. Minha crença na capacidade da lógica fuzzy de lidar com as nuances do diagnóstico escolar baseia-se na compreensão profunda de variáveis como dedicação dos alunos, apoio familiar e características específicas do ambiente escolar. Essa convicção impulsionou meu desejo de explorar estratégias que possam ser ajustadas conforme as necessidades específicas de cada contexto educacional. Ao decidir focar minha pesquisa no título "A LÓGICA FUZZY À LUZ DA LINGUAGEM PYTHON COMO CONTRIBUTO PARA AUXILIAR NO DIAGNÓSTICO ESCOLAR" busco não apenas enfrentar os desafios identificados, mas também contribuir para a comunidade educacional, compartilhando conhecimentos e práticas que possam inspirar colegas e melhorar a experiência de aprendizado para os alunos. Essa jornada é guiada por uma paixão incessante por encontrar soluções significativas e efetivas, combinando minha expertise em matemática com a inovação proporcionada pela lógica fuzzy. Este é um compromisso pessoal que reflete não apenas minha busca por aprimoramento profissional, mas também o desejo profundo de fazer uma diferença positiva no cenário educacional em que estou inserido.

## 2 Referencial Teórico

### 2.1 Fatores que influenciam no processo de aprendizagem

A educação desempenha um papel crucial no desenvolvimento de uma sociedade. Os documentos escolares propõem a formação de um sujeito crítico, criativo e colaborativo, capaz de trabalhar em grupo e agir com responsabilidade, sempre considerando o bem comum. No entanto, a realidade das práticas pedagógicas frequentemente não está alinhada com essa visão progressista.

Lück (2006) destaca que a tarefa escolar é especial e requer comprometimento com os resultados sociais. Não é suficiente ter apenas especialização na área de atuação; os profissionais da educação devem estar em constante transformação, repensando suas abordagens e métodos. [22]

Naisbit e Aburdene (1987 apud Lück, 2006) [22] observam um grande descompasso entre a educação e as necessidades da sociedade atual. Ainda estamos educando para uma sociedade industrial, focada na força de trabalho, em vez de desenvolver as competências e habilidades exigidas pela era da informação. Embora máquinas realizem tarefas, são as mentes criativas e colaborativas que as concebem.

Buchmann e Hannum (2001 apud Freitas; Sousa 2009) [23] apontam fatores cruciais para o sucesso educacional: escolaridade dos pais, renda familiar, infraestrutura da escola e atuação dos docentes. Esses elementos refletem a realidade da escola, a interação com a família e a singularidade de cada aluno.

Além disso, dimensões como a cognitiva, psicopedagógica, institucional e sociocultural também influenciam o desempenho dos estudantes. Quando um aluno fracassa, várias causas podem estar envolvidas, desde dificuldades pessoais até condições familiares adversas.

Para elevar o nível de conhecimento escolar, é essencial mobilizar todos os profissionais da educação, a comunidade local e os recursos disponíveis. Não devemos atribuir o fracasso escolar a um único fator, mas sim encarar os desafios como oportunidades de superação.

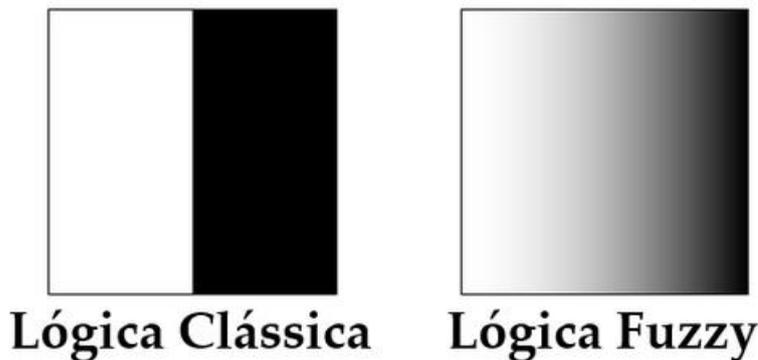
Uma educação que capacita o ser humano para o exercício da cidadania e o autocuidado contribui significativamente para reduzir as desigualdades sociais. É hora de abandonar visões conservadoras e abraçar o empreendedorismo na busca por uma educação transformadora.

## 2.2 Teoria da Lógica Fuzzy

### 2.2.1 Lógica Clássica X Lógica Fuzzy

As diferenças fundamentais entre a Lógica Clássica e a Lógica Fuzzy residem nas abordagens que cada uma delas adota para lidar com a incerteza e a imprecisão. Abaixo estão algumas das diferenças-chave:

Figura 1: Diagrama lógico



Fonte: <<https://photos.app.goo.gl/2fH44kLF1n3jH77X6>>

#### a) Natureza da Verdade:

**Lógica Clássica:** Utiliza uma lógica binária, na qual uma proposição é verdadeira (1) ou falsa (0). Não há meio-termo, e as fronteiras entre verdadeiro e falso são nítidas.

"A neve é branca."(Verdadeiro)

"Todos os pássaros voam."(Falso, pois existem pinguins que não voam)

" $2 + 2 = 4$ ."(Verdadeiro)

**Lógica Fuzzy:** Trabalha com graus de verdade (pertinência), permitindo que uma proposição tenha valores de verdade em uma escala contínua entre 0 e 1. Isso reflete a natureza gradual e não absoluta da informação.

"A água está quente."(Pode ser parcialmente verdade, dependendo da temperatura exata da água)

"João é alto."(Pode ser parcialmente verdade, dependendo da altura de João e da comparação com outras pessoas)

"O filme foi bom."(Opinião subjetiva que pode variar de acordo com o gosto individual, resultando em um valor de verdade fuzzy)

**b) Fronteiras de Conjuntos:**

Lógica Clássica: Os conjuntos têm fronteiras nítidas e os elementos pertencem completamente ou não pertencem a um conjunto.

Lógica Fuzzy: Os conjuntos difusos permitem a pertinência parcial dos elementos, onde um elemento pode pertencer ao conjunto em graus variados, expressos por valores de pertinência entre 0 e 1.

**c) Operações Lógicas:**

Lógica Clássica: As operações lógicas, como a conjunção (E) e a disjunção (OU), são operações binárias que resultam em valores absolutos de verdadeiro ou falso.

Lógica Fuzzy: As operações lógicas em lógica fuzzy são adaptadas para lidar com valores difusos. A conjunção e a disjunção, por exemplo, combinam graus de pertinência em vez de valores binários.

**d) Modelagem de Incerteza:**

Lógica Clássica: Assume um ambiente determinístico, onde as relações entre as proposições são precisas e previsíveis.

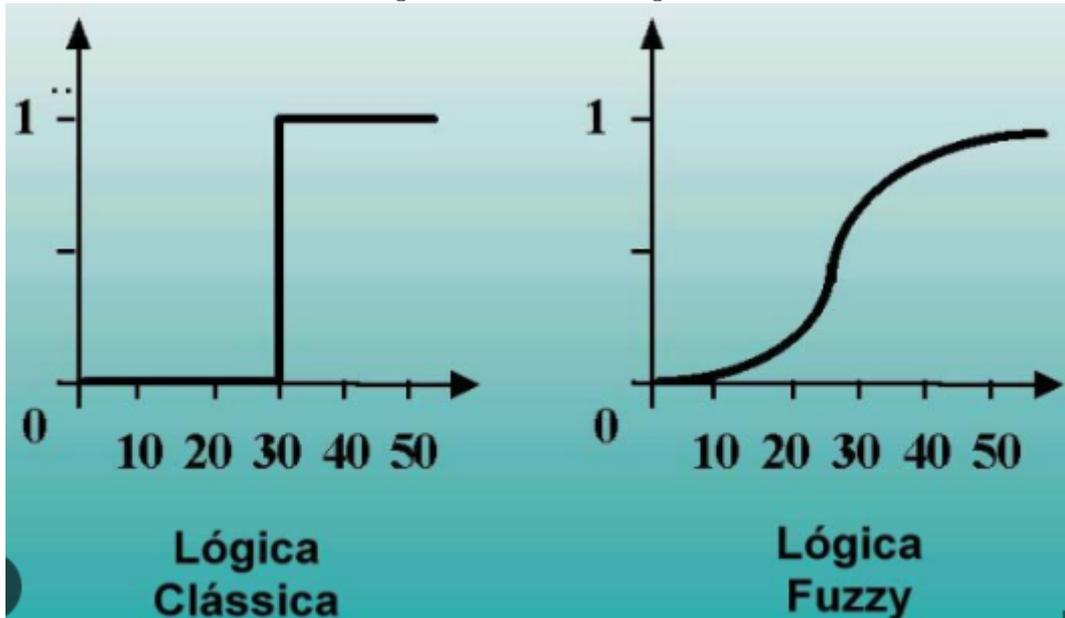
Lógica Fuzzy: Modela a incerteza e a imprecisão de forma mais realista, adequando-se melhor a ambientes onde as fronteiras entre as categorias não são claras.

**e) Aplicações:**

Lógica Clássica: Amplamente utilizada em contextos onde as relações lógicas são claras e precisas, como em muitas áreas da matemática e ciências exatas.

Lógica Fuzzy: Encontrou aplicações em situações onde a incerteza é inerente, como sistemas de controle, tomada de decisão e modelagem de sistemas complexos.

Figura 2: Gráficos lógicos



Fonte: <<https://photos.app.goo.gl/Yk8PJjBGb8VeEs3t6>>

### 2.2.2 Utilização da Lógica Fuzzy

Existem diversos campos em que aplicam a lógica fuzzy, como controle de sistemas, tomada de decisões, processamento de imagens e reconhecimento de padrões. Examina-se estudos de caso que ilustram como a lógica fuzzy pode ser eficaz na modelagem de sistemas complexos e na gestão de informações imprecisas. O foco está em quatro áreas específicas: controle de sistemas, tomada de decisões, processamento de imagens e reconhecimento de padrões [2].

#### a) Controle de Sistemas:

A Lógica Fuzzy desempenha um papel essencial em sistemas de controle complexos e variáveis. O trabalho seminal de Zadeh (1973) sobre Lógica Fuzzy no controle de processos é uma referência crucial nesse domínio. Sua abordagem flexível lida eficazmente com a incerteza, permitindo uma tomada de decisão robusta em ambientes sujeitos a variações. O legado de Zadeh inspira pesquisadores a explorar as potencialidades da Lógica Fuzzy para otimizar a eficiência em sistemas de controle, enfrentando a complexidade e variabilidade inerentes a diversos processos industriais e tecnológicos.

#### b) Tomada de Decisões:

Na tomada de decisões, a Lógica Fuzzy oferece uma abordagem flexível para lidar com informações imprecisas. Estudos como o de Mamdani e Assilian (1975) sobre sistemas de inferência fuzzy aplicados à tomada de decisões são cruciais para compreender as aplicações práticas dessa técnica.

**c) Processamento de Imagens:**

A Lógica Fuzzy demonstra seu valor no processamento de imagens, oferecendo uma ferramenta eficaz para lidar com a incerteza inerente à interpretação visual. O trabalho de Bezdek (1981) sobre segmentação de imagem através da Lógica Fuzzy é um marco significativo nesta disciplina, destacando a aplicabilidade e relevância dessa abordagem para a análise de imagens.

**d) Reconhecimento de Padrões:**

No domínio do reconhecimento de padrões, a Lógica Fuzzy emerge como uma ferramenta essencial para enfrentar a variabilidade e ambiguidade dos dados. A pesquisa de Jang (1993) sobre redes neurais fundamentadas em Lógica Fuzzy destaca-se como uma referência crucial nesse contexto, exemplificando o papel impactante dessa abordagem na melhoria da precisão e robustez dos sistemas de reconhecimento de padrões.

#### **e) Estudos de Caso:**

Além dessas referências fundamentais, examina-se estudos de caso específicos que demonstram como a Lógica Fuzzy pode ser eficaz na modelagem de sistemas complexos e na gestão de informações imprecisas em cada uma dessas áreas.

Ao abordar essas aplicações, busca-se não apenas destacar os sucessos da Lógica Fuzzy, mas também compreender as limitações e desafios encontrados em diferentes contextos, proporcionando uma visão abrangente sobre o estado atual e as perspectivas futuras dessas aplicações [1].

### **2.2.3 Desenvolvimentos recentes da Lógica Fuzzy**

A pesquisa concentra-se na investigação dos desenvolvimentos mais recentes na teoria da Lógica Fuzzy, com uma análise detalhada das extensões e generalizações que ampliam sua aplicabilidade. Além disso, explora-se as pesquisas em andamento e as fronteiras do conhecimento nesta área dinâmica, proporcionando uma visão abrangente do estado atual e das tendências emergentes.

#### **a) Extensões e Generalizações:**

Explora-se avanços recentes na teoria da Lógica Fuzzy, abrangendo extensões significativas, tais como a Lógica Fuzzy intervalar, a Lógica Fuzzy para-valued e a Lógica Fuzzy multivalorada. Destaca-se contribuições notáveis, incluindo as pesquisas pioneiras de Dubois e Prade (2015), que propuseram generalizações inovadoras de conjuntos difusos para-valued, ampliando assim as capacidades de modelagem. Este exame aprofundado destas extensões da Lógica Fuzzy reflete a constante evolução desta área, promovendo uma compreensão mais abrangente e sofisticada de sua aplicabilidade em diversos contextos.

#### **b) Aplicabilidade Ampliada:**

Investiga-se minuciosamente o impacto significativo que essas extensões e generalizações têm exercido na expansão da aplicabilidade da Lógica Fuzzy em uma variedade de domínios, desde sistemas complexos até áreas emergentes, como a Internet das Coisas (IoT). Contribuições notáveis, exemplificadas pelo estudo seminal de Mendel (2007) sobre Lógica Fuzzy tipo-2, desempenham um papel fundamental na compreensão das novas fronteiras de aplicação. Este aprofundamento na interseção entre Lógica Fuzzy avançada e domínios inovadores destaca a natureza dinâmica e progressiva desta disciplina, fortalecendo sua relevância em face dos desafios contemporâneos.

### c) Pesquisas em Andamento:

Enfatiza-se investigações em curso que exploram áreas como Lógica Fuzzy adaptativa, aprendizado de máquina fundamentado em Lógica Fuzzy e a integração estratégica da Lógica Fuzzy com outras abordagens, notadamente redes neurais. Referências contemporâneas, exemplificadas por contribuições significativas de autores como Wang e Li (2021), oferecem insights preciosos nesse contexto dinâmico. Esta análise atenta do panorama atual destaca o dinamismo e a interconexão crescente entre a Lógica Fuzzy e abordagens complementares, revelando oportunidades promissoras para avanços significativos em diversas áreas de pesquisa.

### d) Fronteiras do Conhecimento:

No encerramento, dirige-se o foco para as fronteiras do conhecimento na teoria da Lógica Fuzzy, explorando questões ainda não resolvidas e desafios que se apresentam como horizontes emergentes. Autores proeminentes, a exemplo de Klir (2019), contribuem significativamente para essa discussão ao abordar temas avançados na teoria da Lógica Fuzzy, proporcionando uma base sólida para a compreensão de intrincadas questões não resolvidas.

Este capítulo visa proporcionar uma visão abrangente dos mais recentes avanços na teoria da Lógica Fuzzy, não só destacando os progressos já consolidados, mas também ressaltando as oportunidades e desafios que moldam o atual panorama desta área de pesquisa dinâmica. Ao fazê-lo, busca-se fomentar uma apreciação mais profunda não apenas da evolução já alcançada, mas também dos caminhos futuros e das potenciais contribuições que podem surgir nesse campo dinâmico e em constante expansão.

### e) Aplicabilidade:

As aplicações da Lógica Fuzzy são diversas e abrangem várias áreas. Algumas das principais aplicações incluem:

**Controle de Processos:** Em sistemas industriais, a Lógica Fuzzy é usada para otimizar o controle de variáveis em processos complexos, adaptando-se a mudanças e incertezas.

**Sistemas de Tomada de Decisão:** Em ambientes onde as decisões são baseadas em informações vagas ou imprecisas, como em diagnósticos médicos, a Lógica Fuzzy é empregada para modelar a incerteza e a subjetividade.

**Automóveis e Transporte:** Em sistemas de controle de tráfego, direção autônoma e otimização de rotas, a Lógica Fuzzy ajuda a lidar com a imprecisão inerente às condições de tráfego.

**Eletrodomésticos Inteligentes:** Em eletrodomésticos como máquinas de lavar e condicionadores de ar, a Lógica Fuzzy é utilizada para ajustar automaticamente os parâmetros de operação com base nas condições ambientais e na preferência do usuário.

**Sistemas de Recomendação:** Em ambientes online, a Lógica Fuzzy pode ser aplicada para personalizar recomendações de produtos, serviços ou conteúdo, levando em consideração preferências vagas dos usuários.

**Finanças:** Na modelagem de riscos e na avaliação de investimentos, a Lógica Fuzzy pode lidar com a incerteza associada a fatores econômicos e mercadológicos.

**Medicina e Diagnóstico:** Em sistemas de apoio à decisão médica, a Lógica Fuzzy é empregada para analisar sintomas e resultados de exames, considerando a natureza imprecisa das informações médicas.

Essas aplicações destacam a notável capacidade da Lógica Fuzzy em lidar de maneira eficiente com a incerteza e imprecisão que caracterizam uma ampla gama de cenários do mundo real. A Lógica Fuzzy oferece uma abordagem flexível e adaptável que se revela especialmente valiosa ao enfrentar situações onde a clareza e precisão são desafiantes.

Em contextos onde a complexidade inerente é pronunciada, a Lógica Fuzzy se destaca por sua habilidade singular de modelar e interpretar nuances. Sua capacidade de lidar com conceitos vagos e imprecisos permite uma representação mais fiel da realidade, proporcionando uma visão mais completa e contextualizada em muitos cenários práticos. Dessa forma, a Lógica Fuzzy emerge como uma ferramenta essencial para a compreensão e tomada de decisões em ambientes onde a precisão absoluta é difícil de alcançar.

## 2.2.4 Desafios da Lógica Fuzzy

Aborda-se os desafios e críticas à Lógica Fuzzy, reconhecendo suas limitações e explorando possíveis direções para futuras pesquisas. Discuti-se também as implicações éticas e sociais relacionadas ao uso da Lógica Fuzzy em contextos decisórios. Concentramo-nos na análise crítica da Lógica Fuzzy, abordando desafios e limitações identificadas ao longo de seu desenvolvimento. Reconhecer a importância de compreender as fronteiras da eficácia da Lógica Fuzzy e explora-se possíveis direções para futuras pesquisas. Além disso, discuti-se as implicações éticas e sociais associadas ao uso da Lógica Fuzzy em contextos decisórios.

### a) Desafios e Limitações:

Examina-se de forma crítica os desafios enfrentados pela Lógica Fuzzy, incluindo questões relacionadas à interpretabilidade dos modelos, robustez em cenários dinâmicos e a necessidade de métodos aprimorados de aprendizado em sistemas difusos. Trabalhos como o de Coupland et al. (2003) proporcionam uma maior capacidade de lidar com incertezas e imprecisões de maneira mais adaptável e eficaz. [17].

### b) Direções para Futuras Pesquisas:

Propomos possíveis direções para pesquisas futuras, destacando áreas como a integração de Lógica Fuzzy com abordagens de aprendizado de máquina mais avançadas, o desenvolvimento de métodos aprimorados de interpretabilidade e a exploração de aplicações específicas em setores emergentes. A obra de Lee, Lee e Park (2015) fornece uma perspectiva sobre a integração de Lógica Fuzzy com redes neurais. [21]

### c) Implicações Éticas e Sociais:

Discuti-se as implicações éticas e sociais do uso da Lógica Fuzzy em decisões, destacando preocupações cruciais sobre transparência, preconceitos algorítmicos e responsabilidade. A relevância do trabalho de Mittelstadt et al. (2016) é evidente na compreensão das complexidades éticas relacionadas à tomada de decisões automatizada. Este capítulo visa oferecer uma visão equilibrada e reflexiva da Lógica Fuzzy, reconhecendo não apenas suas vantagens, mas também enfrentando abertamente os desafios e questões éticas associadas ao seu uso em decisões. [20].

Em síntese, esta dissertação proporciona uma jornada abrangente pela Lógica Fuzzy, abordando desde seus fundamentos teóricos até suas aplicações práticas e os desafios emergentes. Ao longo dos capítulos, explora-se os princípios fundamentais da Lógica Fuzzy, suas aplicações em diversos campos, os desenvolvimentos recentes na teoria e discuti-se criticamente os desafios e questões éticas associadas. O objetivo deste trabalho é contribuir para uma compreensão mais profunda e contextualizada do

papel da Lógica Fuzzy na tomada de decisões e suas implicações mais amplas na sociedade contemporânea.

**d) Contribuições Significativas:**

Ao explorar os princípios fundamentais da Lógica Fuzzy, almeja-se não apenas proporcionar uma compreensão sólida, mas também examinar sua capacidade de adaptação e expansão em direção a novas fronteiras, ampliando, assim, sua aplicabilidade em sistemas complexos. Os estudos de caso e as aplicações práticas destacam de maneira concreta seu impacto significativo em áreas como controle de sistemas, tomada de decisões, processamento de imagens e reconhecimento de padrões. Este enfoque abrangente não só solidifica a base teórica da Lógica Fuzzy, mas também realça sua eficácia tangível em resolver desafios práticos em uma variedade de domínios.

**e) Perspectivas Futuras:**

Destacando a importância contínua da Lógica Fuzzy na resolução de desafios do mundo real e no avanço do conhecimento matemático, é crucial reconhecer suas limitações. No entanto, esses obstáculos não diminuem sua utilidade; pelo contrário, evidenciam a necessidade de uma agenda de pesquisa contínua para aprimorar e adaptar essa ferramenta. Este encerramento ressalta o papel vital da Lógica Fuzzy como uma abordagem flexível e valiosa. Apesar de suas imperfeições, continua a ser uma peça significativa na resolução de problemas práticos e na expansão das fronteiras do entendimento matemático.

**f) Convite à Reflexão:**

Em última análise, esta dissertação convida os leitores a contemplarem o papel da Lógica Fuzzy no cenário atual e futuro, ressaltando sua importância na construção de soluções flexíveis para desafios complexos. Ao explorar suas nuances teóricas, aplicações práticas e questões éticas, aspira-se contribuir para uma compreensão abrangente e informada desta área dinâmica da ciência da computação e da matemática aplicada. Ao fazê-lo, espera-se promover uma apreciação mais profunda do potencial da Lógica Fuzzy e sua contínua relevância na resolução de problemas do mundo real e na evolução do conhecimento científico.

### 2.2.5 Aplicações da Lógica Fuzzy

**Sistemas de Controle Fuzzy:** A Lógica Fuzzy é frequentemente utilizada em sistemas de controle para lidar com sistemas complexos e imprecisos. Sistemas de controle fuzzy podem ser mais flexíveis e adaptativos em comparação com sistemas de controle tradicionais.

**Raciocínio Fuzzy:** Em sistemas de suporte à decisão e raciocínio, a Lógica Fuzzy é empregada para modelar a incerteza associada às informações disponíveis. Isso é particularmente útil em casos em que as fronteiras entre classes ou conceitos não são claramente definidas.

**Sistemas de Inferência Fuzzy:** A inferência fuzzy é um componente crucial em muitos sistemas baseados em Lógica Fuzzy. Ela lida com regras imprecisas e incertas para fazer deduções ou previsões.

**Sistemas Especialistas Fuzzy:** Em sistemas especialistas, a Lógica Fuzzy pode ser usada para representar o conhecimento impreciso de especialistas humanos. Essa abordagem pode ajudar a capturar e modelar o raciocínio humano mais eficazmente em ambientes incertos.

**Processamento de Linguagem Natural Fuzzy:** Em aplicações de processamento de linguagem natural, a Lógica Fuzzy pode ser empregada para lidar com a ambiguidade e a imprecisão frequentes na linguagem humana. Isso pode melhorar a capacidade de compreensão e resposta de sistemas de inteligência artificial (IA) em contextos linguísticos complexos.

**Sistemas de Recomendação Fuzzy:** Em sistemas de recomendação, a lógica fuzzy pode ser usada para modelar preferências imprecisas e subjetivas dos usuários, levando a recomendações mais personalizadas.

**Aplicações em Visão Computacional:** Em algumas tarefas de visão computacional, como segmentação de imagem e reconhecimento de padrões, a lógica fuzzy pode ser aplicada para lidar com variações e imprecisões nas características visuais.

**Controle de Robôs:** A lógica fuzzy é frequentemente utilizada no controle de robôs para lidar com a imprecisão nas informações sensoriais e para permitir que os robôs tomem decisões adaptativas em ambientes dinâmicos [3].

A Lógica Fuzzy tem sido aplicada de forma significativa no contexto educacional, especialmente na análise e melhoria do rendimento escolar dos alunos. Esta abordagem permite lidar com a incerteza e a imprecisão dos dados, capturando a complexidade das interações entre diferentes variáveis que afetam o desempenho acadêmico. Aqui estão alguns pontos claros sobre como a Lógica Fuzzy é aplicada no rendimento escolar:

**Modelagem da Avaliação:** A Lógica Fuzzy pode ser utilizada para modelar sistemas de avaliação escolar, levando em consideração múltiplos critérios e suas ponderações. Em vez de avaliações binárias (aprovado/reprovado), a Lógica Fuzzy permite uma abordagem mais granular, onde os alunos podem ser avaliados em diferentes níveis de desempenho.

**Análise de Desempenho:** Ao analisar o desempenho dos alunos em diversas disciplinas e áreas, a Lógica Fuzzy pode considerar variáveis como frequência escolar, notas em provas, trabalhos e participação em atividades extracurriculares. Essa análise multifacetada permite uma compreensão mais completa do rendimento escolar de cada aluno.

**Identificação de Padrões:** Através de algoritmos fuzzy, é possível identificar padrões e tendências no desempenho dos alunos ao longo do tempo. Isso pode ajudar educadores a detectar precocemente problemas acadêmicos e implementar intervenções personalizadas para apoiar os alunos que estão enfrentando dificuldades.

**Personalização do Ensino:** Com base nos resultados da análise fuzzy, os educadores podem adaptar suas abordagens de ensino para atender às necessidades individuais dos alunos. Isso pode incluir a oferta de atividades de reforço, tutoria personalizada ou materiais educacionais adaptados.

**Previsão de Rendimento Futuro:** Utilizando técnicas de modelagem fuzzy, é possível prever o rendimento futuro dos alunos com base em seu histórico acadêmico e outros fatores relevantes. Essas previsões podem ser úteis para orientar o planejamento educacional e desenvolver estratégias de intervenção preventiva.

Em resumo, a aplicação da Lógica Fuzzy no rendimento escolar permite uma análise mais abrangente e personalizada do desempenho dos alunos, contribuindo para a identificação precoce de problemas, a personalização do ensino e o desenvolvimento de estratégias eficazes de apoio educacional.

## Exemplos Práticos da Lógica Fuzzy

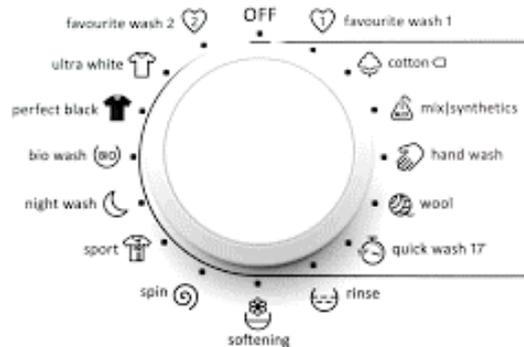
Na imagem de uma máquina de lavar roupa, é possível incluir controladores fuzzy para gerenciar o peso das roupas. Estes controladores levam em conta não só o peso, mas também o tipo de tecido e os níveis de sujeira detectados pelos sensores. Com base nessas informações, a máquina de lavar pode automaticamente determinar os ciclos de lavagem mais adequados. Essa automação permite otimizar o uso de energia, água e detergente, reduzindo significativamente o desperdício desses recursos.

Figura 3: Máquina de lavar



Fonte: <<https://photos.app.goo.gl/8hvX1ujHcDNp4q2t8>>

Figura 4: Controles Fuzzy



Fonte: <<https://photos.app.goo.gl/HiiULrDh2bSt7B4t7>>

Tem-se um exemplo clássico: a representação de um ar-condicionado que incorpora diretrizes para resfriamento e aquecimento. Ao aquecer de maneira mais eficiente, como, por exemplo, cinco vezes mais rápido, é possível diminuir tanto o consumo quanto a potência do dispositivo. Sensores instalados captam a temperatura interna do ambiente e aplicam ajustes automáticos, visando a automação do ajuste de temperatura.

Figura 5: Condicionador de ar



Fonte: <<https://photos.app.goo.gl/vf7a1YXo2MoetZp99>>

Figura 6: Controle fuzzy

	Modo refrigeração
	Modo aquecimento (disponível apenas nos modelos quente / frio)
	Modo automático (disponível apenas nos modelos quente / frio)
	Modo desumidificação
	Modo ventilação

Fonte: <<https://photos.app.goo.gl/84jZ1jRpyZ3xrBMT9>>

Um exemplo adicional refere-se aos aspiradores de pó com capacidade para utilizar controladores de fase, a fim de ajustar a potência de sucção. Esse ajuste é realizado com base na natureza da superfície a ser limpa e no tipo de sujeira presente. A potência de sucção pode ser configurada automaticamente, adaptando-se, por exemplo, à quantidade de sujeira em uma superfície específica. Em situações em que a sujeira é mínima, é possível ativar a potência máxima, mas frequentemente a potência mínima é suficiente para realizar uma limpeza eficaz. Ao utilizar o controlador de fuzzy, este é capaz de analisar as características do ambiente e ajustar automaticamente a potência de sucção conforme necessário. Esse processo não apenas proporciona uma limpeza eficiente, mas também resulta em economia no consumo de energia do equipamento. Posteriormente, explorara-se uma simulação desse cenário específico envolvendo o aspirador de pó.

Logo na sequência, tem-se as câmeras fotográficas que podem utilizar o recurso de alto foco para emitir a clareza da imagem em regiões de visão, usando a informação obtida para determinar se a Câmera está no foco correto. Também pode ser utilizada a Lógica Fuzzy nesse tipo de dispositivo.

Figura 7: Aspirador de pó



Fonte: <<https://photos.app.goo.gl/dQcJKqKqkALb3ANeA>>

Outro exemplo interessante é o micro-ondas, que pode ser gerenciado por meio de Lógica Fuzzy. Esse sistema é capaz de medir a temperatura e determinar se um alimento requer mais ou menos potência para o processo de descongelamento, por exemplo. Esse exemplo ilustra a aplicação da automação residencial, em que todos esses dispositivos podem ser controlados utilizando Lógica Fuzzy.

Figura 8: Microondas



Fonte: <<https://photos.app.goo.gl/dQcJKqKqkALb3ANeA>>

A Lógica Fuzzy tem diversas aplicações na inteligência artificial (IA), principalmente em situações em que a incerteza e a imprecisão desempenham um papel importante.

### **Áreas de Aplicação da Lógica Fuzzy na Inteligência Artificial (IA)**

A Lógica Fuzzy se destaca como uma ferramenta eficaz na Inteligência Artificial (IA), devido à sua capacidade de lidar com a incerteza e a imprecisão presentes em diversos problemas do mundo real. Sua versatilidade a torna aplicável em uma ampla gama de áreas, como:

#### **1. Sistemas de Controle:**

Controle de processos: A Lógica Fuzzy é utilizada para controlar processos dinâmicos complexos, como sistemas de manufatura, robótica e plantas químicas. Sua capacidade

de lidar com variáveis imprecisas e mutáveis a torna ideal para este tipo de aplicação.

Sistemas de suporte à decisão: A Lógica Fuzzy auxilia na tomada de decisões em cenários com informações incompletas ou incertas. É utilizada em diversos sistemas, como sistemas de diagnóstico médico, sistemas financeiros e sistemas de controle de tráfego.

## **2. Robótica:**

Controle de movimento: A Lógica Fuzzy é aplicada no controle de movimento de robôs, permitindo movimentos mais precisos e naturais, adaptando-se a diferentes condições do ambiente.

Sistemas de visão computacional: A Lógica Fuzzy é utilizada para interpretar imagens e vídeos em ambientes com pouca iluminação ou ruídos, permitindo que robôs percebam o mundo de forma mais robusta.

## **3. Processamento de Linguagem Natural:**

Análise de sentimento: A Lógica Fuzzy é utilizada para analisar o sentimento de textos e discursos, identificando emoções e opiniões.

Sistemas de tradução automática: A Lógica Fuzzy auxilia na tradução de idiomas, considerando as nuances e ambiguidades da linguagem natural.

## **4. Sistemas de Especialistas:**

Diagnóstico médico: A Lógica Fuzzy é utilizada em sistemas de diagnóstico médico para auxiliar na identificação de doenças, considerando diversos sintomas e fatores de risco.

Sistemas de mineração de dados: A Lógica Fuzzy é aplicada na mineração de dados para extrair informações valiosas de grandes conjuntos de dados, mesmo com dados incompletos ou inconsistentes.

## **5. Outras Áreas:**

Finanças: A Lógica Fuzzy é utilizada para análise de risco, previsão de mercado e desenvolvimento de sistemas de trading.

Automação industrial: A Lógica Fuzzy é aplicada em sistemas de automação industrial para controlar e otimizar processos de produção.

Jogos: A Lógica Fuzzy é utilizada para criar personagens e ambientes mais realistas em jogos, permitindo que os personagens tomem decisões e interajam com o mundo de forma mais natural.

### 2.2.6 Conjuntos Fuzzy

Na teoria clássica dos conjuntos, a relação entre um elemento e um conjunto é definida de maneira binária: o elemento pertence ou não ao conjunto. Em um contexto mais amplo, considera-se um universo  $\Omega$  e um conjunto  $A$ , no qual  $A$  é um subconjunto de  $\Omega$ .

O grau de pertinência de um elemento específico  $x$  ao conjunto  $A$  é quantificado pela função  $\mu_A(x)$ . Essa função atribui um valor numérico no intervalo  $[0, 1]$ , indicando em que medida o elemento  $x$  faz parte do conjunto  $A$  dentro do universo  $\Omega$ . Este conceito de grau de pertinência na teoria dos conjuntos fuzzy permite uma representação mais flexível e gradativa da associação entre elementos e conjuntos, superando a rigidez da abordagem binária da teoria clássica dos conjuntos [8].

Dessa forma, a função  $\mu_A(x)$  proporciona uma medida contínua do grau de associação entre um elemento e um conjunto, permitindo uma abordagem mais flexível e refinada em comparação com a visão clássica dos conjuntos, que é restrita à pertinência ou não pertinência.

$$\mu_A(x) = \begin{cases} 1, & \text{se } x \in A, \\ 0, & \text{se } x \notin A. \end{cases} \quad (1)$$

A função  $\mu_A(x) : \Omega \rightarrow [0, 1]$  é denominada função característica no contexto da teoria clássica dos conjuntos. Nesse contexto, o grau de pertinência pode assumir qualquer valor real no intervalo de 0 a 1. Aqui, 0 representa a exclusão completa do elemento do conjunto, enquanto 1 denota uma pertinência total. Considere  $\Omega$  como uma coleção de objetos, que denomina-se universo do discurso. Este universo pode ser contínuo ou discreto, dependendo da natureza dos objetos em questão. Essa ampliação conceitual na teoria dos conjuntos Fuzzy permite uma representação mais flexível e realista das relações entre elementos e conjuntos, superando as limitações da abordagem clássica de pertinência ou não pertinência.

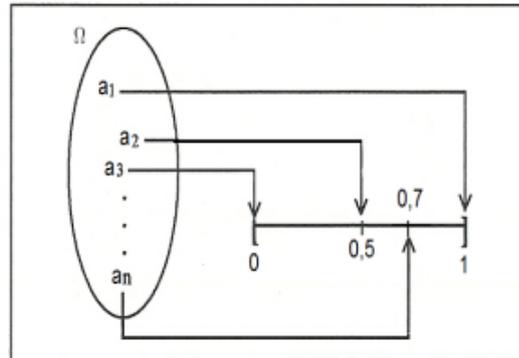
**Definição 1.1.** Um conjunto Fuzzy  $A$  contido em um universo de discurso  $\Omega$  é definido por uma função  $\mu_A(x)$  que assume valores no intervalo  $[0, 1]$ , isto é,

$$\mu_A(x) : \Omega \rightarrow [0, 1].$$

A função  $\mu_A(x)$  é conhecida como função de pertinência na teoria dos conjuntos Fuzzy. Os elementos que compõem o conjunto imagem dessa função são referidos como graus de pertinência. Essa terminologia reflete a capacidade da teoria dos conjuntos Fuzzy de quantificar e expressar o grau de associação de um elemento específico com um conjunto, indo além da dicotomia tradicional de pertinência ou não pertinência. Dessa forma, a função de pertinência atribui valores contínuos no intervalo  $[0, 1]$ , proporcionando uma

representação mais refinada e flexível das relações entre elementos e conjuntos.

Figura 9: Diagrama de relação entre elementos e conjuntos



Fonte: <<https://photos.app.goo.gl/AwNdQpm7jgBXRf8i9>>

Denota-se o conjunto Fuzzy A através de pares ordenados

$$A = \{(a, \mu_A(a)) \mid a \in \Omega\}$$

O suporte de um conjunto Fuzzy  $A$  é definido como o subconjunto de  $\Omega$  que inclui todos os elementos  $x$  de  $\Omega$  para os quais  $\mu_A(x) > 0$ . Em outras palavras, o suporte é formado pelos elementos que têm um grau de pertinência maior que zero no contexto do conjunto Fuzzy  $A$ .

Quando o suporte de um conjunto Fuzzy possui apenas um elemento  $a$  de  $\Omega$  com  $\mu_A(a) = 1$ , esse conjunto é denominado conjunto unitário Fuzzy. Nesse caso, o grau de pertinência máximo de 1 indica que o elemento  $a$  tem uma associação completa com o conjunto Fuzzy  $A$ , ressaltando uma relação de pertinência total. Essa característica específica do conjunto unitário Fuzzy é relevante para situações em que há um único elemento com pertinência máxima ao conjunto.

Os conjuntos Fuzzy possuem uma característica distintiva: a capacidade de representar conceitos imprecisos. Conforme definido, esses conjuntos são uma generalização dos conjuntos clássicos, que tradicionalmente atribuem valores binários, 0 ou 1, a cada elemento do conjunto universo. A novidade dos conjuntos Fuzzy reside na sua habilidade de expressar graus variados de pertinência, proporcionando uma representação mais flexível e realista de conceitos que não se encaixam estritamente nas categorias de pertencimento ou não pertencimento.

O grau de pertinência de um elemento do conjunto universo em relação a um conjunto Fuzzy reflete o quanto esse elemento se ajusta ao conceito representado por esse conjunto Fuzzy. Se  $A$  é um conjunto Fuzzy, sua função de pertinência pode ser denotada por  $A(x)$ . Notavelmente, o símbolo que representa o conjunto é o mesmo que simboliza sua função de pertinência, enfatizando a estreita relação entre a concepção do conjunto Fuzzy e a

medida contínua do grau de pertinência associado a cada elemento do universo. Essa abordagem mais flexível permite uma modelagem mais precisa de situações em que as fronteiras conceituais não são nitidamente definidas.

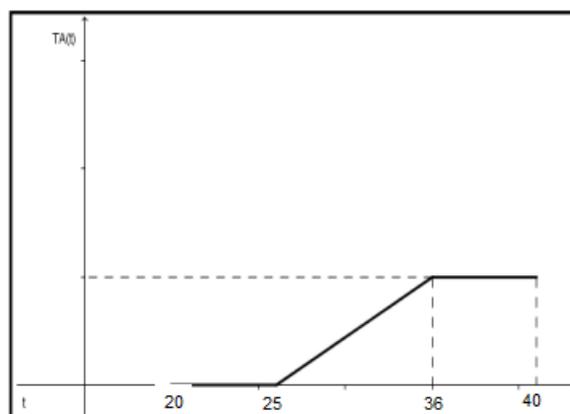
### 2.2.7 Representação da função de pertinência

A função de pertinência define completamente o conjunto Fuzzy e pode ser representada das seguintes formas:

#### Representação Gráfica

A representação gráfica da função de pertinência é uma ferramenta visual que proporciona uma compreensão geométrica da distribuição de pertinência ao longo do universo do discurso. Esse tipo de representação é particularmente útil em domínios cujo universo do discurso é o espaço euclidiano ou bidimensional. Considere, por exemplo, a representação do conceito de "temperatura alta" na cidade de Teresina Piauí, onde a temperatura varia no intervalo  $T = [25,40]$  em graus Celsius, por meio de um conjunto Fuzzy TA. No contexto desse exemplo, o valor de temperatura  $20^{\circ}\text{C}$  não é considerado como temperatura alta, resultando em um grau de pertinência zero para esse valor. Em contraste, temperaturas a partir de  $36^{\circ}\text{C}$  são consideradas altas, apresentando um grau de pertinência de 1. Portanto, uma representação gráfica da função de pertinência para o conjunto Fuzzy TA pode ser visualizada no gráfico contido na figura abaixo, oferecendo uma visão clara da evolução do grau de pertinência ao longo do intervalo de temperaturas considerado.

Figura 10: Representação gráfica



Fonte: <<https://photos.app.goo.gl/KPJF9uLpR9jfJbMr9>>

## **Representação por tabela ou lista.**

A representação da função de pertinência por tabela ou lista é uma abordagem que descreve como os conjuntos fuzzy atribuem graus de pertinência a diferentes valores de entrada. A função de pertinência é fundamental em lógica fuzzy, pois ela define a medida em que um elemento pertence a um conjunto fuzzy.

A representação através de tabela ou lista é uma forma tabular de expressar essas relações entre valores de entrada e os graus de pertinência correspondentes. Geralmente, uma tabela ou lista contém pares ordenados, onde o primeiro componente é o valor de entrada e o segundo componente é o grau de pertinência associado. Aqui estão alguns pontos importantes sobre essa representação:

### **Valores de Entrada e Graus de Pertinência:**

Cada linha na tabela ou item na lista representa um ponto no espaço de entrada e seu grau de pertinência associado. Os valores de entrada podem ser discretos ou contínuos, dependendo da aplicação.

### **Mapeamento de Valores:**

A tabela ou lista mapeia valores de entrada para graus de pertinência, indicando quão fortemente um valor pertence a um conjunto fuzzy específico.

### **Interpolação:**

Em muitos casos, a interpolação é utilizada para inferir graus de pertinência para valores que não estão explicitamente listados na tabela. Isso é especialmente útil para valores de entrada contínuos.

### **Facilidade de Interpretação:**

A representação por tabela ou lista é geralmente fácil de interpretar e entender, o que é uma vantagem em muitas situações práticas.

### **Limitações:**

Para conjuntos fuzzy com valores de entrada contínuos, a tabela ou lista pode se tornar impraticável devido à necessidade de incluir uma quantidade infinita de pontos.

### Aplicações:

Essa representação é comumente usada em sistemas fuzzy para modelar relações de pertinência em domínios específicos, como controle fuzzy, tomada de decisões fuzzy, etc. Aqui está um exemplo hipotético de como essa representação pode parecer:

Valor de Entrada	Grau de Pertinência
3.5	0.8
6.0	0.5
8.2	0.2

### Representação analítica.

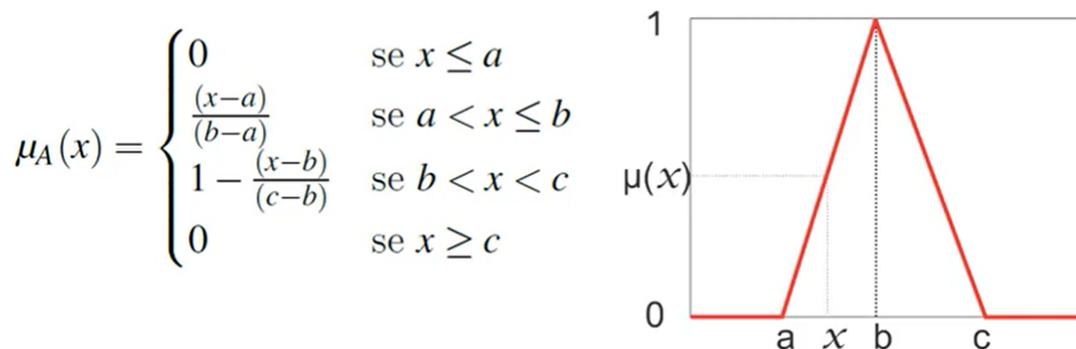
Nas situações em que o conjunto Fuzzy é definido em um universo infinito, a representação analítica é a mais conveniente, pois nesse tipo de representação todos os elementos do conjunto e seus respectivos graus de pertinência ficam relacionados por meio de uma fórmula, que juntamente com o domínio e o contradomínio escolhidos compõem a função de pertinência.

#### Principais tipos de funções analíticas

A forma analítica das funções de pertinência pode assumir diversos formatos, as formas mais utilizadas são as triangulares e trapezoidais.

**Função triangular:** Uma função triangular é caracterizada por três parâmetros de ajuste, geralmente denotados como  $a$ ,  $b$  e  $c$ , e é definida por uma equação que descreve sua forma triangular, como ilustrado na figura abaixo.

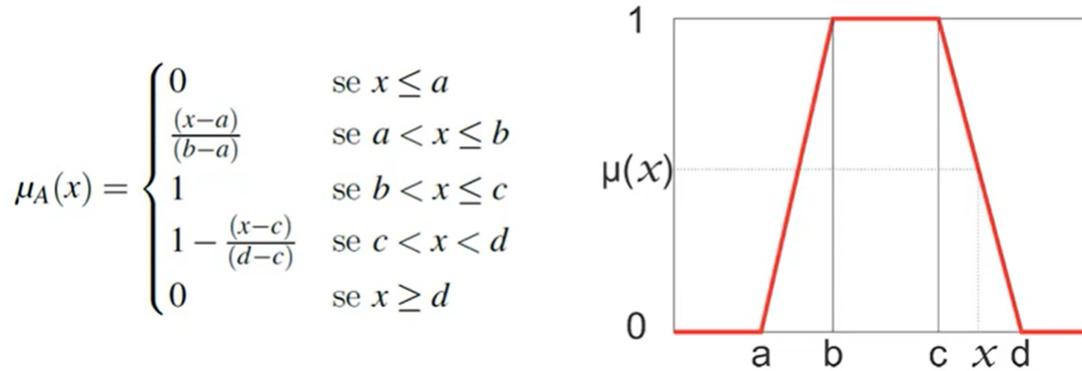
Figura 11: Gráfico Função Triangular



Fonte: <<https://photos.app.goo.gl/8XuT9WwVcB8oJSis9>>

**Função trapezoidal:** Uma função trapezoidal é caracterizada por quatro parâmetros de ajuste, geralmente denotados como a,b,c e d, e é definida por uma equação que descreve sua forma trapezoidal, conforme ilustrado na figura abaixo.

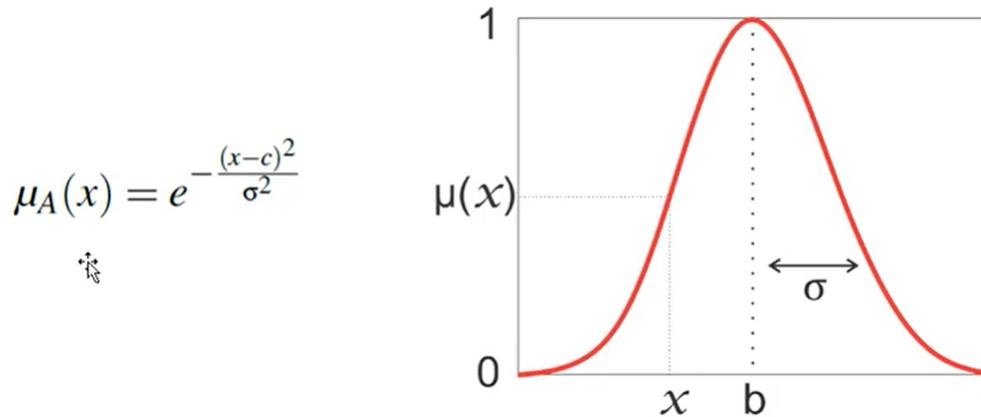
Figura 12: Gráfico Função Trapezoidal



Fonte: <<https://photos.app.goo.gl/21obhZMymBrPG8Fx6>>

**Função Gaussiana:** Possui dois parâmetros de ajuste e é definida pela equação a seguir assim como na figura:

Figura 13: Gráfico Função Gaussiana

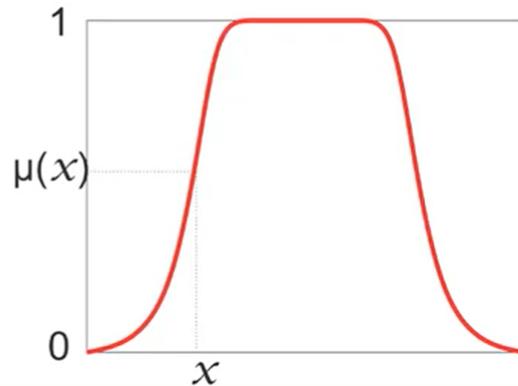


Fonte: <<https://photos.app.goo.gl/x5qdHoMs9W5uk1Q47>>

**Função Sino generalizada:** possui três parâmetros de ajuste e é definida pela equação a seguir assim como a figura

Figura 14: Gráfico Função Sino Generalizada

$$\mu_A(x) = \frac{1}{1 + \left|\frac{x-c}{a}\right|^{2b}}$$



Fonte: <<https://photos.app.goo.gl/QntNoHc7PhAT1xDi8>>

Alguns passos práticos podem ser tomados para a definição dessas funções:

- a) Geralmente, o número de funções de pertinência varia entre 2 e 7. Quanto maior o número de conjuntos, maior também será a demanda computacional.
- b) Os formatos de triângulos e trapezóides são os mais frequentemente encontrados e resultam em menores custos computacionais.
- c) No entanto, funções do tipo gaussiana e sino generalizada podem resultar em desempenho detalhado.
- d) O grau de superposição de funções entre as funções de pertinência afeta a precisão. A propriedade inerente de interpolação de Lógica Fuzzy se dá em parte à superposição entre as funções de pertinência.

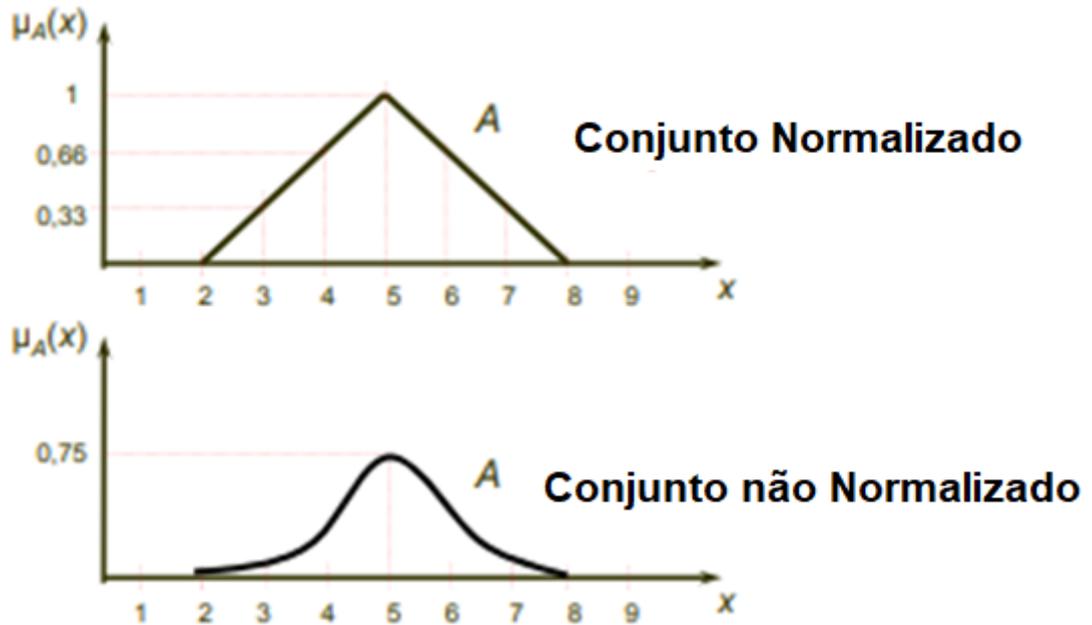
## 2.2.8 Definições da Lógica Fuzzy

### Conjunto Fuzzy Normalizado

Um conjunto fuzzy  $A$  é normalizado se pelo menos um de seus elementos possui grau de pertinência igual a 1, ou seja,  $\mu_A(x_i) = 1$  [4].

Exemplificando, têm-se:

Figura 15: Normalização



Fonte: <<https://photos.app.goo.gl/QntNoHc7PhAT1xDi8>>

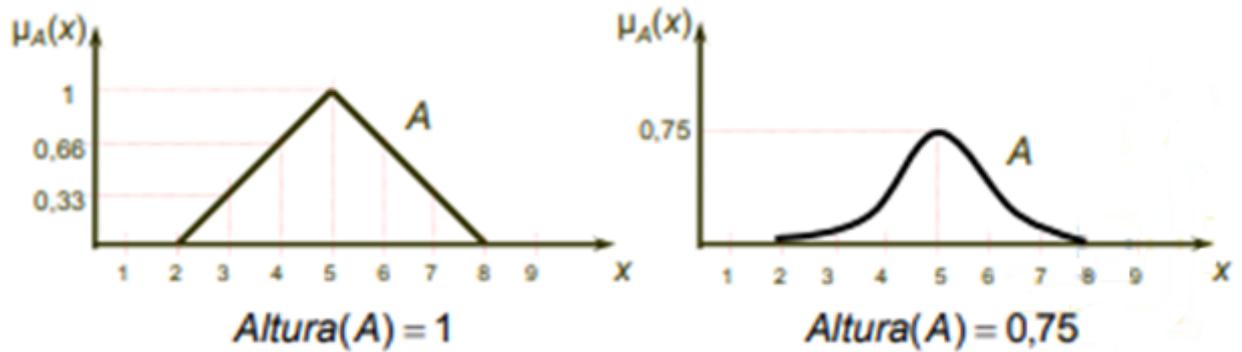
### Altura de Conjunto Fuzzy

A altura de um conjunto Fuzzy  $A$  corresponde ao maior grau de pertinência assumido por um de seus elementos, isto é:  $Altura(A) = \max \mu_A(x_i)$ , sendo  $x_i \in x$

Um conjunto  $A$  não normalizado pode ser normalizado por meio da seguinte relação:

$$A_{normal} = \frac{A}{altura(A)}$$

Figura 16: Normalização



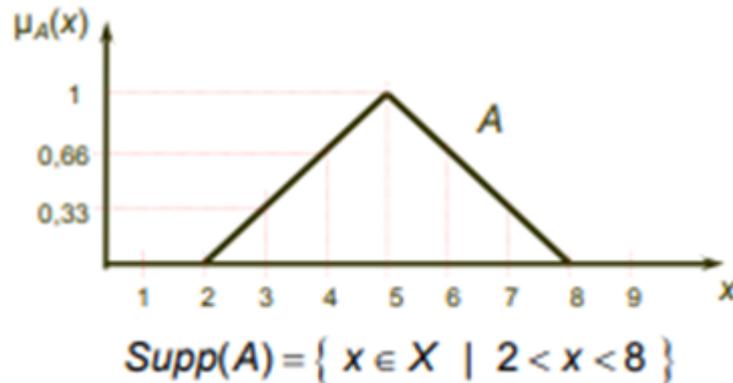
Fonte: <<https://photos.app.goo.gl/QntNoHc7PhAT1xDi8>>

### Suporte de Conjunto Fuzzy

O suporte de um conjunto fuzzy  $A$  é o conjunto de todos os elementos de  $A$  que possuem graus de pertinência maior que zero, ou seja:

$$\text{Supp}(A) = \{x \in X \mid \mu_A(x) > 0\}$$

Figura 17: Normalização



Fonte: <<https://photos.app.goo.gl/QntNoHc7PhAT1xDi8>>

### Alfa-corte:

O alfa-corte de um conjunto em teoria dos conjuntos é um conceito que descreve todos os elementos do universo (ou espaço amostral) que não estão no conjunto. Em outras palavras, é o conjunto de todos os elementos que não pertencem ao conjunto original. O alfa-corte de um conjunto  $A$ , denotado por  $\bar{A}$ , é definido como o conjunto complementar de  $A$  em relação ao universo, onde o universo é o conjunto de todos os elementos relevantes sob consideração. Formalmente, pode-se expressar o alfa-corte como  $\bar{A} = \{x \mid x \notin A\}$ .

### Alfa-corte estrito ( $\alpha$ -corte estrito):

O alfa-corte estrito é uma extensão do conceito de alfa-corte. Ele também descreve todos os elementos do universo que não estão no conjunto, mas com uma diferença crucial: no alfa-corte estrito, o próprio elemento não é incluído no corte. Em outras palavras, é o conjunto de todos os elementos que são estritamente maiores que os elementos do conjunto original. Formalmente, o alfa-corte estrito de um conjunto  $A$ , denotado por  $\bar{\bar{A}}$ , é definido como  $\bar{\bar{A}} = \{x \mid x > a \text{ para todo } a \in A\}$

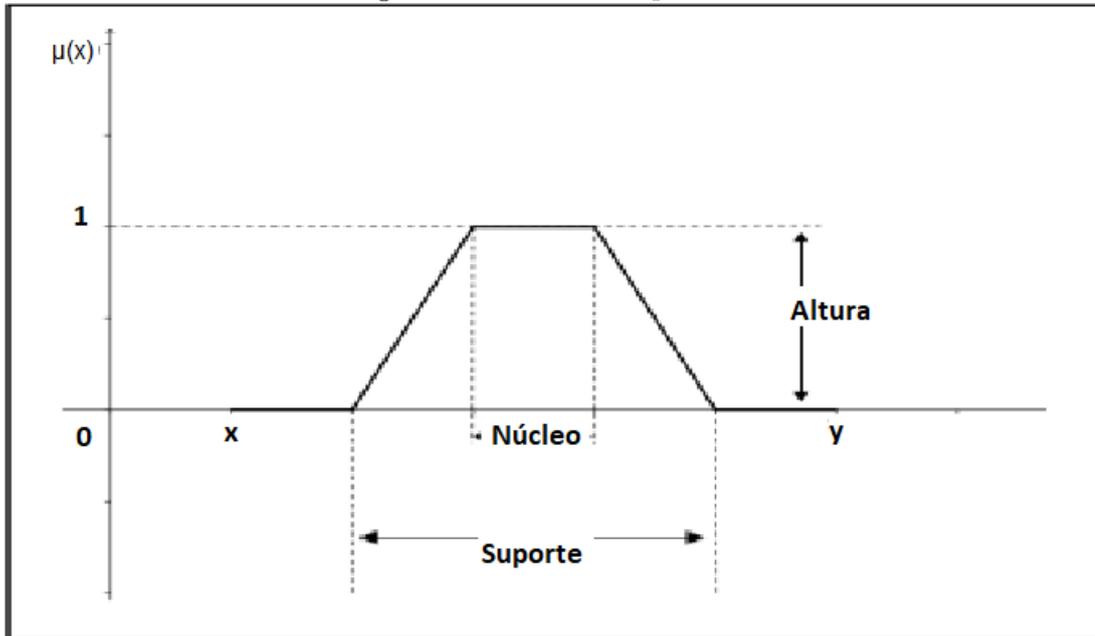
### Núcleo

O conjunto núcleo de  $A$  é o conjunto que contém todos os elementos de  $\Omega$  que possuem grau de pertinência igual a 1 em  $A$ , ou seja,

$$\text{Nu}(A) = \{x \in \Omega \mid \mu_A(x) = 1\}$$

Note que o núcleo de um conjunto Fuzzy  $A$  é o 1-corte de  $A$ .

Figura 18: Gráfico trapezoidal



Fonte: <<https://photos.app.goo.gl/hTk18aJvHRxtReUa9>>

### 2.2.9 Operações

Considerando dois conjuntos Fuzzy  $A$  e  $B$  contidos no universo  $\Omega$ , defini-se:

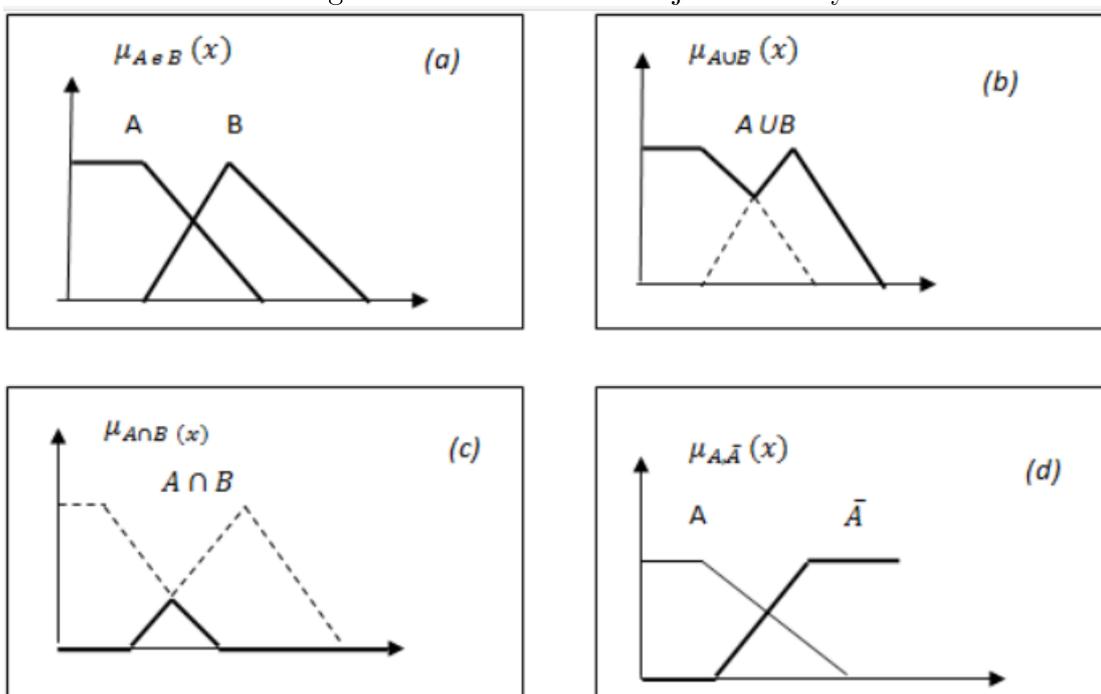
1. Conjunto vazio:  $A = \emptyset$  se, e somente se,  $\forall a \in \Omega, \mu_A(a) = 0$ ;
2. Conjunto universo:  $A = \Omega$  se, e somente se,  $\forall a \in \Omega, \mu_A(a) = 1$ ;
3. Conjuntos iguais:  $A = B$  se, e somente se,  $\forall a \in \Omega, \mu_A(a) = \mu_B(a)$ ;
4. Subconjunto:  $A \subset B$  quando  $\forall a \in \Omega, \mu_A(a) \leq \mu_B(a)$ ;
5. Complementar:  $\bar{A} = \{(a, \mu_{A'}(a)) \mid a \in \Omega\}$ , onde  $\mu_{A'}(a) = 1 - \mu_A(a)$ ;
6. União:  $\mu_{A \cup B}(a) = \max\{\mu_A(a), \mu_B(a)\}$ ;
7. Interseção:  $\mu_{A \cap B}(a) = \min\{\mu_A(a), \mu_B(a)\}$ .

Exemplo 1.1. Considere que o conjunto universo  $\Omega$  seja formado por cinco alunos de uma turma de 1º ano do ensino médio, identificados pelos números 1, 2, 3, 4 e 5. Sejam  $A$  e  $B$  os conjuntos Fuzzy que representam os conceitos de "estatura alta" e "porte físico magro", respectivamente. Considerando que os graus de pertinência aos conjuntos Fuzzy  $A$  e  $B$  são dados, a tabela abaixo ilustra a união, intersecção e o complemento dos conjuntos  $A$  e  $B$ .

ALUNO	A	B	$A \cup B$	$A \cap B$	A'	B'
1	0,5	0,6	0,6	0,5	0,5	0,4
2	0,3	0,8	0,8	0,3	0,7	0,2
3	0,7	0,4	0,7	0,4	0,3	0,6
4	0,2	0,6	0,6	0,2	0,8	0,4
5	0,9	0,1	0,9	0,1	0,1	0,9

Se o universo do discurso for contínuo a representação gráfica das operações é dada pelas figuras seguintes:

Figura 19: Gráficos de Conjuntos Fuzzy



Fonte: <<https://photos.app.goo.gl/hTM2ENN22RdSiq4j8>>

### 2.2.10 Propriedades

Utilizando as definições de união, interseção e complementar, é possível verificar as seguintes propriedades:

**Involução**  $\bar{\bar{A}} = A$

**Prova.** Da definição de complementar, tem-se

$$\mu_{\bar{A}}(a) = 1 - \mu_A(a) = 1 - (1 - \mu_{\bar{\bar{A}}}(a)) = \mu_{\bar{\bar{A}}}(a).$$

Portanto,  $\bar{\bar{A}} = A$

**Idempotência** ( $A \cap A = A$ ) e ( $A \cup A = A$ )

**Prova.** Nota-se que, para demonstrar a idempotência  $(A \cap A = A)$  e  $(A \cup A = A)$ , nota-se que:

$$\mu_{A \cap A}(a) = \min\{\mu_A(a), \mu_A(a)\} = \mu_A(a)$$

e

$$\mu_{A \cup A}(a) = \max\{\mu_A(a), \mu_A(a)\} = \mu_A(a).$$

Portanto,  $(A \cap A = A)$  e  $(A \cup A = A)$ .

**Comutatividade**  $(A \cap B = B \cap A)$  e  $(A \cup B = B \cup A)$

**Prova.** Como  $\mu_{A \cap B}(a) = \min\{\mu_A(a), \mu_B(a)\} = \min\{\mu_B(a), \mu_A(a)\} = \mu_{B \cap A}(a)$ , segue que  $A \cap B = B \cap A$ . A demonstração referente à união é análoga.

**Associatividade**  $[(A \cap B) \cap C = A \cap (B \cap C)]$  e  $[(A \cup B) \cup C = A \cup (B \cup C)]$

**Prova.** Nota-se que,

$$\mu_{(A \cap B) \cap C}(a) = \min\{\mu_{A \cap B}(a), \mu_C(a)\} = \min\{\min\{\mu_A(a), \mu_B(a)\}, \mu_C(a)\} =$$

$$\min\{\mu_A(a), \mu_B(a), \mu_C(a)\} = \min\{\mu_A(a), \min\{\mu_B(a), \mu_C(a)\}\} = \mu_{A \cap (B \cap C)}(a).$$

Logo,  $(A \cap B) \cap C = A \cap (B \cap C)$ . A demonstração referente à união é análoga.

**Distributividade**  $[A \cap (B \cup C) = (A \cap B) \cup (A \cap C)]$  e

$[A \cup (B \cap C) = (A \cup B) \cap (A \cup C)]$

**Prova.** Nota-se que,

$$\mu_{A \cap (B \cup C)}(a) = \min\{\mu_A(a), \max\{\mu_B(a), \mu_C(a)\}\}.$$

Contudo,

$$\min\{\mu_A(a), \max\{\mu_B(a), \mu_C(a)\}\} = \max\{\min\{\mu_A(a), \mu_B(a)\}, \min\{\mu_A(a), \mu_C(a)\}\}.$$

Portanto,  $A \cap (B \cup C) = (A \cap B) \cup (A \cap C)$ . A demonstração referente à segunda parte é análoga.

**Transitividade**  $(A \subset B \text{ e } B \subset C) \Rightarrow A \subset C$

**Prova.** Se  $A \subset B$  e  $B \subset C$ , então para todo  $a \in \Omega$ ,  $\mu_A(a) \leq \mu_B(a)$  e  $\mu_B(a) \leq \mu_C(a)$ , assim,  $\mu_A(a) \leq \mu_C(a)$ . Portanto,  $A \subset C$ .

$A \cap \emptyset = \emptyset$  e  $A \cap \Omega = A$

**Prova.** Nota-se que,

$$\mu_{A \cap \emptyset}(a) = \min\{\mu_A(a), 0\} = 0 = \mu_{\emptyset}(a).$$

Segue que  $A \cap \emptyset = \emptyset$ . A demonstração referente à segunda parte é análoga.

$A \cup \emptyset = A$  e  $A \cup \Omega = \Omega$

**Prova.** Nota-se que,

$$\mu_{A \cup \emptyset}(a) = \max\{\mu_A(a), 0\} = \mu_A(a).$$

Logo,  $A \cup \emptyset = A$ . A demonstração referente à segunda parte é análoga.

Dentre as propriedades de conjuntos clássicos que não se verificam para conjuntos Fuzzy tem-se  $A \cap \bar{A} = \emptyset$  e  $A \cup \bar{A} = \Omega$ . Por exemplo, seja  $A$  um conjunto Fuzzy e um elemento  $a \in \Omega$  tal que  $\mu_A(a) = 0.3$ , tem-se então que  $\mu_{A \cap \bar{A}}(a) = 0.3$  e  $\mu_{A \cup \bar{A}}(a) = 0.7$ . Assim,  $A \cap \bar{A} \neq \emptyset$  e  $A \cup \bar{A} \neq \Omega$ .

### 2.2.11 Produto Cartesiano Fuzzy e Relações Fuzzy

O conceito de relação matemática utilizado nos conjuntos clássicos trata-se da indicação de haver ou não alguma associação entre dois objetos. Na relação Fuzzy, além de indicar se há ou não tal associação, indica-se também o grau dessa relação. Uma relação clássica  $R$  é um subconjunto do produto cartesiano, que pode ser representada por sua função característica  $R : \Omega_1 \times \dots \times \Omega_n \rightarrow [0, 1]$ , dada por:

$$R(x_1, \dots, x_n) = \begin{cases} 1 & \text{se } (x_1, \dots, x_n) \in R \\ 0 & \text{caso contrário} \end{cases}$$

[9] O conceito de relação Fuzzy é formalizado a partir do produto cartesiano usual entre conjuntos, estendendo a função característica de uma relação por uma função de  $\Omega_1 \times \dots \times \Omega_n$  em  $[0, 1]$ , chamada de função de pertinência de  $R$ .

Suponha que  $A_1$  e  $A_2$  sejam subconjuntos Fuzzy de  $\Omega_1$  e  $\Omega_2$ , respectivamente. O produto cartesiano Fuzzy de  $A_1$  por  $A_2$  é o subconjunto Fuzzy do produto cartesiano (clássico)  $\Omega_1 \times \Omega_2$ , cuja função de pertinência é dada por:

$$\mu_{A_1 \times A_2}(a_1, a_2) = \min\{\mu_{A_1}(a_1), \mu_{A_2}(a_2)\}$$

A definição de produto cartesiano pode ser estendida para mais de dois conjuntos. O produto cartesiano Fuzzy dos subconjuntos  $A_1, \dots, A_n$  de  $\Omega_1, \dots, \Omega_n$ , respectivamente, é o conjunto Fuzzy  $A_1 \times \dots \times A_n$ , cuja função de pertinência é dada por:

$$\mu_{A_1 \times \dots \times A_n}(a_1, \dots, a_n) = \min\{\mu_{A_1}(a_1), \dots, \mu_{A_n}(a_n)\}$$

Uma relação Fuzzy  $R$  sobre  $\Omega_1 \times \dots \times \Omega_n$  é qualquer subconjunto Fuzzy de  $\Omega_1 \times \dots \times \Omega_n$ . Se a função de pertinência da relação Fuzzy  $R$  for indicada por  $\mu_R$ , então o número  $\mu_R(x_1, \dots, x_n)$  indica o grau com que os elementos  $x_i$  estão relacionados segundo a relação  $R$ .

Os conjuntos Fuzzy  $A = \{0.4|a_1, 0.6|a_2, 0.2|a_3, 0.8|a_4\}$  e  $B = \{0.1|b_1, 0.5|b_2, 1|b_3\}$  definidos nos universos discretos  $\Omega_1$  e  $\Omega_2$  respectivamente, e a relação Fuzzy  $R$  dada por  $\mu_R(x, y) = \max\{\mu_A(x), 1 - \min\{\mu_A(x), \mu_B(y)\}\}$ , onde  $x \in \Omega_1$  e  $y \in \Omega_2$ .

**Observação:** A notação apresentada descreve conjuntos Fuzzy, que são conjuntos onde os elementos têm graus de pertinência associados a eles. Analisando a notação para os conjuntos A e B fornecidos:

$\{0.4|a_1\}$ , significa que o elemento  $a_1$  tem um grau de pertinência de 0.4 ao conjunto A.

Essencialmente, a notação descreve o quanto cada elemento pertence ao conjunto, representado pelo grau de pertinência, que varia entre 0 e 1. Valores mais próximos de 1 indicam uma pertinência mais forte, enquanto valores mais próximos de 0 indicam uma pertinência mais fraca.

$$\begin{aligned}
 \mu_R(a_1, b_1) &= \max\{0.4, 1 - \min\{0.4, 0.1\}\} = 0.9 \\
 \mu_R(a_1, b_2) &= \max\{0.4, 1 - \min\{0.4, 0.5\}\} = 0.6 \\
 \mu_R(a_1, b_3) &= \max\{0.4, 1 - \min\{0.4, 1\}\} = 0.6 \\
 \mu_R(a_2, b_1) &= \max\{0.6, 1 - \min\{0.6, 0.1\}\} = 0.9 \\
 \mu_R(a_2, b_2) &= \max\{0.6, 1 - \min\{0.6, 0.5\}\} = 0.6 \\
 \mu_R(a_2, b_3) &= \max\{0.6, 1 - \min\{0.6, 1\}\} = 0.6 \\
 \mu_R(a_3, b_1) &= \max\{0.2, 1 - \min\{0.2, 0.1\}\} = 0.9 \\
 \mu_R(a_3, b_2) &= \max\{0.2, 1 - \min\{0.2, 0.5\}\} = 0.8 \\
 \mu_R(a_3, b_3) &= \max\{0.2, 1 - \min\{0.2, 1\}\} = 0.8 \\
 \mu_R(a_4, b_1) &= \max\{0.8, 1 - \min\{0.8, 0.1\}\} = 0.9 \\
 \mu_R(a_4, b_2) &= \max\{0.8, 1 - \min\{0.8, 0.5\}\} = 0.8 \\
 \mu_R(a_4, b_3) &= \max\{0.8, 1 - \min\{0.8, 1\}\} = 0.8
 \end{aligned}$$

Organizando os resultados numa matriz tem-se,

$$\begin{bmatrix}
 0.9 & 0.6 & 0.6 \\
 0.9 & 0.6 & 0.6 \\
 0.9 & 0.8 & 0.8 \\
 0.9 & 0.8 & 0.8
 \end{bmatrix}$$

A matriz encontrada é chamada de matriz relacional.

A matriz relacional é uma estrutura de dados usada em matemática, ciência da computação e em diversas outras áreas, como estatística, teoria dos grafos, análise de redes sociais e sistemas de banco de dados. Ela é especialmente útil para representar e analisar relações entre elementos de um conjunto.

Em uma matriz relacional, as linhas e as colunas representam elementos do conjunto em questão, e os elementos da matriz indicam se há ou não uma relação entre esses elementos. Geralmente, os valores dentro da matriz são booleanos, indicando se a relação entre os elementos correspondentes existe (1) ou não (0). No entanto, em alguns casos, os valores podem representar a intensidade ou o tipo de relação.

### 2.2.12 Composição entre Relações Fuzzy Binárias

A composição de relações é uma ferramenta muito utilizada nas aplicações relacionadas aos conjuntos Fuzzy. Entre as principais composições, tem-se a composição máximo-mínimo, que defini a seguir [11].

#### Definição

Considere  $R$  e  $S$  duas relações Fuzzy binárias em  $\Omega_1 \times \Omega_2$  e  $\Omega_2 \times \Omega_3$ , respectivamente. A composição  $R \circ S$  é uma relação Fuzzy binária em  $\Omega_1 \times \Omega_3$  cuja função de pertinência é dada por

$$\mu_{R \circ S}(x_1, x_3) = \sup_{x_2 \in \Omega_2} \{ \min(\mu_R(x_1, x_2), \mu_S(x_2, x_3)) \}$$

Quando os conjuntos  $\Omega_1, \Omega_2$  e  $\Omega_3$  são finitos, a forma matricial da relação  $R \circ S$ , pela composição máximo-mínimo, é obtida como uma multiplicação de matrizes, substituindo o produto pelo mínimo e a soma pelo máximo.

#### Exemplo

Sejam  $R$  e  $S$  duas relações Fuzzy binárias definidas nos universos discretos  $\Omega_1 \times \Omega_2$  e  $\Omega_2 \times \Omega_3$ , respectivamente. Se as matrizes relacionais de  $R$  e  $S$  são dadas por,

$$R = \begin{bmatrix} 0.7 & 0.4 \\ 0.2 & 0.9 \end{bmatrix} \quad \text{e} \quad S = \begin{bmatrix} 0.5 & 0.8 \\ 0.3 & 0.6 \end{bmatrix}$$

A composição máximo-mínimo resulta na matriz relacional  $R \circ S$  dada por,

$$R \circ S = \begin{bmatrix} \max(\min(0.7, 0.5), \min(0.4, 0.3)) & \max(\min(0.7, 0.8), \min(0.4, 0.6)) \\ \max(\min(0.2, 0.5), \min(0.9, 0.3)) & \max(\min(0.2, 0.8), \min(0.9, 0.6)) \end{bmatrix}$$

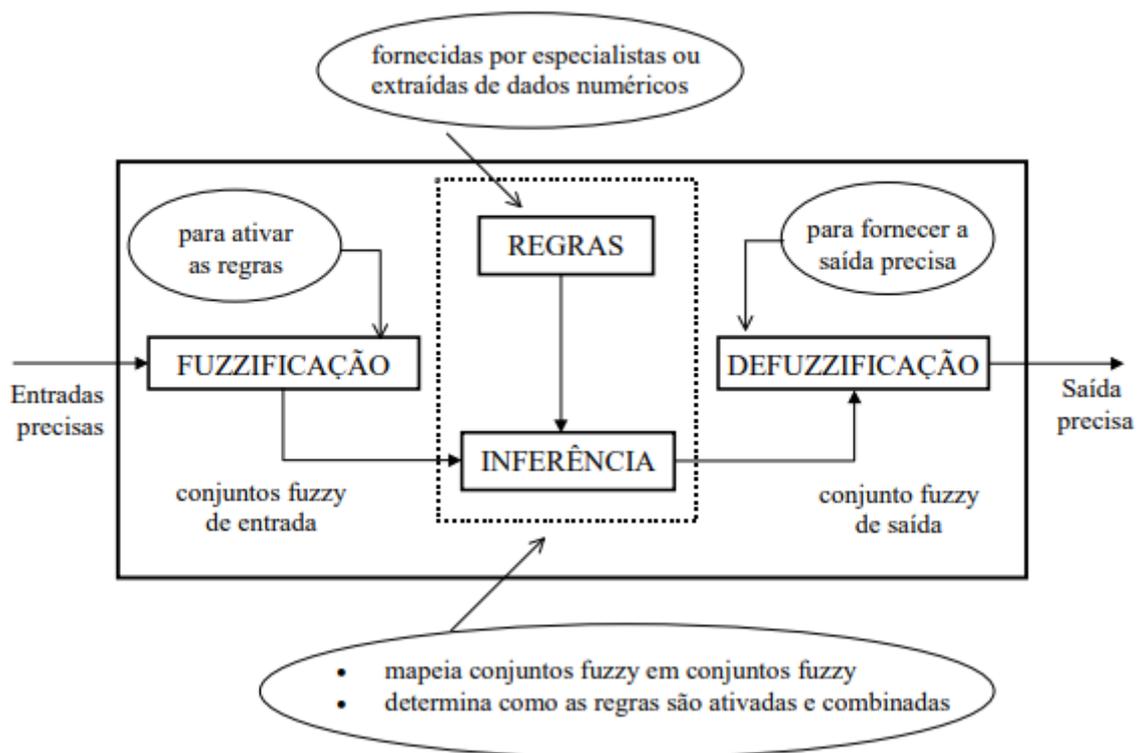
$$R \circ S = \begin{bmatrix} \max(0.5, 0.3) & \max(0.7, 0.4) \\ \max(0.2, 0.3) & \max(0.2, 0.6) \end{bmatrix}$$

$$R \circ S = \begin{bmatrix} 0.5 & 0.7 \\ 0.3 & 0.6 \end{bmatrix}$$

### 2.2.13 Sistemas Lógicos Fuzzy

Um Sistema de Inferência Fuzzy é mostrado na figura abaixo, onde estão identificadas as funções de cada bloco [15].

Figura 20: Sistema de inferência Fuzzy



Fonte: <<https://photos.app.goo.gl/5VDPNVxWd4mqKMA7>>

No processo de Inferência Fuzzy, as entradas consideradas são geralmente não-fuzzy, representando medições ou observações precisas, como conjuntos de dados em aplicações práticas. Para adequar esses dados precisos aos conjuntos fuzzy relevantes, é essencial realizar um mapeamento durante o estágio de fuzzificação. Durante esse estágio, ocorre também a ativação das regras relevantes para uma determinada situação.

Uma vez obtido o conjunto fuzzy de saída por meio do processo de inferência, utilizando o modus ponens generalizado, o estágio subsequente é a defuzzificação. Essa etapa é crucial, pois a maioria das aplicações práticas requer saídas precisas. Por exemplo, em um sistema de controle baseado em um controlador fuzzy, é necessário fornecer à planta dados ou sinais precisos, uma vez que a apresentação de um conjunto fuzzy à entrada da planta não teria significado.

Existem diversos métodos de defuzzificação documentados na literatura, sendo dois dos mais comuns o centro de gravidade e a média dos máximos. No método da média dos máximos, a saída precisa é calculada tomando-se a média entre os dois elementos extremos no universo que correspondem aos maiores valores da função de pertinência do

consequente. Por outro lado, no método do centro de gravidade, a saída é determinada como o valor no universo que divide a área sob a curva da função de pertinência em duas partes iguais.

A escolha entre esses métodos de defuzzificação depende da aplicação específica e das características desejadas para a saída precisa do sistema fuzzy. Em ambos os casos, o objetivo é traduzir eficientemente a informação fuzzy resultante da inferência em dados ou sinais precisos, garantindo a relevância e a utilidade do sistema em contextos práticos.

As regras desempenham um papel crucial no funcionamento de sistemas de inferência fuzzy, sendo fornecidas geralmente por especialistas na forma de sentenças linguísticas. No contexto de um controlador fuzzy, a qualidade do desempenho está intrinsecamente ligada à consistência e precisão das regras que definem a estratégia de controle. Para ilustrar, considere um controlador fuzzy que regula o funcionamento de um sistema. Se as regras que orientam o controle não forem coesas, o desempenho do sistema pode ser comprometido. Extrair regras de especialistas na forma de sentenças "se ... então" pode, por vezes, apresentar desafios significativos, mesmo quando os especialistas possuem profundo conhecimento do problema em questão. A formulação precisa e clara dessas regras requer uma compreensão aprofundada do domínio específico e a habilidade de expressar nuances em termos linguísticos. Esse processo manual pode ser susceptível a ambiguidades e variações interpretativas, destacando a importância de métodos que facilitem a captura eficiente do conhecimento especializado.

Alternativamente, em vez de depender exclusivamente de especialistas para a definição da base de regras, há abordagens que utilizam métodos de extração de regras a partir de dados numéricos. Esses métodos se revelam particularmente úteis em problemas de classificação e previsão de séries temporais, onde padrões e relações podem ser identificados a partir de conjuntos de dados. Essa abordagem baseada em dados oferece uma alternativa valiosa, especialmente em situações em que a expertise especializada pode ser limitada ou difícil de obter. Vale ressaltar que as regras fuzzy são, em sua maioria, formuladas e atribuídas por especialistas no domínio específico do problema. Essas regras refletem o conhecimento humano sobre como tomar decisões em situações imprecisas ou incertas, e não são coletadas automaticamente. Em vez disso, são elaboradas com base na experiência e entendimento do especialista sobre o sistema ou processo em questão. Esse processo manual de formulação de regras contribui para a robustez e adaptabilidade dos sistemas de inferência fuzzy, permitindo que sejam ajustados de acordo com as nuances do contexto específico.

## 2.3 "Implementação de Lógica Fuzzy em Python

### Avaliando Preferência de Filmes com Base na Idade.

A Lógica Fuzzy é uma abordagem que permite lidar com a incerteza e a imprecisão em sistemas. Ela é especialmente útil quando se trata de modelar conceitos vagos ou ambíguos, onde as fronteiras entre categorias não são claramente definidas. A lógica fuzzy usa conjuntos fuzzy e regras fuzzy para realizar inferências e tomada de decisão. Em Python, você pode usar a biblioteca scikit-fuzzy para implementar lógica fuzzy. Aqui está um exemplo simples de como você pode começar a usar a lógica fuzzy em Python:

Instalação da biblioteca: Certifique-se de ter a biblioteca scikit-fuzzy instalada. Você pode instalá-la usando o seguinte comando:

```
pip install -U scikit-fuzzy
```

Exemplo de Uso: Criando um exemplo simples para ilustrar o uso da lógica fuzzy. Neste caso, usa-se uma variável de entrada chamada "idade" e uma variável de saída chamada "preferência". As regras serão baseadas na ideia de determinar a preferência de uma pessoa por um filme com base em sua idade.

```
import numpy as np  
import skfuzzy as fuzz from skfuzzy  
import control as ctrl
```

### Variáveis de entrada e saída

```
idade = ctrl.Antecedent(np.arange(0, 101, 1), 'idade')  
preferencia = ctrl.Consequent(np.arange(0, 101, 1), 'preferencia')
```

### Funções de pertinência para as variáveis de entrada e saída

```
idade['jovem'] = fuzz.trimf(idade.universe, [0, 25, 50])  
idade['meia-idade'] = fuzz.trimf(idade.universe, [25, 50, 75])  
idade['idoso'] = fuzz.trimf(idade.universe, [50, 75, 100])
```

```
preferencia['baixa'] = fuzz.trimf(preferencia.universe, [0, 25, 50])  
preferencia['média'] = fuzz.trimf(preferencia.universe, [25, 50, 75])  
preferencia['alta'] = fuzz.trimf(preferencia.universe, [50, 75, 100])
```

### Definição das regras fuzzy

```
regra1 = ctrl.Rule(idade['jovem'], preferencia['alta'])
```

```
regra2 = ctrl.Rule(idade['meia-idade'], preferencia['média'])  
regra3 = ctrl.Rule(idade['idoso'], preferencia['baixa'])
```

## Criando o sistema de controle fuzzy

```
sistema_controle = ctrl.ControlSystem([regra1, regra2, regra3])
preferencia_fuzzy = ctrl.ControlSystemSimulation(sistema_controle)
```

## Entrada para o sistema fuzzy

```
preferencia_fuzzy.input['idade'] = 30
```

## Computando a saída

```
preferencia_fuzzy.compute()
```

## Obtendo o resultado

```
resultado = preferencia_fuzzy.output['preferencia']
print(f"Resultado de preferência: resultado:.2f")
```

Neste exemplo, as funções de pertinência foram definidas como triângulos, e as regras fuzzy foram definidas de acordo com a idade da pessoa. Você pode ajustar as funções de pertinência, as regras e os valores de entrada conforme necessário para o seu problema específico.

Este é um exemplo bastante simples, mas a lógica fuzzy pode ser aplicada em problemas mais complexos com conjuntos de regras mais elaborados e várias variáveis de entrada e saída. Consulte a documentação do **scikit-fuzzy** [14] para obter mais detalhes sobre como usar a biblioteca em casos mais avançados.

### 2.3.1 Avanços e pontos-chave no uso da Lógica Fuzzy em Python

[13]

#### **Facilidade de Implementação:**

- A sintaxe clara e a flexibilidade do Python tornam a implementação de sistemas de lógica fuzzy acessível mesmo para desenvolvedores menos experientes.
- O scikit-fuzzy oferece uma interface amigável e bem documentada.

#### **Integração com Outras Bibliotecas:**

- Python permite fácil integração com outras bibliotecas científicas e de análise de dados, como NumPy e SciPy, fornecendo um ambiente robusto para experimentação e análise.

### **Aplicações em Diversos Campos:**

- A lógica fuzzy em Python é amplamente utilizada em áreas como controle de sistemas, inteligência artificial, automação, tomada de decisões e análise de dados.

### **Desenvolvimento Ativo:**

- A comunidade Python continua a apoiar o desenvolvimento de ferramentas relacionadas à lógica fuzzy, garantindo atualizações regulares e incorporação de avanços na área.

### **Documentação e Recursos Educativos:**

- Há uma quantidade significativa de recursos educativos, tutoriais e documentação disponíveis para ajudar os desenvolvedores a entenderem e aplicarem a lógica fuzzy em Python.

### **Expansão de Recursos e Funcionalidades:**

- O scikit-fuzzy evoluiu ao longo do tempo, expandindo suas funcionalidades e aprimorando a eficiência para suportar problemas mais complexos.

### **Contribuições da Comunidade:**

- A comunidade Python é ativa, e contribuições regulares são feitas para melhorar as bibliotecas existentes, além de desenvolver novas ferramentas e extensões para a lógica fuzzy.

## **2.3.2 Desafios e críticas no uso de Python na Lógica Fuzzy**

Embora Python seja uma escolha popular entre desenvolvedores, incluindo aqueles que trabalham com lógica fuzzy, é importante reconhecer algumas críticas e desafios associados. Abaixo estão algumas das críticas comuns que podem ser relevantes:

### **Desempenho:**

- Python, como uma linguagem interpretada, pode não ser a escolha mais eficiente em termos de desempenho para cálculos intensivos, especialmente em comparação com linguagens compiladas. Implementações em C ou C++ podem ser preferíveis para aplicações que exigem alta performance.

### **Limitações em aplicações de tempo real:**

- Em sistemas que requerem respostas em tempo real, o garbage collector e outros aspectos da execução em Python podem introduzir atrasos, o que pode ser crítico em certas aplicações.

### **Recursos de Memória:**

- Python pode consumir mais recursos de memória em comparação com linguagens mais leves, o que pode ser uma preocupação em sistemas embarcados ou em ambientes com restrições de memória.

### **Curva de aprendizado para iniciantes:**

- A sintaxe e a estrutura do Python podem ser menos intuitivas para alguns desenvolvedores, especialmente aqueles mais familiarizados com linguagens explicitamente tipadas ou outras estruturas de controle de fluxo.

### **Gerenciamento de dependências:**

- O gerenciamento de dependências pode ser desafiador, especialmente em projetos complexos com muitas bibliotecas externas, podendo ocorrer conflitos entre versões de dependências.

### **Integração com outras tecnologias:**

- Em algumas situações, a integração com sistemas legados ou outras tecnologias pode ser mais desafiadora em Python do que em linguagens mais amplamente usadas em certos domínios.

É crucial observar que muitas dessas críticas têm mitigantes ou são contextualmente dependentes. Python continua sendo uma escolha para desenvolvedores devido à sua sintaxe legível, vasto ecossistema e suporte à orientação a objetos. Além disso, a ativa comunidade Python contribui para melhorias contínuas na linguagem. Ferramentas como Cython (O Cython se destaca como uma ferramenta para integrar Python com C/C++, permitindo que você escreva código Python com desempenho aprimorado e acesse bibliotecas C/C++ existentes. Ele funciona como um compilador que converte código Python em código C/C++ otimizado, combinando a facilidade de uso e expressividade do Python com a velocidade e eficiência do C/C++.) oferecem otimizações de desempenho, e frameworks como PyTorch e TensorFlow demonstram a capacidade do Python em lidar com problemas complexos, incluindo aprendizado de máquina e inteligência artificial.

Portanto, enquanto é válido considerar as críticas associadas ao uso de Python, muitos desenvolvedores ainda valorizam suas vantagens, optando por essa linguagem devido à produtividade, facilidade de aprendizado e amplo suporte comunitário. A escolha da linguagem deve ser feita com base nas necessidades específicas do projeto e nas habilidades e preferências da equipe de desenvolvimento.

## 3 Análise e Discussão de Dados

### 3.1 Fuzzificação, Inferência e Defuzzificação em um Sistema de Controle

Em lógica fuzzy, as variáveis antecedentes são atribuídas valores pertencentes ao intervalo  $[0, 1]$ , indicando o grau de pertinência de um elemento ao conjunto fuzzy associado. Esses valores representam a intensidade da relação do elemento com a característica representada pela variável antecedente. Um valor de 0 significa não pertinência, enquanto um valor de 1 indica pertinência total. Os valores entre 0 e 1 refletem graus de pertinência parciais [12].

Por exemplo, se estiver lidando com a variável "altura" e um conjunto fuzzy "alto", um valor de pertinência de 0,8 indicaria que o elemento tem um alto grau de pertinência ao conjunto fuzzy "alto". Esses valores são determinados com base nas funções de pertinência associadas aos conjuntos fuzzy definidos para cada variável antecedente no sistema fuzzy.

A forma exata de calcular o grau de pertinência depende da função de pertinência escolhida para o conjunto fuzzy. Funções comuns incluem funções triangulares, trapezoidais, gaussianas, entre outras.

O cálculo do grau de pertinência em lógica fuzzy pode ser realizado em linguagens de programação que suportam operações matemáticas. A seguir, fornecerei um exemplo simples em Python utilizando a biblioteca `scipy` para ilustrar o conceito.

Suponha uma variável "Altura" e um conjunto fuzzy "Alto" com uma função de pertinência triangular. Calcula-se o grau de pertinência para uma altura específica, por exemplo, 170 cm.

Parâmetros da função triangular para "Alto":

$$\begin{aligned} a &= 160 && \text{(início da base)} \\ b &= 180 && \text{(ponto máximo - vértice)} \\ c &= 200 && \text{(final da base)} \end{aligned}$$

Altura para a qual quer-se calcular o grau de pertinência:

$$\text{altura} = 170$$

Calculando o grau de pertinência usando a função triangular:

```
grau_pertinencia = triang.cdf(altura, c=(a, b, c))
print(f'0 grau de pertinência da altura {altura} ao conjunto "Alto" é:
{grau_pertinencia:.2f}')
```

Este é apenas um exemplo simplificado, e a escolha dos parâmetros da função triangular depende do contexto específico do problema que você está modelando. Em uma aplicação real, esses parâmetros seriam definidos com base no conhecimento especializado sobre o domínio do problema.

O cálculo manual do grau de pertinência em lógica fuzzy envolve a aplicação da função de pertinência associada ao conjunto fuzzy em questão. A seguir, fornecerei um exemplo usando uma função triangular simples.

Suponha que a variável "Temperatura" é um conjunto fuzzy "Agradável" com uma função de pertinência triangular. Os parâmetros da função triangular são:

$$\begin{aligned} a &= 20^\circ\text{C} \quad (\text{início da base}) \\ b &= 25^\circ\text{C} \quad (\text{ponto máximo - vértice}) \\ c &= 30^\circ\text{C} \quad (\text{final da base}) \end{aligned}$$

Calcula-se o grau de pertinência para uma temperatura de  $27^\circ\text{C}$ . Verifica-se em qual intervalo a temperatura de  $27^\circ\text{C}$  se encontra. Neste caso,  $a \leq 27 \leq b$ .

$$\mu_A(27) = \frac{27 - a}{b - a} = \frac{27 - 20}{25 - 20} = \frac{7}{5} = 1.4$$

Calcula-se o grau de pertinência ponderado usando a média ponderada dos graus de pertinência nos intervalos relevantes. Para a função triangular, considera-se os dois lados da base da função:

$$\begin{aligned} \text{Distância do ponto ao lado direito} &= \frac{27 - 25}{30 - 25} = \frac{2}{5} \\ \text{Distância do ponto ao lado esquerdo} &= \frac{30 - 27}{30 - 25} = \frac{3}{5} \end{aligned}$$

Substitua-se na fórmula:

$$\begin{aligned} \text{Grau de Pertinência} &= (1 - \text{distância do ponto ao lado direito}) \cdot \mu_A(b) + \\ & (1 - \text{distância do ponto ao lado esquerdo}) \cdot \mu_A(a) \end{aligned}$$

$$\text{Grau de Pertinência} = \left(1 - \frac{2}{5}\right) \cdot \frac{7}{5} + \left(1 - \frac{3}{5}\right) \cdot 0$$

$$\text{Grau de Pertinência} = \left(\frac{3}{5} \cdot \frac{7}{5} + \frac{2}{5} \cdot 0\right)$$

$$\text{Grau de Pertinência} = \frac{21}{25}$$

$$\text{Grau de Pertinência} = 0.84$$

Portanto, o grau de pertinência da temperatura de 27°C ao conjunto fuzzy "Agradável" é 0.84, indicando um alto grau de pertinência. A escolha exata dos conjuntos fuzzy e das funções de pertinência dependerá da natureza específica do seu problema, dos dados disponíveis e da interpretação que você deseja dar a cada variável linguística. Consultar especialistas no domínio pode ajudar a refinar essas escolhas com base no conhecimento prático do contexto.

Cria-se um conjunto de regras fictícias relacionando as variáveis antecedentes "Tempo de Estudo" e "Motivação" com a variável consequente "Dedicação". Lembre-se de que este é apenas um exemplo simplificado e que as regras específicas podem variar com base na interpretação do problema e no conhecimento do domínio. Usando conjuntos fuzzy triangulares para ilustrar.

**Regra 1:** Se Tempo de Estudo é Baixo e Motivação é Baixa, então Dedicação é Baixa.

Tempo de Estudo: 2 horas (pertinência alta em "Baixo")  
Motivação: 3 (pertinência alta em "Baixa")  
Dedicação: Baixa

**Regra 2:** Se Tempo de Estudo é Médio e Motivação é Média, então Dedicação é Moderada.

Tempo de Estudo: 4 horas (pertinência alta em "Médio")  
Motivação: 5 (pertinência alta em "Média")  
Dedicação: Moderada

**Regra 3:** Se Tempo de Estudo é Alto e Motivação é Baixa, então Dedicação é Baixa.

Tempo de Estudo: 6 horas (pertinência alta em "Alto")  
Motivação: 2 (pertinência alta em "Baixa")  
Dedicação: Baixa

**Regra 4:** Se Tempo de Estudo é Baixo e Motivação é Alta, então Dedicação é Moderada.

Tempo de Estudo: 3 horas (pertinência alta em "Baixo")  
Motivação: 7 (pertinência alta em "Alta")  
Dedicação: Moderada

**Regra 5:** Se Tempo de Estudo é Alto e Motivação é Alta, então Dedicção é Alta.

Tempo de Estudo: 7 horas (pertinência alta em "Alto")

Motivação: 8 (pertinência alta em "Alta")

Dedicção: Alta

Essas regras são uma representação simplificada e hipotética. No mundo real, a definição precisa dos conjuntos fuzzy, a escolha das funções de pertinência e a interpretação das regras seriam baseadas no conhecimento especializado do domínio. Este exemplo visa ilustrar a relação entre as variáveis antecedentes e consequentes em um sistema fuzzy.

Usando a defuzzificação ponderada pelo centroide para este. Dadas as pertinências para "Dedicção":

$$\text{Pertinência para "Baixa"} (\mu_{\text{Baixa}}) = 0,3$$

$$\text{Pertinência para "Moderada"} (\mu_{\text{Moderada}}) = 0,6$$

$$\text{Pertinência para "Alta"} (\mu_{\text{Alta}}) = 0,8.$$

A defuzzificação é o processo de converter as saídas fuzzy (nesse caso, a dedicação) em um valor não fuzzy. A defuzzificação ponderada pelo centroide é uma abordagem comum. Nesse método, o valor final é calculado tomando-se a média ponderada dos valores nos conjuntos fuzzy considerando as pertinências. A fórmula geral para a defuzzificação ponderada pelo centroide é:

O valor final é dado por: [15].

$$\text{Valor final} = \frac{\sum(\text{Pertinência} \times \text{Valor})}{\sum \text{Pertinência}}$$

Para o exemplo dado:

$$\text{Valor final} = \frac{(0,3 \times \text{Valor de "Baixa"}) + (0,6 \times \text{Valor de "Moderada"}) + (0,8 \times \text{Valor de "Alta"})}{0,3 + 0,6 + 0,8}$$

Dado que as pertinências são:

$$\mu_{\text{Baixa}} = 0,3, \quad \mu_{\text{Moderada}} = 0,6, \quad \mu_{\text{Alta}} = 0,8$$

E os valores associados são (exemplos):

$$\text{Valor de "Baixa"} = 30, \quad \text{Valor de "Moderada"} = 60, \quad \text{Valor de "Alta"} = 90$$

Substituindo esses valores na fórmula, tem-se:

$$\text{Valor final} = \frac{(0,3 \times 30) + (0,6 \times 60) + (0,8 \times 90)}{0,3 + 0,6 + 0,8}$$

Simplificando os termos:

$$\text{Valor final} = \frac{9 + 36 + 72}{1,7}$$

$$\text{Valor final} = \frac{117}{1,7}$$

$$\text{Valor final} \approx 68,82$$

Portanto, o valor final para a dedicação, usando a defuzzificação ponderada pelo centroide, é aproximadamente 68,82. Este valor representa uma estimativa do nível de dedicação com base nas regras fuzzy e nas pertinências associadas aos conjuntos fuzzy "Baixa", "Moderada" e "Alta". Vale ressaltar que os valores exatos dos conjuntos fuzzy e suas pertinências podem variar com base na definição específica do problema e nas funções de pertinência escolhidas.

Se quisermos interpretar as pertinências de "Dedicação" como probabilidades e normalizá-las para que a soma seja 1, pode-se dividir cada pertinência pelo somatório de todas as pertinências. Chama-se as pertinências normalizadas de  $P_{\text{Baixa}}$ ,  $P_{\text{Moderada}}$  e  $P_{\text{Alta}}$ . As pertinências originais são dadas como:

$$\text{Pertinência para "Baixa"} (\mu_{\text{Baixa}}) = 0,3$$

$$\text{Pertinência para "Moderada"} (\mu_{\text{Moderada}}) = 0,6$$

$$\text{Pertinência para "Alta"} (\mu_{\text{Alta}}) = 0,8$$

O somatório é  $\mu_{\text{Baixa}} + \mu_{\text{Moderada}} + \mu_{\text{Alta}} = 0,3 + 0,6 + 0,8 = 1,7$ .

Agora, normaliza-se cada pertinência dividindo pelo somatório:

$$P_{\text{Baixa}} = \frac{\mu_{\text{Baixa}}}{1,7} \approx \frac{0,3}{1,7} \approx 0,1765$$

$$P_{\text{Moderada}} = \frac{\mu_{\text{Moderada}}}{1,7} \approx \frac{0,6}{1,7} \approx 0,3529$$

$$P_{\text{Alta}} = \frac{\mu_{\text{Alta}}}{1,7} \approx \frac{0,8}{1,7} \approx 0,4706$$

Agora, a soma dessas probabilidades normalizadas deve ser 1:

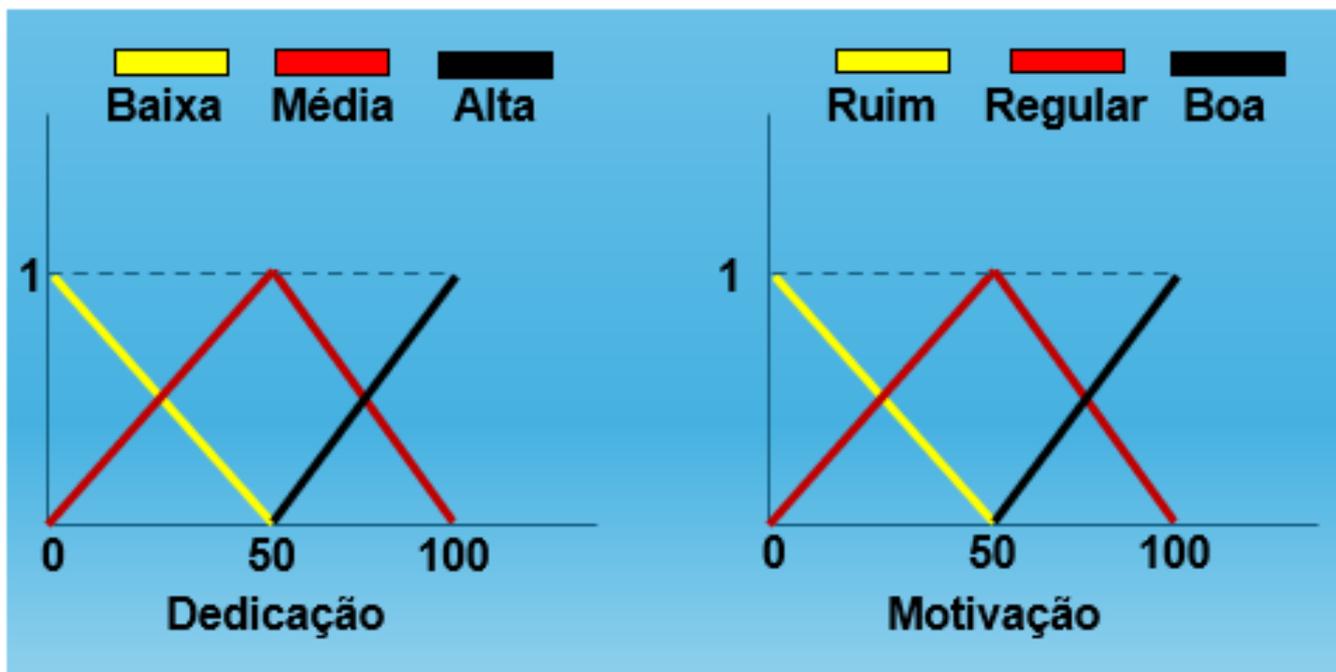
$$P_{\text{Baixa}} + P_{\text{Moderada}} + P_{\text{Alta}} \approx 0,1765 + 0,3529 + 0,4706 \approx 1$$

Portanto, as pertinências normalizadas para “Baixa”, “Moderada” e “Alta” são aproximadamente 0,1765, 0,3529 e 0,4706, respectivamente. Esses valores normalizados podem ser interpretados como probabilidades proporcionais de pertencer a cada categoria de dedicação.

**PROBLEMA:** Uma escola deseja avaliar o tempo real de estudo de um aluno em função da sua dedicação e motivação que recebe. E que o tempo máximo será 8h de estudo

**VARIÁVEIS DE ENTRADA:** DEDICAÇÃO E MOTIVAÇÃO

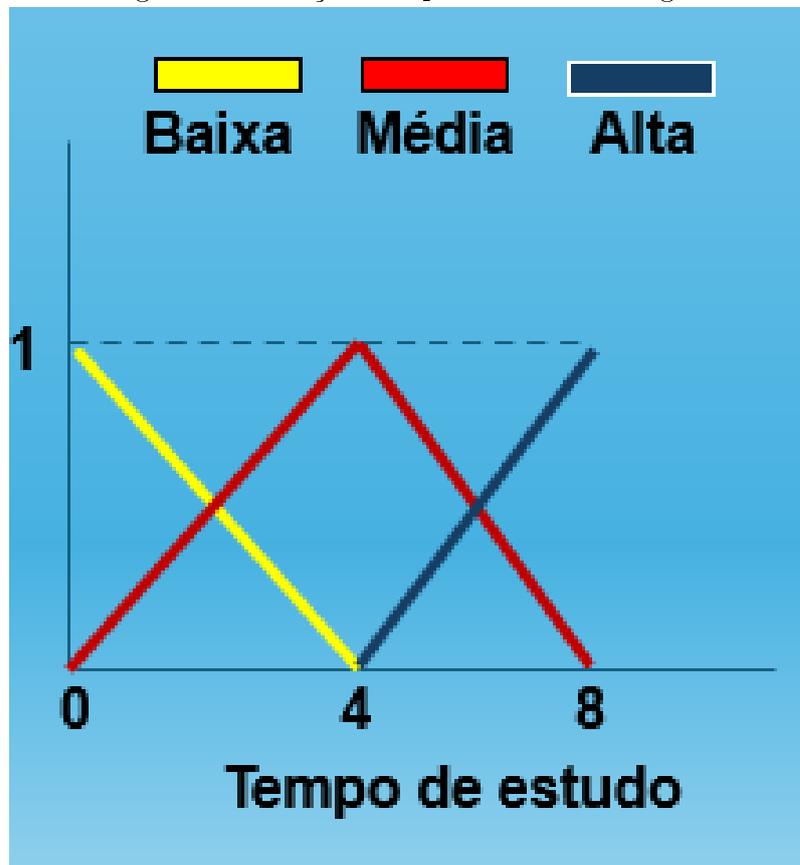
Figura 21: Funções de pertinência Triangular



Fonte: <figura construida pelo autor>

## VARIÁVEL DE SAÍDA: TEMPO DE ESTUDO

Figura 22: Funções de pertinência Triangular



Fonte: <figura construída pelo autor>

### DEFINIÇÃO DAS REGRAS

Regra 1: Se Dedicção for baixa E a Motivação for regular então o Tempo de Estudo é baixo

Regra 2: Se Dedicção for média OU a Motivação for alta então o Tempo de Estudo é médio

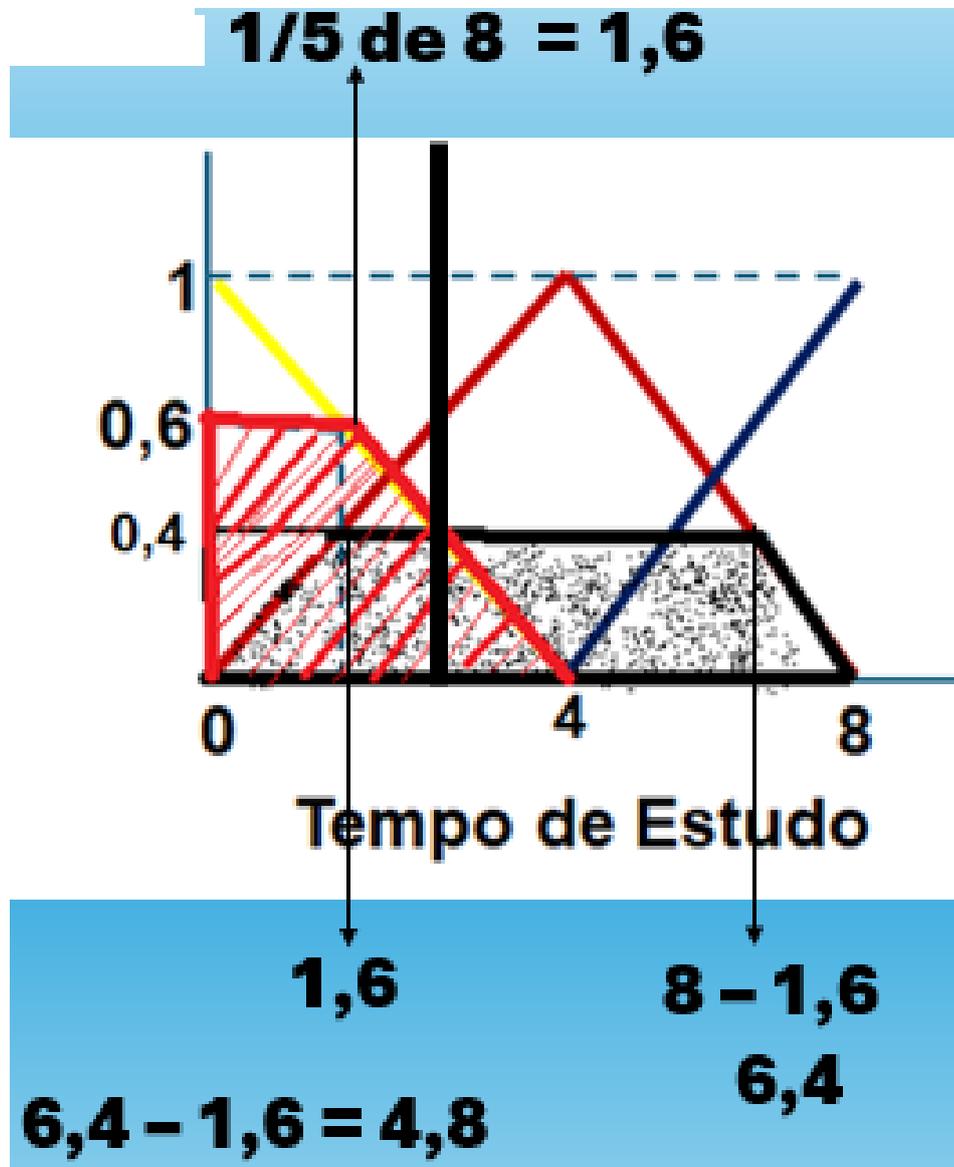
Considerando uma dedicação de 20% e uma motivação de 65%

Figura 23: Gráfico de ativação



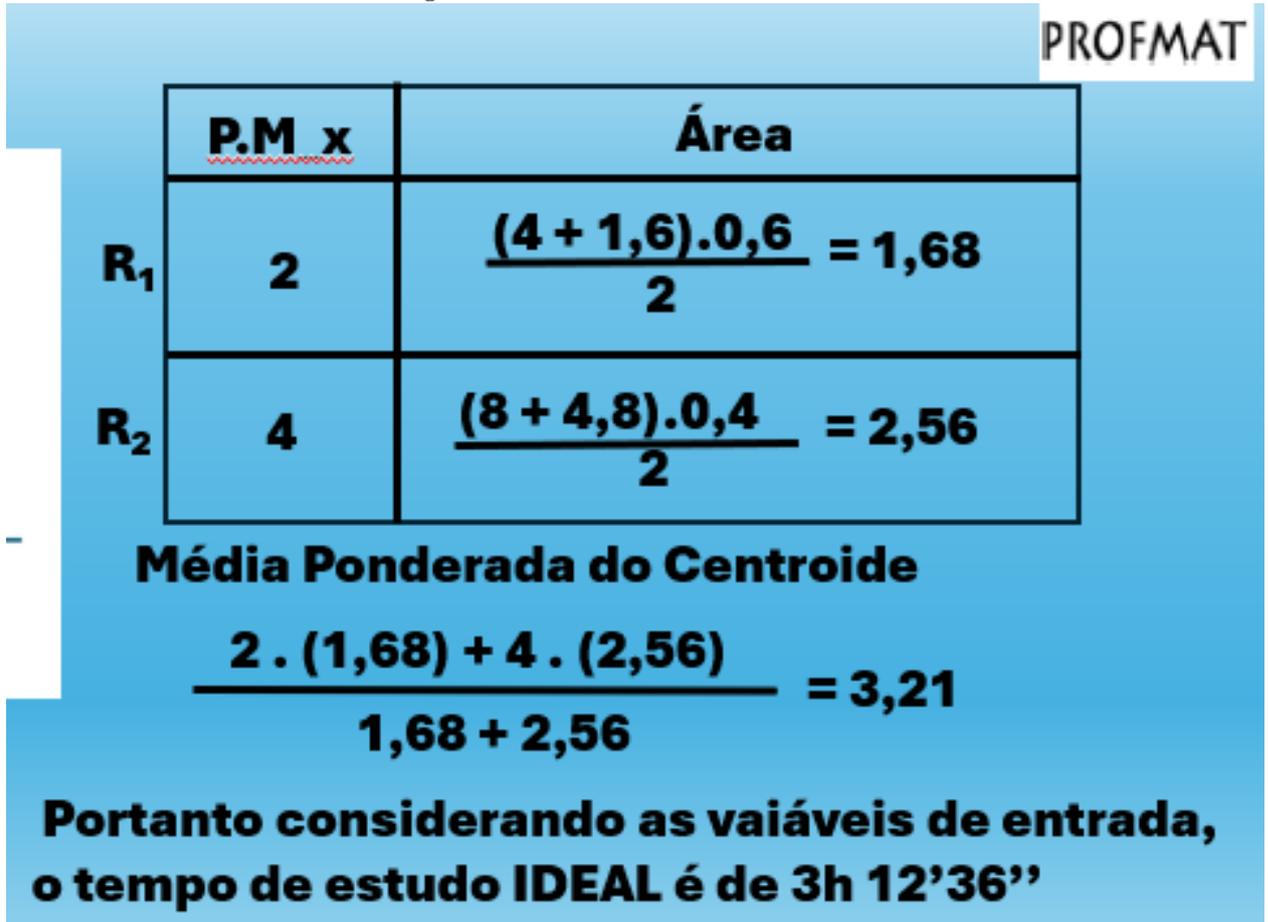
Fonte: <figura construída pelo autor>

Figura 24: Identificação dos dados



Fonte: <figura construída pelo autor>

Figura 25: Cálculo do Centróide



Fonte: <figura construída pelo autor>

### 3.2 Descrição das Variáveis em Linguagem Python

Reformulando as variáveis utilizando a linguagem fuzzy para os conceitos de “Dedicação”, “Apoio da Família”, “Ociosidade”, “Má Influência” e “Ambiente Adequado”. Em seguida, fá-se uma descrição detalhada da variável “Dedicação” usando a linguagem Python.

#### Tempo de estudo como variável consequente

```
import numpy as np
import skfuzzy as fuzz from skfuzzy
import control as ctrl
import matplotlib.pyplot as plt
```

#### Definindo as variáveis do universo

```
dedicacao = ctrl.Antecedent(np.arange(0, 11, 1), 'dedicacao')
```

```
motivacao = ctrl.Antecedent(np.arange(0, 11, 1), 'motivacao')
tempo_estudo = ctrl.Consequent(np.arange(0, 26, 1), 'tempo_estudo')
```

### Definindo as funções de pertinência

```
tempo_estudo['baixo'] = fuzz.trimf(tempo_estudo.universe, [0, 0, 4])
tempo_estudo['medio'] = fuzz.trimf(tempo_estudo.universe, [0, 4, 8])
tempo_estudo['alto'] = fuzz.trimf(tempo_estudo.universe, [4, 8, 8])
```

```
motivacao['baixa'] = fuzz.gaussmf(motivacao.universe, 0, 2)
motivacao['media'] = fuzz.gaussmf(motivacao.universe, 5, 2)
motivacao['alta'] = fuzz.gaussmf(motivacao.universe, 10, 2)
```

```
dedicacao['baixa'] = fuzz.trimf(dedicacao.universe, [0, 0, 13])\\
dedicacao['media'] = fuzz.trimf(dedicacao.universe, [0, 13, 25])\\
dedicacao['alta'] = fuzz.trimf(dedicacao.universe, [13, 25, 25])\\
```

## Definindo as regras

```
regra1 = ctrl.Rule(dedicacao['baixo'] | motivacao['baixa'], tempo_estudo['baixa'])
regra2 = ctrl.Rule(dedicacao['medio'] & motivacao['media'], tempo_estudo['media'])
regra3 = ctrl.Rule(dedicacao['alto'] & motivacao['alta'], tempo_estudo['alta'])
regra4 = ctrl.Rule(dedicacao['baixo'] & motivacao['alta'], tempo_estudo['media'])
regra5 = ctrl.Rule(dedicacao['alto'] & motivacao['baixa'], tempo_estudo['media'])
regra6 = ctrl.Rule((dedicacao['baixo'] | motivacao['baixa']), tempo_estudo['baixa'])
```

## Criando e simulando o sistema de controle

```
sistema_controle = ctrl.ControlSystem([regra1, regra2, regra3, regra4, regra5])
simulacao = ctrl.ControlSystemSimulation(sistema_controle)
```

## Testando o sistema de controle

```
simulacao.input['dedicacao'] = 6.5
simulacao.input['motivacao'] = 6.5
simulacao.compute()

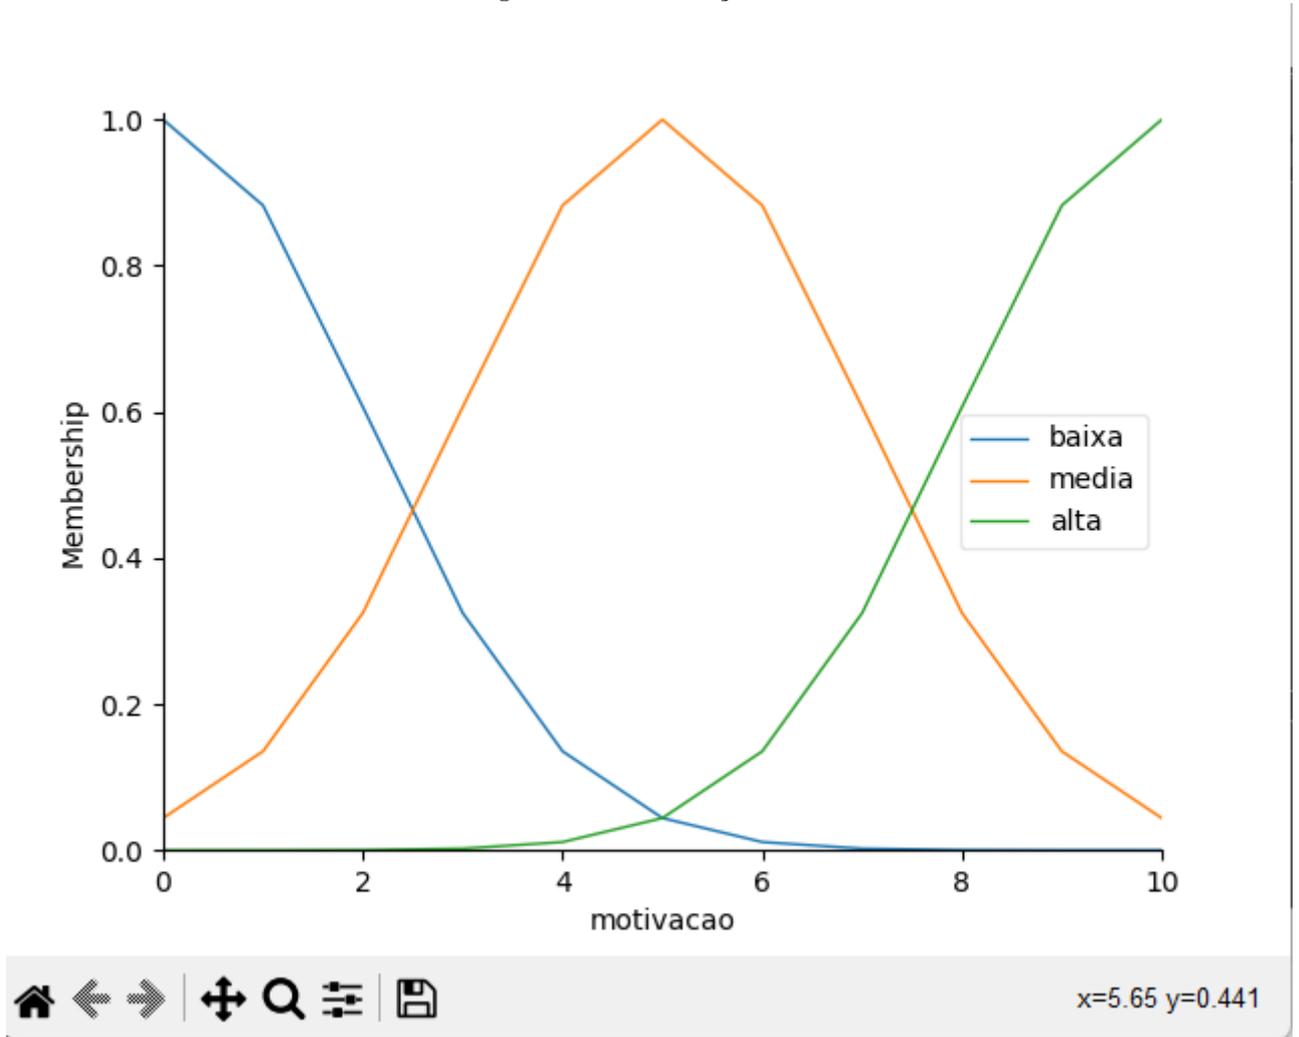
print(simulacao.output['tempo_estudo'])
```

## Plotando os gráficos

```
tempo_estudo.view()
motivacao.view()
dedicacao.view(sim=simulacao)

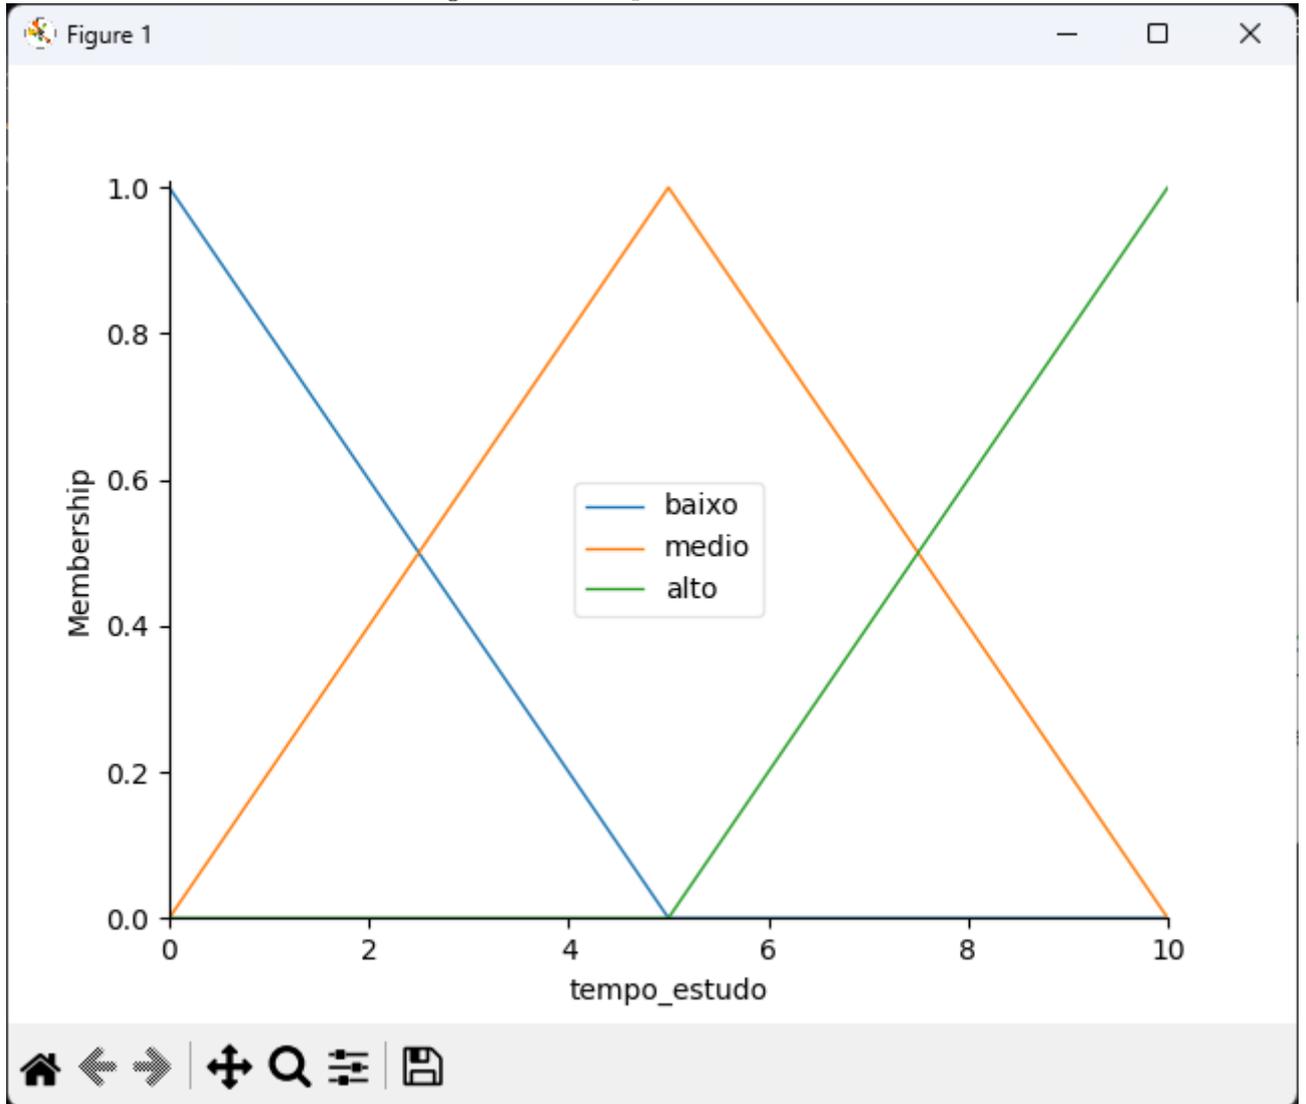
plt.show()
```

Figura 26: Motivação



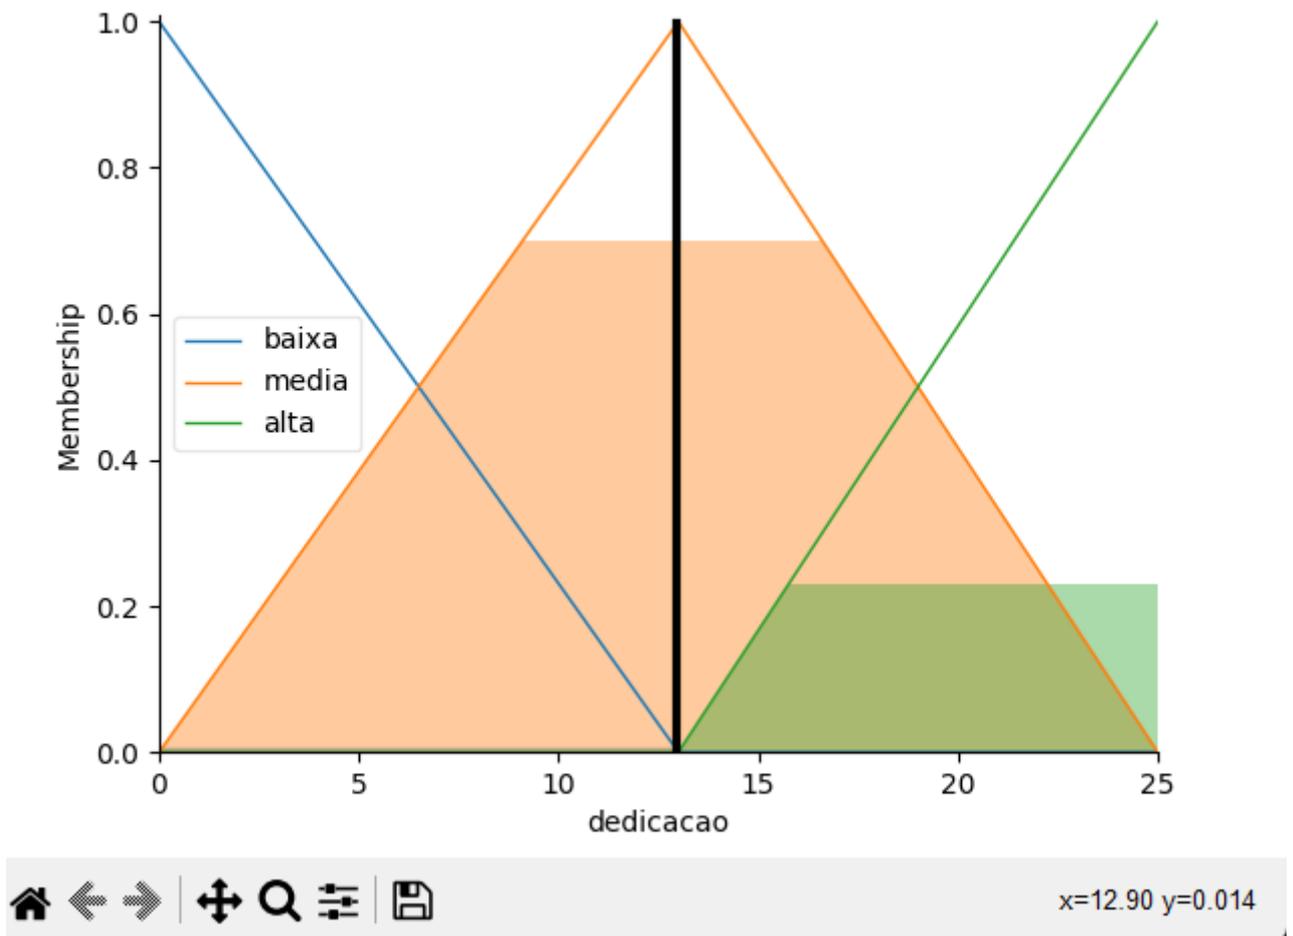
Fonte: <Do próprio autor>

Figura 27: Tempo de Estudo



Fonte: <Do próprio autor>

Figura 28: Dedicção



Fonte: <Do próprio autor>

A defuzzificação é o processo pelo qual os conjuntos fuzzy são convertidos de volta em valores nítidos ou crisp, geralmente para tomar uma decisão ou realizar uma ação. Existem várias técnicas de defuzzificação, mas uma das mais comuns é o método do centróide.

No método do centróide, o valor de defuzzificação é calculado como o centro de massa dos graus de pertinência do conjunto fuzzy. Seja  $A$  um conjunto fuzzy definido em um universo de discurso  $X$ , representado por  $\mu_A(x)$ , onde  $x$  é um elemento de  $X$ . O valor de defuzzificação  $x^*$  é calculado como:

$$x^* = \frac{\sum_{x \in X} x \cdot \mu_A(x)}{\sum_{x \in X} \mu_A(x)}$$

Este valor  $x^*$  representa o ponto médio ou o centro de massa do conjunto fuzzy  $A$ , e é considerado como o valor de defuzzificação usando o método do centróide.

Após a defuzzificação te  $12,9/25 = 51,6\%$  de Dedicção de acordo com as regras utilizadas.

## Apoio da Família

```
import numpy as np
```

```
import skfuzzy as fuzz
```

```
from skfuzzy import control as ctrl
```

```
import matplotlib.pyplot as plt
```

Definindo as variáveis do universo

```
comunicacao = ctrl.Antecedent(np.arange(0, 11, 1), 'comunicacao')
```

```
envolvimento = ctrl.Antecedent(np.arange(0, 11, 1), 'envolvimento')
```

```
recursos_disponiveis = ctrl.Antecedent(np.arange(0, 11, 1), 'recursos_disponiveis')
```

```
apoio_familia = ctrl.Consequent(np.arange(0, 26, 1), 'apoio_familia')
```

# Definindo as funções de pertinência

```
comunicacao['baixa'] = fuzz.trapmf(comunicacao.universe, [0, 0, 2, 4])
```

```
comunicacao['alta'] = fuzz.trapmf(comunicacao.universe, [2, 4, 6, 8])
```

```
comunicacao['muito_aberta'] = fuzz.trapmf(comunicacao.universe, [6, 8, 10, 10])
```

```
envolvimento['baixo'] = fuzz.trimf(envolvimento.universe, [0, 0, 5])
```

```
envolvimento['alto'] = fuzz.trimf(envolvimento.universe, [0, 5, 10])
```

```
recursos_disponiveis['baixos'] = fuzz.trapmf(recursos_disponiveis.universe,  
[0, 0, 2, 4])
```

```
recursos_disponiveis['muitos'] = fuzz.trapmf(recursos_disponiveis.universe,  
[6, 8, 10, 10])
```

```
apoio_familia['baixo'] = fuzz.trimf(apoio_familia.universe, [0, 0, 13])
```

```
apoio_familia['medio'] = fuzz.trimf(apoio_familia.universe, [0, 13, 25])
```

```
apoio_familia['alto'] = fuzz.trimf(apoio_familia.universe, [13, 25, 25])
```

```
apoio_familia['muito_alto'] = fuzz.trimf(apoio_familia.universe, [18, 25, 25])
```

Definindo as regras

```
regra1 = ctrl.Rule(comunicacao['muito_aberta'] & recursos_disponiveis['muitos'],  
apoio_familia['muito_alto'])
```

```
regra2 = ctrl.Rule(comunicacao['baixa'] | envolvimento['baixo'],  
apoio_familia['baixo'])
```

```
regra3 = ctrl.Rule(comunicacao['alta'] & envolvimento['alto'] &
```

```

recursos_disponiveis['muitos'],
apoio_familia['muito_alto'])

regra4 = ctrl.Rule(comunicacao['muito_aberta'] & recursos_disponiveis['baixos'],
apoio_familia['alto'])

regra5 = ctrl.Rule(comunicacao['baixa']& envolvimento['alto'],
apoio_familia['medio'])

regra6 = ctrl.Rule((comunicacao['muito_aberta'] | envolvimento['baixo'])
& recursos_disponiveis['muitos'], apoio_familia['medio'])

```

Criando e simulando o sistema de controle

```

sistema_controle = ctrl.ControlSystem([regra1, regra2, regra3,
regra4, regra5, regra6])
simulacao = ctrl.ControlSystemSimulation(sistema_controle)

```

Testando o sistema de controle

```

simulacao.input['comunicacao'] = 6.5
simulacao.input['envolvimento'] = 6.5
simulacao.input['recursos_disponiveis'] = 6.5
simulacao.compute()

```

```

print(simulacao.output['apoio_familia'])

```

Plotando os gráficos

```

comunicacao.view()
envolvimento.view()
recursos_disponiveis.view()
apoio_familia.view(sim=simulacao)

```

```

plt.show()

```

Figura 29: Comunicação

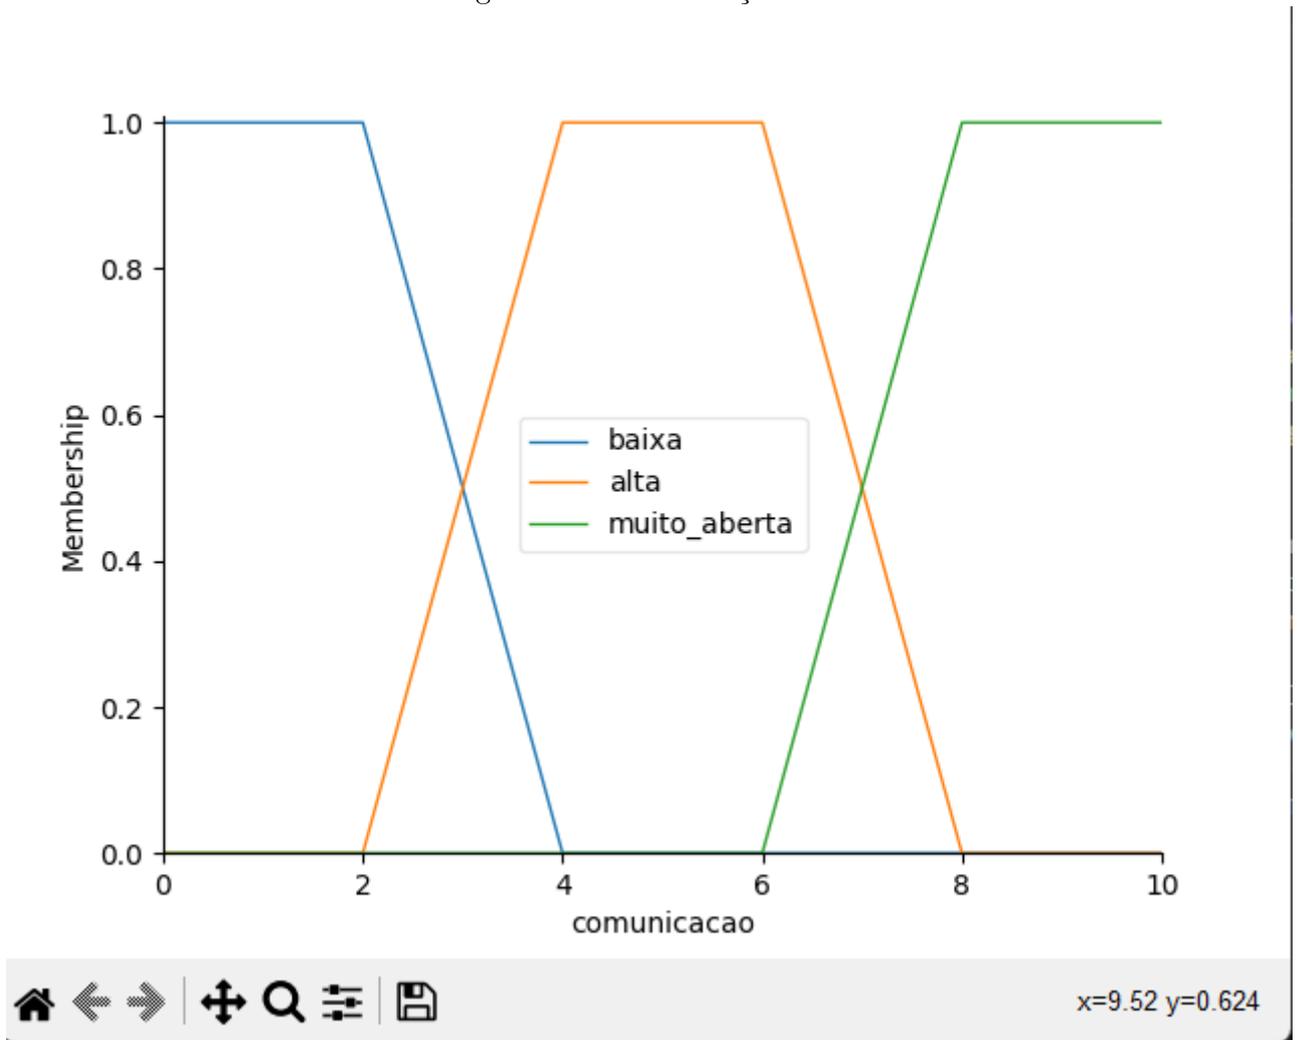
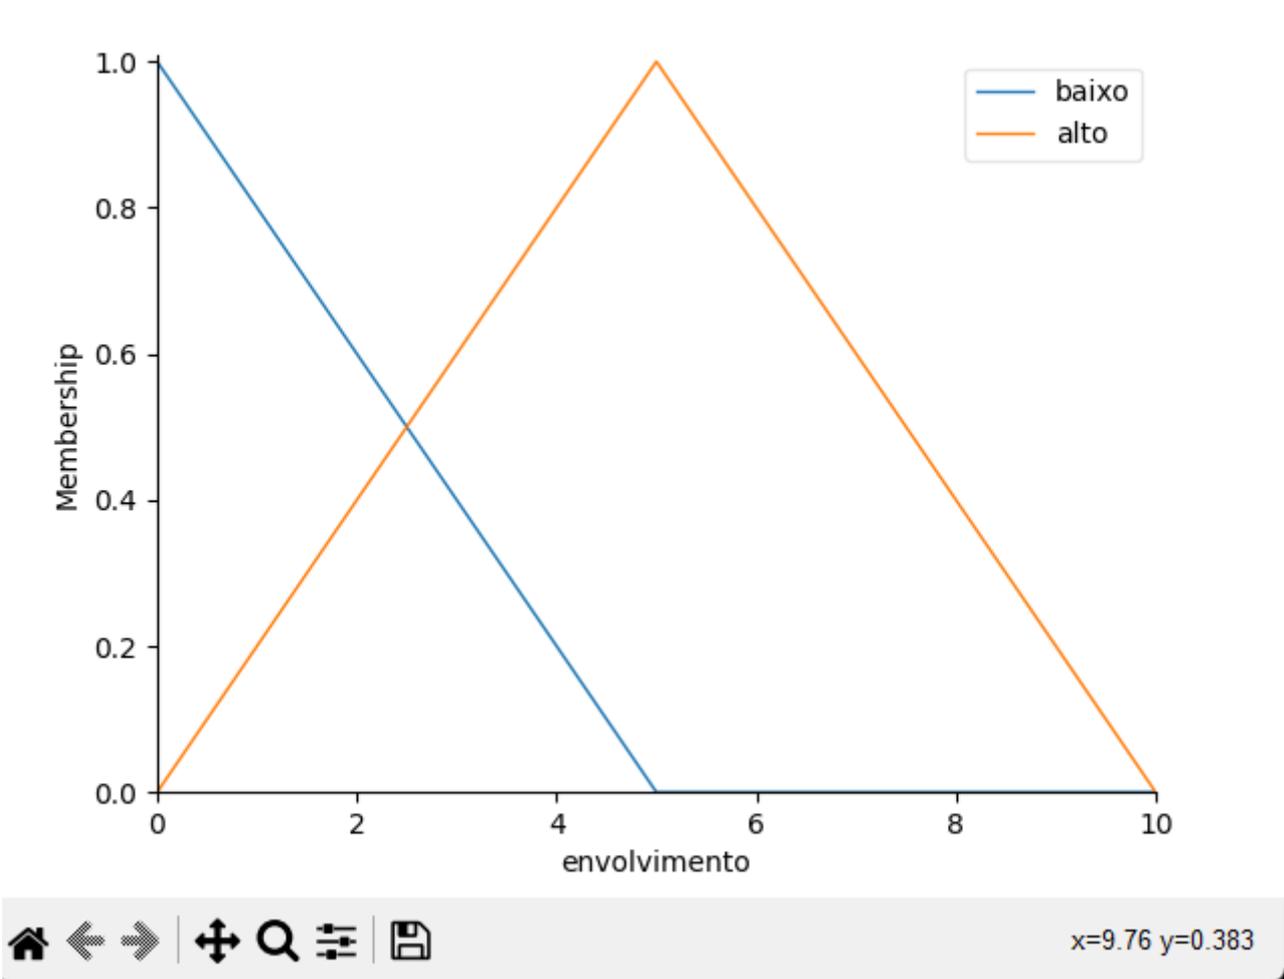
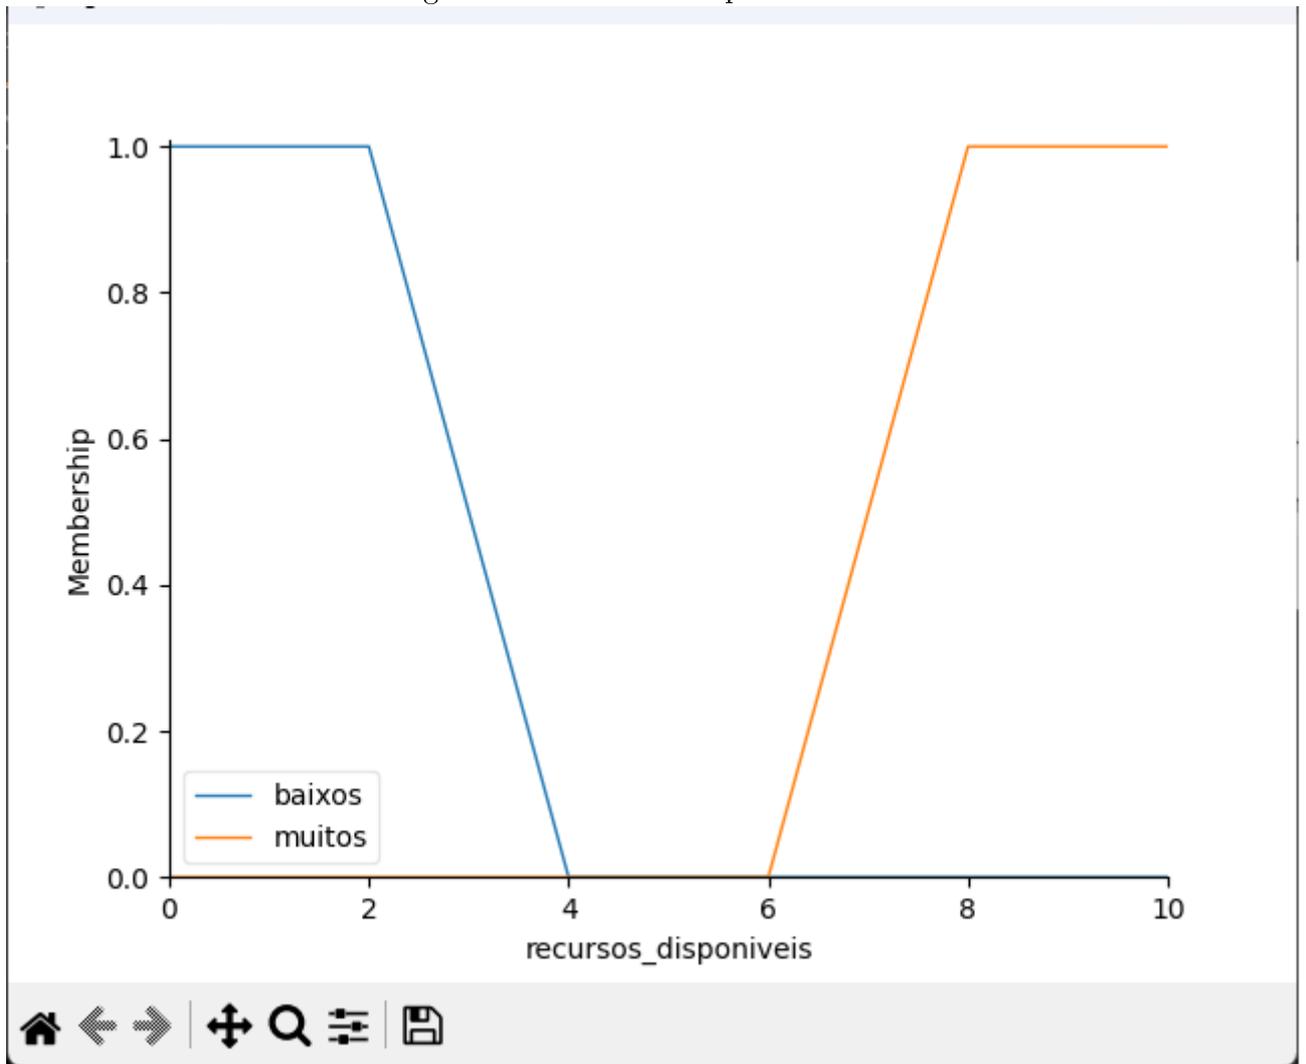


Figura 30: Envolvimento



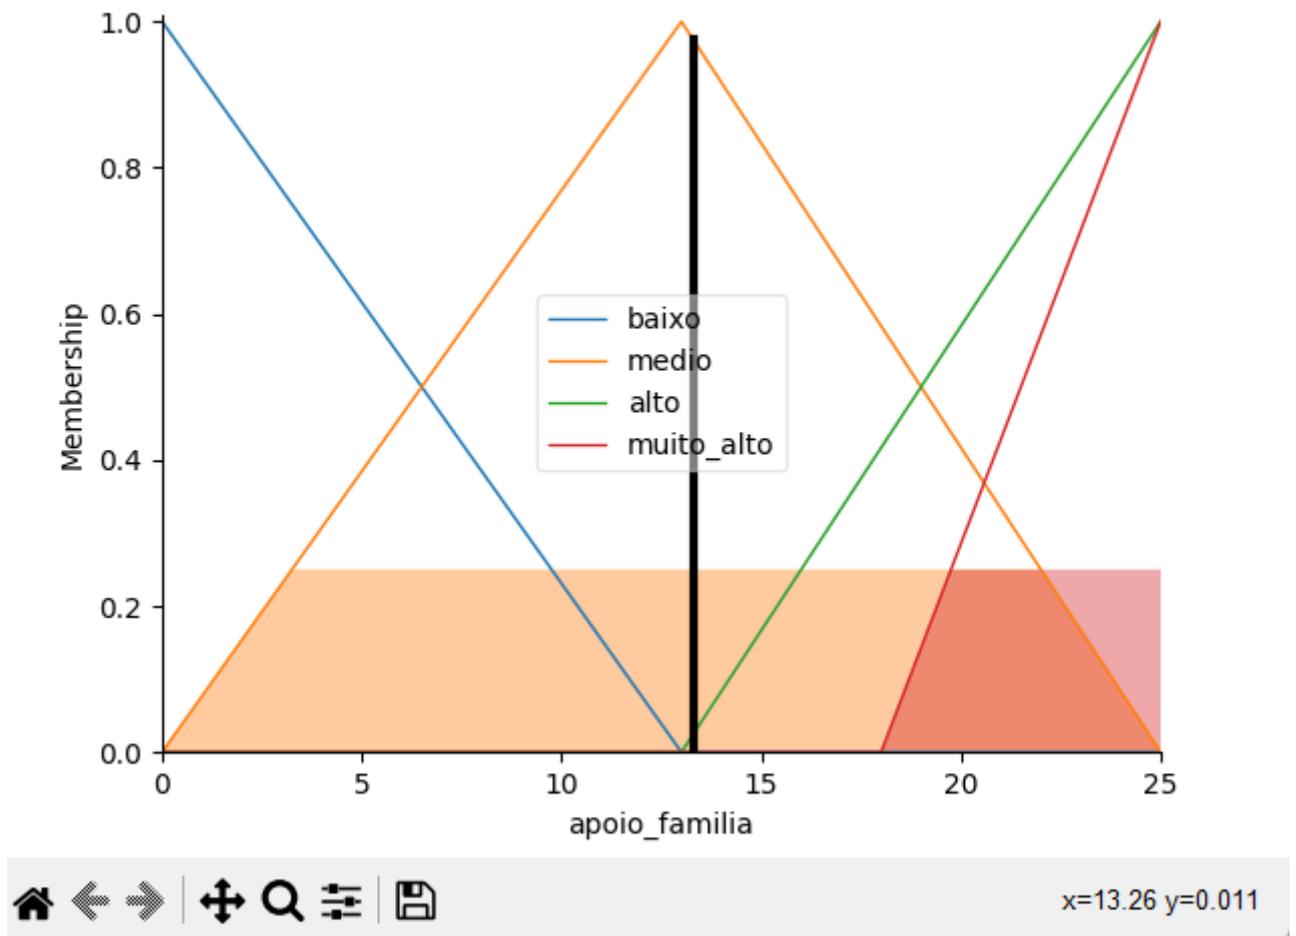
Fonte: <Do próprio autor>

Figura 31: Recursos Disponíveis



Fonte: <Do próprio autor>

Figura 32: Apoio Familiar



Fonte: <Do próprio autor>

Após a defuzzificação tem-se  $13,26/25 = 53,04\%$  de apoio familiar de acordo com as regras utilizadas.

## Ambiente Adequado para Estudar

```
import numpy as np import skfuzzy as fuzz from skfuzzy import control as ctrl import
matplotlib.pyplot as plt

Definindo as variáveis do universo

ambiente = ctrl.Antecedent(np.arange(0, 11, 1), 'ambiente')
equipamento = ctrl.Antecedent(np.arange(0, 11, 1), 'equipamento')
apropriado = ctrl.Consequent(np.arange(0, 26, 1), 'Ambiente adequado')

Função triangular para 'ambiente'
ambiente['distrativo'] = fuzz.trimf(ambiente.universe, [0, 0, 5])
ambiente['silencioso'] = fuzz.trimf(ambiente.universe, [0, 5, 10])

Função trapezoidal para 'equipamento'
equipamento['desorganizado'] = fuzz.trapmf(equipamento.universe, [0, 0, 2, 4])
equipamento['bem equipado'] = fuzz.trapmf(equipamento.universe, [6, 8, 10, 10])

Função triangular para 'adequado'
apropriado['baixo'] = fuzz.trimf(apropriado.universe, [0, 0, 13])
apropriado['moderado'] = fuzz.trimf(apropriado.universe, [0, 13, 25])
apropriado['alto'] = fuzz.trimf(apropriado.universe, [13, 25, 25])
apropriado['muito alto'] = fuzz.trimf(apropriado.universe, [18, 25, 25])

Definindo as regras
regra1 = ctrl.Rule(ambiente['silencioso'] & equipamento['bem equipado'],
apropriado['muito alto'])

regra2 = ctrl.Rule(ambiente['distrativo'] | equipamento['desorganizado'],
apropriado['baixo'])

regra3 = ctrl.Rule(ambiente['silencioso'] | equipamento['bem equipado'],
apropriado['moderado'])

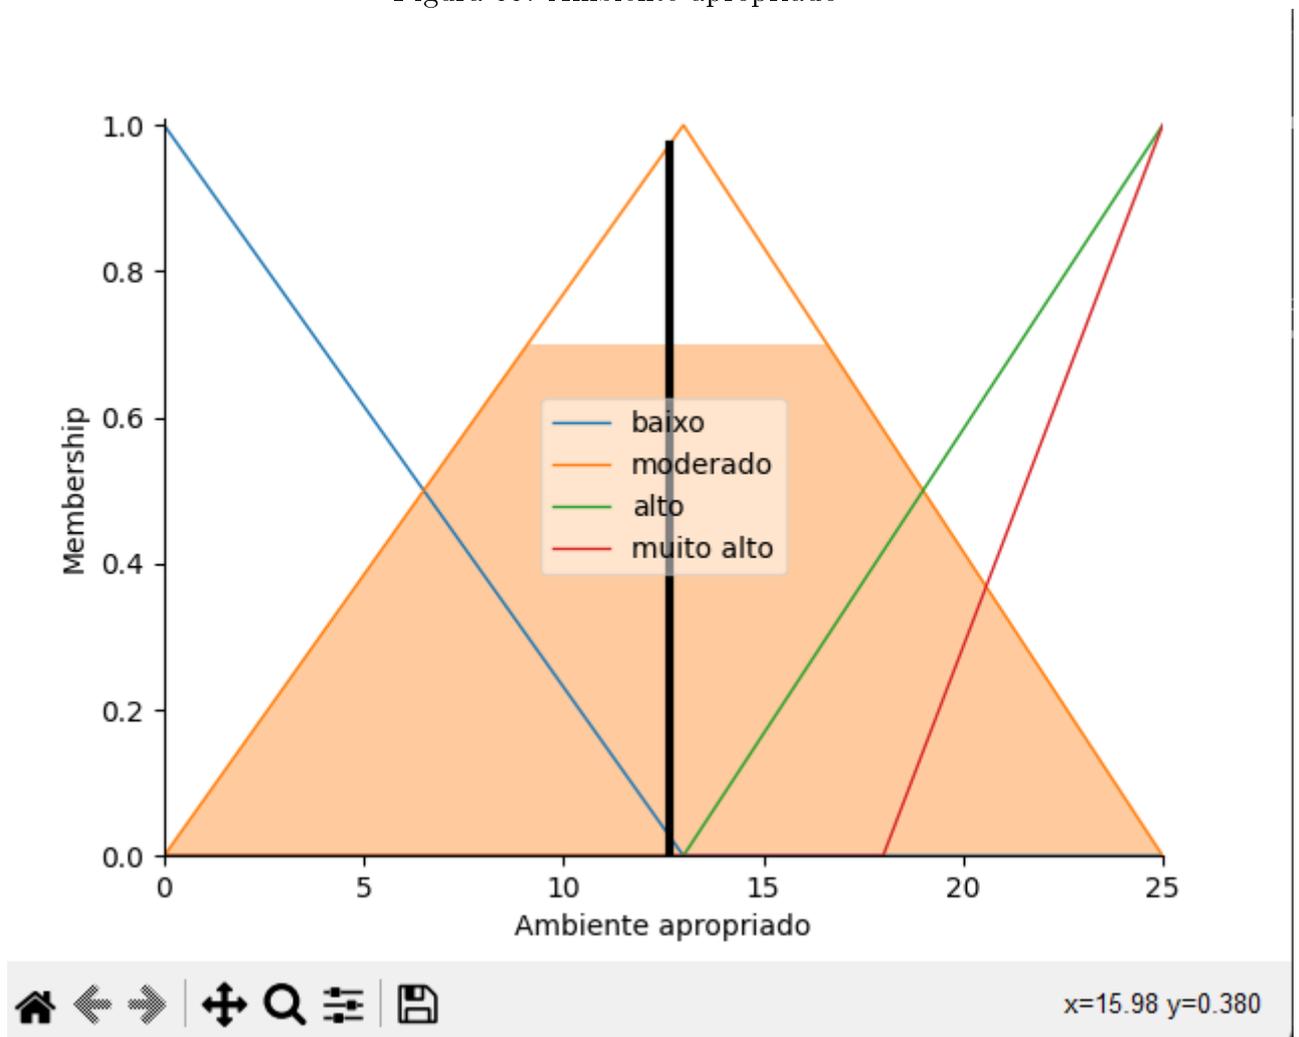
regra4 = ctrl.Rule(equipamento['bem equipado'] & ~ambiente['distrativo'],
apropriado['alto'])

Criando e simulando um controlador fuzzy
controlador = ctrl.ControlSystem([regra1, regra2, regra3, regra4])
simulador = ctrl.ControlSystemSimulation(controlador)
```

```
Passando as entradas e computando o resultado
simulador.input['ambiente'] = 6.5
simulador.input['equipamento'] = 4
simulador.compute()
```

```
Imprimindo e plotando o resultado
print(simulador.output['Ambiente apropriado'])
apropriado.view(sim=simulador)
plt.show()
```

Figura 33: Ambiente apropriado



Fonte: <Do próprio autor>

Após a defuzzificação tem-se  $15,98/25 = 63,92\%$  de Ambiente apropriado de acordo com as regras utilizadas.

## Má Inflência

```
import numpy as np
import skfuzzy as fuzz
from skfuzzy import control as ctrl
import matplotlib.pyplot as plt

Definindo as variáveis do universo
amizades = ctrl.Antecedent(np.arange(0, 11, 1), 'amizades')
comportamentos = ctrl.Antecedent(np.arange(0, 11, 1), 'comportamentos')
ma_influencia = ctrl.Consequent(np.arange(0, 26, 1), 'ma_influencia')

Função triangular para 'amizades'
amizades['negativas'] = fuzz.trimf(amizades.universe, [0, 0, 5])
amizades['neutras'] = fuzz.trimf(amizades.universe, [0, 5, 10])
amizades['positivas'] = fuzz.trimf(amizades.universe, [5, 10, 10])

Função trapezoidal para 'comportamentos'
comportamentos['negativos']=fuzz.trapmf(comportamentos.universe, [0, 0, 2, 4])
comportamentos['neutros']=fuzz.trapmf(comportamentos.universe, [2, 4, 6, 8])
comportamentos['positivos']=fuzz.trapmf(comportamentos.universe, [6, 8, 10, 10])

Função triangular para 'ma_influencia'
ma_influencia['baixa'] = fuzz.trimf(ma_influencia.universe, [0, 0, 13])
ma_influencia['moderada'] = fuzz.trimf(ma_influencia.universe, [0, 13, 25])
ma_influencia['alta'] = fuzz.trimf(ma_influencia.universe, [13, 25, 25])
ma_influencia['muito alta'] = fuzz.trimf(ma_influencia.universe, [18, 25, 25])

Definindo as regras
regra1 = ctrl.Rule(amizades['positivas'] & comportamentos['positivos'],
    ma_influencia['baixa'])

regra2 = ctrl.Rule(amizades['neutras'] | comportamentos['negativos'],
    ma_influencia['alta'])

regra3 = ctrl.Rule(amizades['positivas'] & comportamentos['neutros'],
    ma_influencia['moderada'])

regra4 = ctrl.Rule(amizades['neutras'] | comportamentos['negativos'],
    ma_influencia['alta'])
```

```
regra5 = ctrl.Rule(amizades['neutras'] | comportamentos['negativos'],
ma_influencia['moderada'])

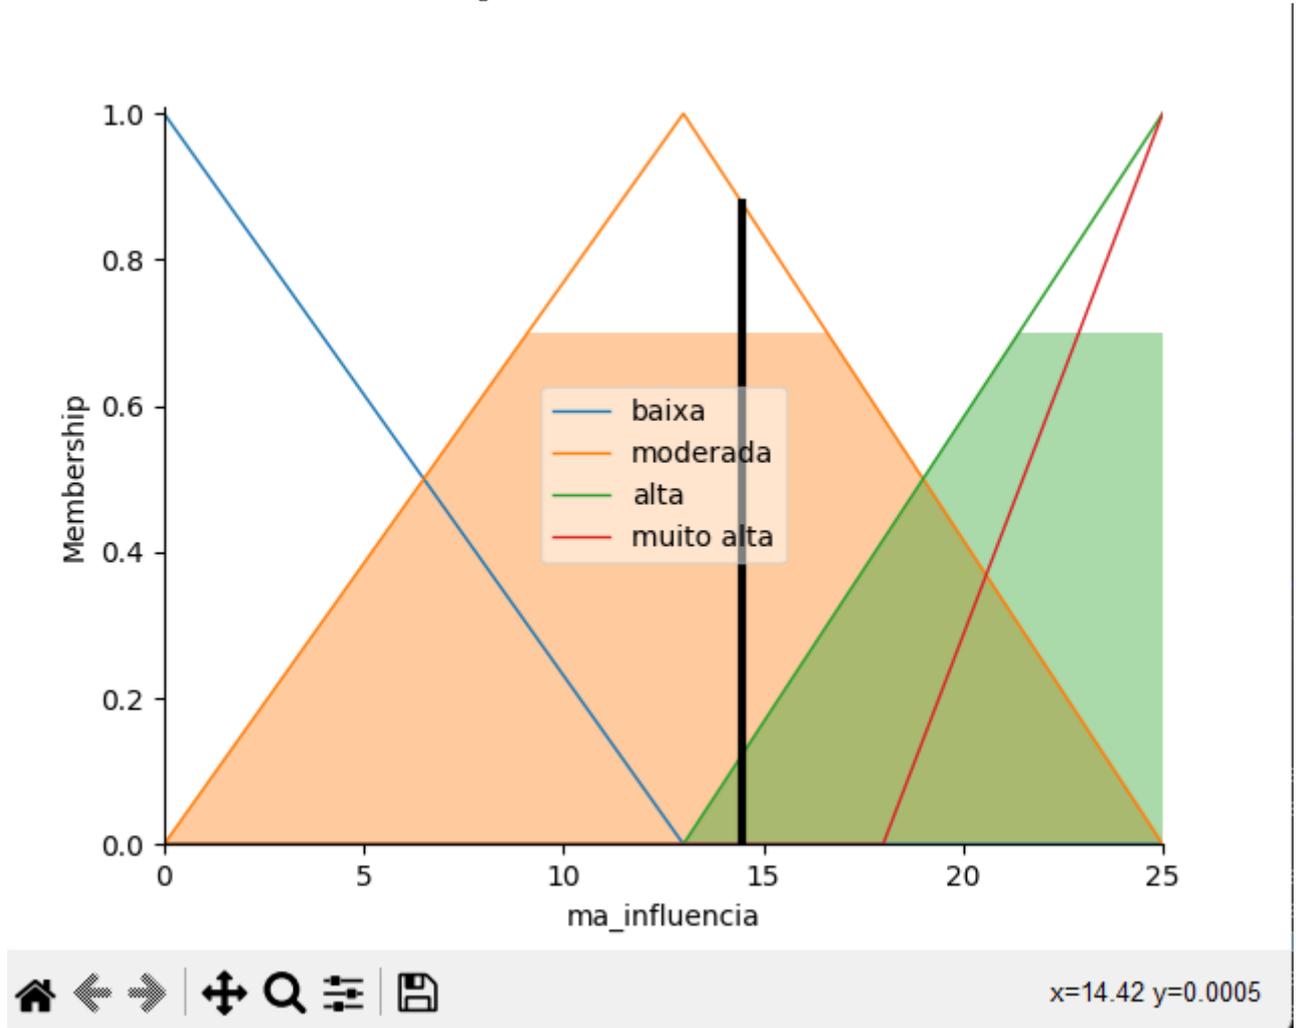
regra6 = ctrl.Rule(amizades['negativas'] & comportamentos['negativos'],
ma_influencia['muito alta'])

Criando e simulando um controlador fuzzy
controlador = ctrl.ControlSystem([regra1, regra2, regra3, regra4,
regra5, regra6])
simulador = ctrl.ControlSystemSimulation(controlador)

Passando as entradas e computando o resultado
simulador.input['amizades'] = 6.5
simulador.input['comportamentos'] = 4
simulador.compute()

Imprimindo e plotando o resultado
print(simulador.output['ma_influencia'])
ma_influencia.view(sim=simulador)
plt.show()
```

Figura 34: Má influência



Fonte: <Do próprio autor>

Após a defuzzificação tem-se  $14,42/25 = 57,68\%$  de má influência de acordo com as regras utilizadas.

## Ociosidade (ficar sem produzir)

```
import numpy as np
import skfuzzy as fuzz
from skfuzzy import control as ctrl
import matplotlib.pyplot as plt

Definindo as variáveis do universo
tempo_livre = ctrl.Antecedent(np.arange(0, 11, 1), 'tempo_livre')
atividades_produtivas = ctrl.Antecedent(np.arange(0, 11, 1),
'atividades_produtivas')
ociosidade = ctrl.Consequent(np.arange(0, 26, 1), 'ociosidade')

Função triangular para 'tempo_livre'
tempo_livre['baixo'] = fuzz.trimf(tempo_livre.universe, [0, 0, 5])
tempo_livre['moderado'] = fuzz.trimf(tempo_livre.universe, [0, 5, 10])
tempo_livre['muito'] = fuzz.trimf(tempo_livre.universe, [5, 10, 10])

Função trapezoidal para 'atividades_produtivas'
atividades_produtivas['baixa'] = fuzz.trapmf(atividades_produtivas.universe,
[0, 0, 2, 4])
atividades_produtivas['média'] = fuzz.trapmf(atividades_produtivas.universe,
[2, 4, 6, 8])
atividades_produtivas['alta'] = fuzz.trapmf(atividades_produtivas.universe,
[6, 8, 10, 10])

ociosidade['baixa'] = fuzz.trimf(ociosidade.universe, [0, 0, 13])
ociosidade['moderada'] = fuzz.trimf(ociosidade.universe, [0, 13, 25])
ociosidade['alta'] = fuzz.trimf(ociosidade.universe, [13, 25, 25])

Definindo as regras
regra1 = ctrl.Rule(tempo_livre['baixo'], ocosidade['alta'])

regra2 = ctrl.Rule(atividades_produtivas['alta'], ocosidade['baixa'])

regra3 = ctrl.Rule(tempo_livre['baixo'] | atividades_produtivas['baixa'],
ociosidade['alta'])

regra4 = ctrl.Rule(tempo_livre['moderado'] & atividades_produtivas['média'],
ociosidade['moderada'])
```

```

regra5 = ctrl.Rule(tempo_livre['muito'] & atividades_produtivas['alta'],
    ociosidade['baixa'])

regra6 = ctrl.Rule(tempo_livre['baixo'] & atividades_produtivas['alta'],
    ociosidade['alta'])

Criando e simulando um controlador fuzzy
controlador = ctrl.ControlSystem([regra1, regra2, regra3, regra4,
    regra5, regra6])
simulador = ctrl.ControlSystemSimulation(controlador)

Passando as entradas e computando o resultado
simulador.input['tempo_livre'] = 6.5
simulador.input['atividades_produtivas'] = 4
simulador.compute()

Imprimindo e plotando o resultado
print(simulador.output['ociosidade'])
ociosidade.view(sim=simulador)
atividades_produtivas.view(sim=simulador)
plt.show()

```

Após a defuzzificação tem-se  $12,55/25 = 50,02\%$  de ociosidade de acordo com as regras utilizadas.

### 3.2.1 Regras Integradas

Se Dedicção é Alta E Apoio da Família é Alto E Não Ociosidade é Alta E Má Influência é Baixa E Ambiente Adequado é Alto, então Probabilidade de Sucesso é Muito Alta.

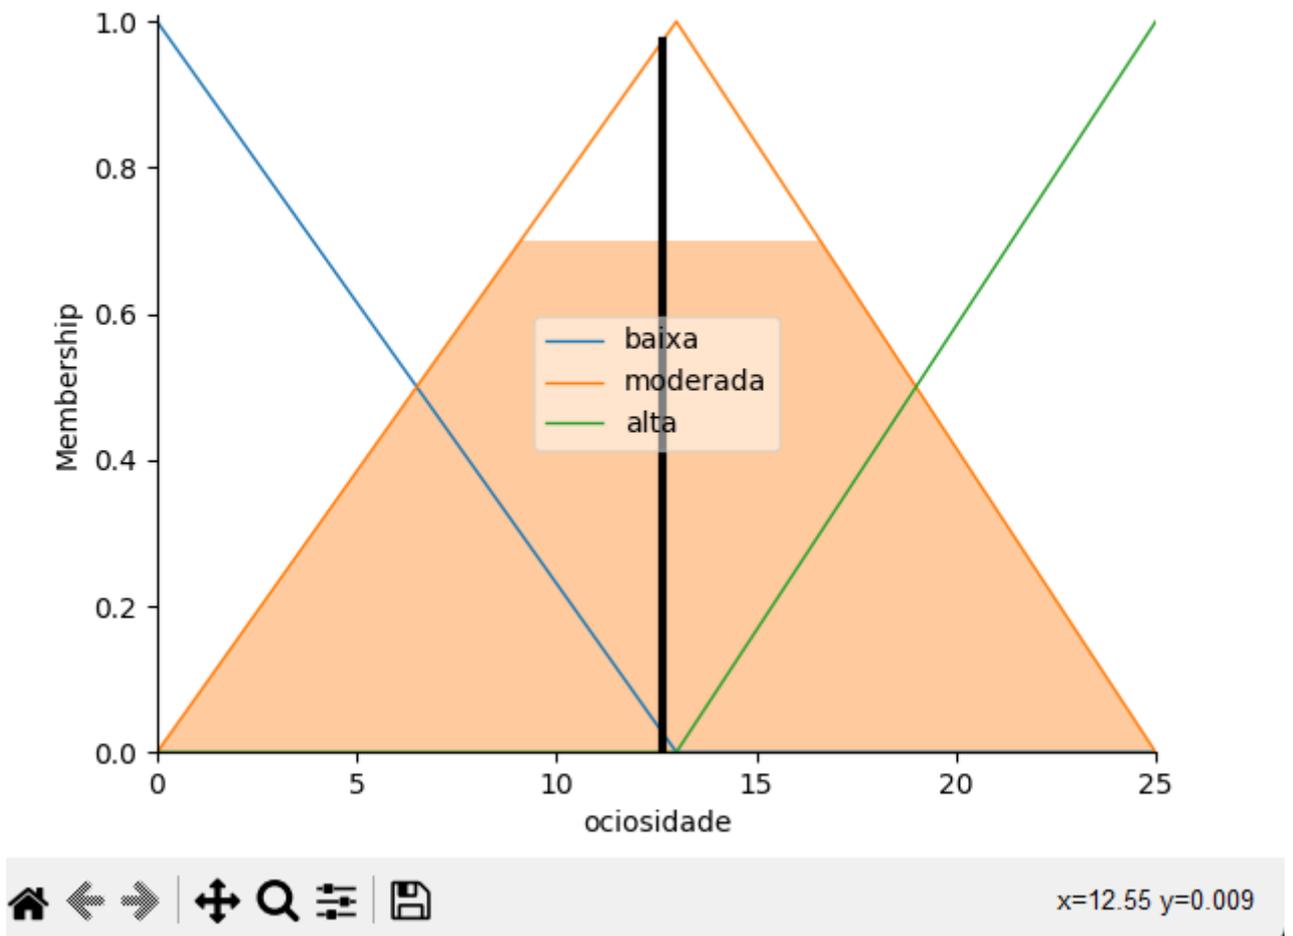
Se Dedicção é Média OU Apoio da Família é Baixo OU Não Ociosidade é Baixa OU Má Influência é Alta OU Ambiente Adequado é Baixo, então Probabilidade de Sucesso é Baixa.

Regras que levam em consideração a interação de todas as variáveis.

Avaliação Fuzzy Geral:

Probabilidade de Sucesso: Atribuir graus fuzzy para diferentes níveis de probabilidade

Figura 35: Ociosidade



Fonte: <Do próprio autor>

de sucesso, considerando a influência combinada das variáveis. Utilizar variáveis fuzzy fornece uma abordagem mais flexível e adaptativa para modelar a complexidade desses conceitos, levando em consideração a incerteza e a subjetividade associadas a cada um deles.

```
import numpy as np
import skfuzzy as fuzz
from skfuzzy import control as ctrl
import matplotlib.pyplot as plt
```

Definindo as variáveis do universo

```
dedicacao = ctrl.Antecedent(np.arange(0, 26, 1), 'dedicacao')
apoio_familia = ctrl.Antecedent(np.arange(0, 11, 1), 'apoio_familia')
nao_ociosidade = ctrl.Antecedent(np.arange(0, 11, 1), 'nao_ociosidade')
ma_influencia = ctrl.Antecedent(np.arange(0, 11, 1), 'ma_influencia')
ambiente_apropriado = ctrl.Antecedent(np.arange(0, 11, 1),
    'ambiente_apropriado')
probabilidade_sucesso = ctrl.Consequent(np.arange(0, 101, 1),
```

```
'probabilidade_sucesso')
```

Definindo as funções de pertinência

```
dedicacao['baixa'] = fuzz.trimf(dedicacao.universe, [0, 0, 13])
dedicacao['media'] = fuzz.trimf(dedicacao.universe, [0, 13, 25])
dedicacao['alta'] = fuzz.trimf(dedicacao.universe, [13, 25, 25])
```

Definindo funções de pertinência para apoio\_familia

```
apoio_familia['baixa'] = fuzz.trimf(apoio_familia.universe, [0, 0, 5])
apoio_familia['media'] = fuzz.trimf(apoio_familia.universe, [0, 5, 10])
apoio_familia['alta'] = fuzz.trimf(apoio_familia.universe, [5, 10, 10])
```

Definindo funções de pertinência para nao\_ociosidade

```
nao_ociosidade['baixa'] = fuzz.trimf(nao_ociosidade.universe, [0, 0, 5])
nao_ociosidade['media'] = fuzz.trimf(nao_ociosidade.universe, [0, 5, 10])
nao_ociosidade['alta'] = fuzz.trimf(nao_ociosidade.universe, [5, 10, 10])
```

Definindo funções de pertinência para ma\_influencia

```
ma_influencia['baixa'] = fuzz.trimf(ma_influencia.universe, [0, 0, 5])
ma_influencia['media'] = fuzz.trimf(ma_influencia.universe, [0, 5, 10])
ma_influencia['alta'] = fuzz.trimf(ma_influencia.universe, [5, 10, 10])
```

Definindo funções de pertinência para ambiente\_apropriado

```
ambiente_apropriado['baixo'] = fuzz.trimf(ambiente_apropriado.universe,
[0, 0, 5])
ambiente_apropriado['medio'] = fuzz.trimf(ambiente_apropriado.universe,
[0, 5, 10])
ambiente_apropriado['alto'] = fuzz.trimf(ambiente_apropriado.universe,
[5, 10, 10])
```

Definindo funções de pertinência para a variável de saída

```
probabilidade_sucesso['muito_baixo'] =
fuzz.trimf(probabilidade_sucesso.universe,
[0, 0, 20])
probabilidade_sucesso['baixo'] = fuzz.trimf(probabilidade_sucesso.universe,
[0, 20, 40])
probabilidade_sucesso['medio'] = fuzz.trimf(probabilidade_sucesso.universe,
[20, 40, 60])
probabilidade_sucesso['alto'] = fuzz.trimf(probabilidade_sucesso.universe,
```

```

[40, 60, 80])
probabilidade_sucesso['muito_alto']=fuzz.trimf(probabilidade_sucesso.universe,
[60, 80, 100])

Definindo regras fuzzy
regra1 = ctrl.Rule(dedicacao['alta'] & apoio_familia['alta']
& nao_ociosidade['alta'] &
ma_influencia['alta'] & ambiente_apropriado['alto'],
probabilidade_sucesso['muito_alto'])
regra2 = ctrl.Rule(dedicacao['media'] | apoio_familia['baixa']
| nao_ociosidade['baixa'] |
ma_influencia['alta'] | ambiente_apropriado['baixo'],
probabilidade_sucesso['baixo'])

Criando e simulando o sistema de controle
sistema_controle = ctrl.ControlSystem([regra1, regra2])
simulacao = ctrl.ControlSystemSimulation(sistema_controle)

Testando o sistema de controle
simulacao.input['dedicacao'] = 20
simulacao.input['apoio_familia'] = 8
simulacao.input['nao_ociosidade'] = 9
simulacao.input['ma_influencia'] = 8
simulacao.input['ambiente_apropriado'] = 8
simulacao.compute()

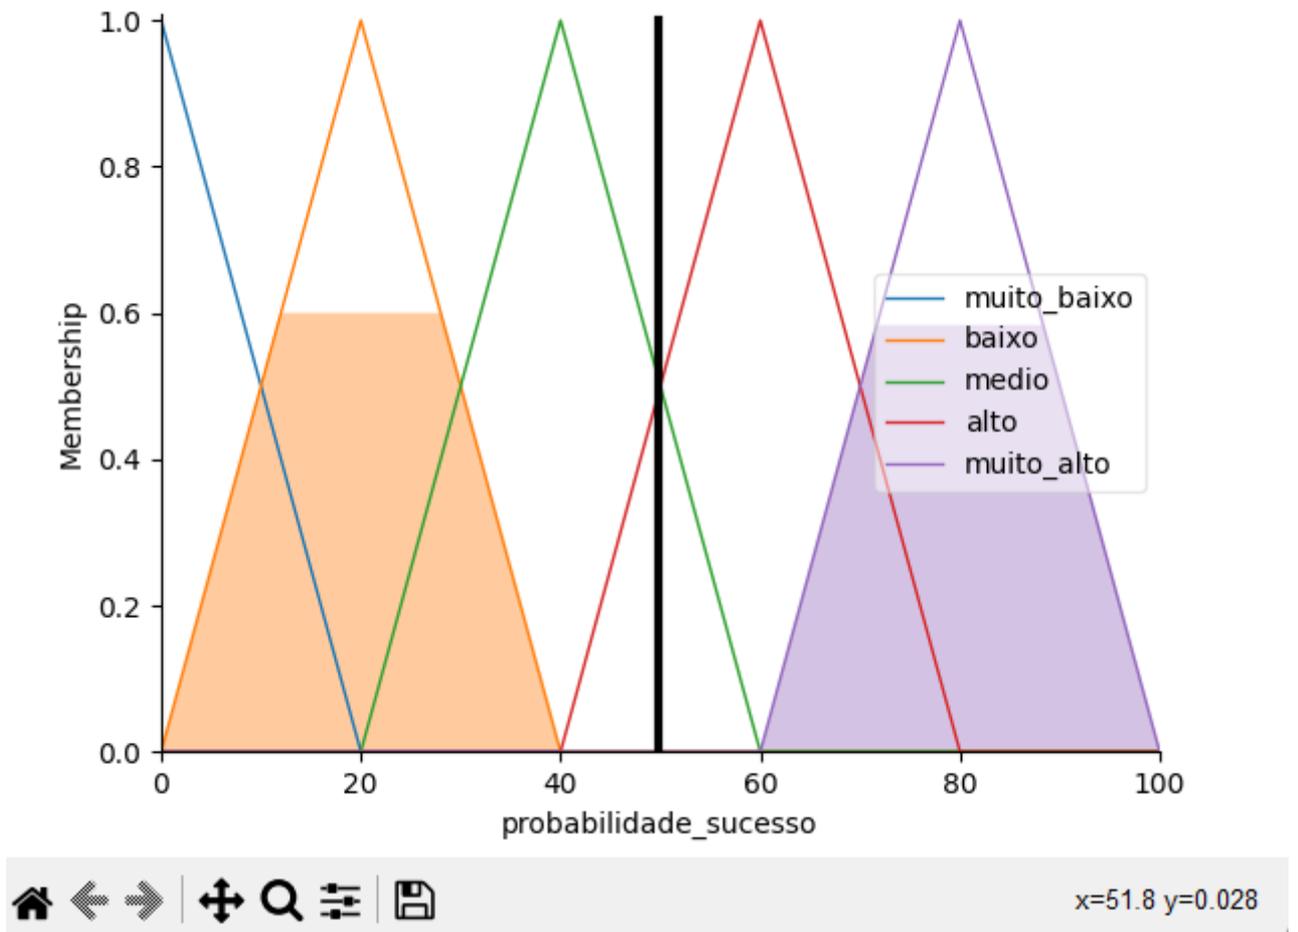
Visualizando as funções de pertinência
dedicacao.view()
apoio_familia.view()
nao_ociosidade.view()
ma_influencia.view()
ambiente_apropriado.view()
probabilidade_sucesso.view(sim=simulacao)

Exibindo o resultado da simulação
print("Probabilidade de Sucesso:",
simulacao.output['probabilidade_sucesso'])

plt.show()

```

Figura 36: Chances de Sucesso



Fonte: <Do próprio autor>

## 4 Considerações Finais

A presente dissertação de mestrado teve como objetivo principal analisar as bases teóricas da lógica fuzzy e sua aplicação em sistemas de diagnóstico, com foco no desenvolvimento de um modelo fuzzy em Python para avaliar o desempenho acadêmico dos alunos. Além disso, buscou-se coletar dados sobre as atitudes, crenças e experiências dos profissionais em ambiente escolar, a fim de avaliar a efetividade do modelo proposto.

Um sistema fuzzy foi implementado em Python para controlar um processo dinâmico, demonstrando sua eficácia no controle do sistema e na obtenção do desempenho desejado.

Os resultados da pesquisa demonstram o potencial da Lógica Fuzzy como ferramenta para a resolução de problemas complexos em diferentes áreas do conhecimento. A versatilidade da Lógica Fuzzy, combinada com sua capacidade de lidar com a incerteza e a imprecisão, a torna uma ferramenta valiosa para o desenvolvimento de sistemas de modelagem e controle em diversos contextos.

A implementação de um sistema baseado em Lógica Fuzzy (SLF) para auxiliar no diagnóstico escolar pode trazer benefícios significativos, como a automatização de tarefas, a análise de dados complexos e a tomada de decisões mais precisas. No entanto, para garantir a efetividade e confiabilidade do sistema, é crucial realizar uma avaliação rigorosa.

Como métodos de Validação e avaliação recomenda-se verificar se as regras fuzzy e as funções de pertinência estão bem definidas, consistentes e alinhadas com os objetivos do diagnóstico. Para tanto, faz-se importante submeter o SLF à avaliação de especialistas em educação, psicologia e Lógica Fuzzy para identificar possíveis falhas ou inconsistências. Além disso, recomenda-se, também, o teste do SLF com diferentes valores de entrada e observar como as saídas se modificam, verificando a robustez do sistema.

Como métodos de Avaliação, é fundamental medir a porcentagem de casos em que o SLF fornece o diagnóstico correto, comparando com os resultados de especialistas. Assim é possível medir os tipos de erros cometidos pelo SLF e investigar as causas, buscando aprimorar o sistema. É fundamental medir o tempo que o SLF leva para realizar um diagnóstico e verificar se atende às necessidades da prática escolar. Contudo, é de suma importância o envolvimento de especialistas em educação, psicologia e Lógica Fuzzy no processo de avaliação para garantir a qualidade e a confiabilidade dos resultados.

Ao combinar diferentes métodos de validação e avaliação, envolver especialistas e realizar o processo de forma iterativa, é possível aprimorar continuamente o sistema e alcançar os melhores resultados na prática educacional.

Portanto a Lógica Fuzzy se configura como uma ferramenta eficaz para auxiliar no diagnóstico escolar, promovendo uma educação mais personalizada, eficaz e inclusiva. A pesquisa apresentada nesta dissertação contribui significativamente para esse objetivo, abrindo caminho para um futuro promissor na educação.

## Referências

- [1] Zadeh, L. A. (1965). Fuzzy sets. *Information and Control*, 8(3), 338-353.
- [2] Klir, G. J., & Yuan, B. (1995). Fuzzy sets and fuzzy logic: theory and applications. Prentice Hall.
- [3] Dubois, D., & Prade, H. (1980). Fuzzy sets and systems: Theory and applications. Academic Press.
- [4] Pedrycz, W. (1984). Engineering applications of fuzzy sets. *IEEE Transactions on Systems, Man, and Cybernetics*, 14(6), 841-850.
- [5] Mamdani, E. H., & Assilian, S. (1975). An experiment in linguistic synthesis with a fuzzy logic controller. *International Journal of Man-Machine Studies*, 7(1), 1-13.
- [6] Bezdek, J. C. (1981). Pattern recognition with fuzzy objective function algorithms. Plenum Press.
- [7] Dubois, D., e Prade, H. (2000). Fuzzy sets and systems: theory and applications. Academic Press.
- [8] Dubois, D., & Prade, H. (2015). A review of fuzzy set aggregation connectives. *Information Sciences*, 291, 184-208.
- [9] Goguen, J. L. (1969). The fuzzy ontology: A new foundation for 'reasoning about vagueness'. In Proceedings of the 1969 international symposium on multiple-valued logic (pp. 1-17).
- [10] Wang, L. X., & Li, Y. (2021). Fuzzy systems for big data processing: Recent advances and future challenges. *IEEE Transactions on Fuzzy Systems*, 29(8), 2217-2232.
- [11] Klir, G. J. (2019). Uncertainty and information: Foundations of generalized information theory. John Wiley & Sons.
- [12] Jang, J. S., Sun, C. T., e Mizutani, E. (1997). Neuro-fuzzy modeling and control. Prentice Hall.
- [13] Python Machine Learning (Sebastián Raschka e Vahid Mirjalili): This book covers machine learning algorithms in Python, including chapters on fuzzy logic integration.
- [14] <https://pythonhosted.org/scikit-fuzzy/overview.html>

- [15] Dubois, D., e Prade, H. (2012). Fuzzy sets and systems: Theory and applications. Springer Science e Business Media.
- [16] Araujo, R. B., et al. (2016). Sistema de Apoio à Decisão para Diagnóstico de Dificuldades de Aprendizagem em Matemática com Base em Lógica Fuzzy. Revista Brasileira de Educação, 21(1), 148-163. <https://www.scielo.br/j/rbedu/>
- [17] COUPLAND, Simon. Type-2 fuzzy control of a mobile Robot. Centre for Computational Intelligence De Montfort University, UK, v. 1, p. 25, 2003.
- [18] VON ALTROCK, Constantin. Fuzzy logic and neuroFuzzy applications in busines and finance. New Jersey: Prentice Hall PTR, 1996.
- [19] BRASIL. Ministério da Educação. Base nacional comum curricular. Brasília, [2017]. Disponível em: Base Nacional Comum Curricular (BNCC) - Ministério da Educação.
- [20] MITTELSTADT, Brent Daniel et al. The ethics of algorithms: Mapping the debate. Big Data & Society, v. 3, n. 2, p. 2053951716679679, 2016.
- [21] LEE, Minho; LEE, Soo-Young; PARK, Cheol Hoon. Neurofuzzy controller design using neurofuzzy identifier. International Journal of Approximate Reasoning, v. 13, n. 4, p. 269-285, 1995.
- [22] LÜCK, Heloísa. As exigências do novo milênio ao ensino brasileiro. Gestão em Rede, Brasília: CONSED, n. 74, p. 13 – 18. Nov. 2006.
- [23] FREITAS, Kátia Siqueira. SOUSA, José Vieira. Progestão: como articular a gestão pedagógica da escola com as políticas públicas da educação para melhoria do desempenho escolar? Módulo X. Brasília: CONSED, 2009.