

PGCOMP - Programa de Pós-Graduação em Ciência da Computação
Universidade Federal da Bahia (UFBA)
Av. Milton Santos, s/n - Ondina
Salvador, BA, Brasil, 40170-110

<https://pgcomp.ufba.br>
pgcomp@ufba.br

A representação computacional do conhecimento humano, quando composto por dados imprecisos, é uma tarefa facilitada pela utilização de sistemas que utilizam recursos da teoria de conjuntos e lógica fuzzy. Tais sistemas usam regras que permitem mapear o conhecimento obtido a partir dos dados em uma representação linguística de fácil entendimento. A base de regras fuzzy que constitui parte desse sistema pode ser gerada por um especialista ou por meio de métodos que consideram as características dos próprios dados, diminuindo a necessidade de um especialista neste processo de criação. Com os devidos ajustes e utilização de métodos automatizados é possível aumentar a interpretabilidade dessas regras sem reduzir a precisão do sistema. Neste sentido, a base de regras de um sistema fuzzy pode ser melhorada por meio do princípio da granularidade justificável para ajustar os conjuntos fuzzy representativos dos dados. Sendo assim, nesta dissertação de mestrado é proposto o método denominado GENI-FR (Granularity to Ensure Interpretability of the Fuzzy Rules), o qual realiza ajustes e refinamentos no processo de geração de regras fuzzy, obtendo o equilíbrio entre interpretabilidade e precisão, ajustando conjuntos fuzzy baseando-se nas características dos próprios dados. GENI-FR apresenta-se como um método promissor visto que proporciona uma redução da quantidade de regras fuzzy mantendo os mesmos níveis de acurácia quando comparado com outros métodos do estado da arte.

Palavras-chave: regras fuzzy, funções de pertinência, sistemas fuzzy baseados em regras, interpretabilidade, granularidade e especificidade, termos linguísticos

| 170 |

GENI-FR: Um método para assegurar a interpretabilidade de regras fuzzy por meio de granularidade

Genicleito Carvalho
Beltrão Gonçalves

GENI-FR: Um método para assegurar a interpretabilidade de regras fuzzy por meio de granularidade

Genicleito Carvalho Beltrão Gonçalves

Dissertação de Mestrado

Universidade Federal da Bahia

Programa de Pós-Graduação em
Ciência da Computação

Novembro |

UFBA





UNIVERSIDADE FEDERAL DA BAHIA

DISSERTAÇÃO DE MESTRADO

GENI-FR: Um método para assegurar a interpretabilidade de regras fuzzy por meio de granularidade

Genicleito Carvalho Beltrão Gonçalves

Programa de Pós-Graduação em Ciência da Computação

Salvador
30 de novembro de 2023

PGCOMP-Msc-2023

GENICLEITO CARVALHO BELTRÃO GONÇALVES

**GENI-FR: UM MÉTODO PARA ASSEGURAR A
INTERPRETABILIDADE DE REGRAS FUZZY POR MEIO DE
GRANULARIDADE**

Esta Dissertação de Mestrado foi apresentada ao Programa de Pós-Graduação em Ciência da Computação da Universidade Federal da Bahia, como requisito parcial para obtenção do grau de Mestre em Ciência da Computação.

Orientadora: Profa. Dra. Tatiane Nogueira Rios

Salvador
30 de novembro de 2023

Ficha catalográfica.

G635 Gonçalves, Genicleito Carvalho Beltrão

GENI-FR: Um método para assegurar a interpretabilidade de regras fuzzy por meio de granularidade/ Genicleito Carvalho Beltrão Gonçalves– Salvador, 30 de novembro de 2023.

50p.: il.

Orientadora: Profa. Dra. Tatiane Nogueira Rios.
Dissertação (Mestrado)– UNIVERSIDADE FEDERAL DA BAHIA, INSTITUTO DE COMPUTAÇÃO, 30 de novembro de 2023.

1. Fuzzy Rules, 2. Fuzzy Rule-Based Systems, 3. Interpretability, 3. Principle of Justifiable Granularity, 4. Coverage and Specificity, 5. Fuzzy Membership Function.

I. Rios, Tatiane Nogueira. II. UNIVERSIDADE FEDERAL DA BAHIA. INSTITUTO DE COMPUTAÇÃO. III Título.

CDU – 004.8



“GEnI-FR: Um método para assegurar a interpretabilidade de regras fuzzy por meio de granularidade”

Genicleito Carvalho Beltrao Goncalves

Dissertação apresentada ao Colegiado do Programa de Pós-Graduação em Ciência da Computação na Universidade Federal da Bahia, como requisito parcial para obtenção do Título de Mestre em Ciência da Computação.

Banca Examinadora



Documento assinado digitalmente

TATIANE NOGUEIRA RIOS

Data: 11/12/2023 14:00:32-0300

Verifique em <https://validar.iti.gov.br>

Prof^ª. Dr^ª. Tatiane Nogueira Rios (Orientadora - PGCOMP)



Documento assinado digitalmente

HELOISA DE ARRUDA CAMARGO

Data: 11/12/2023 12:47:41-0300

Verifique em <https://validar.iti.gov.br>

Prof^ª. Dr^ª. Heloisa de Arruda Camago (UFSCar)



Documento assinado digitalmente

MARCOS EVANDRO CINTRA

Data: 11/12/2023 13:51:46-0300

Verifique em <https://validar.iti.gov.br>

Prof. Dr. Marcos Evandro Cintra (UFES)

O mais importante nunca parar de questionar. A curiosidade tem uma razão para existir... Nunca perca sua sagrada curiosidade.

– Albert Einstein

AGRADECIMENTOS

É com imensa felicidade que chego neste momento de dar um importante passo na minha vida com a conclusão do mestrado. Celebro todos os momentos de descobertas e aprendizados que tive a oportunidade de vivenciar nesta universidade desde o início da graduação até o momento de conclusão do mestrado. Desde a graduação em Ciência da Computação, tem aflorado em mim a vontade de investigar, propor e melhorar descobertas que já foram propostas e compartilhadas com a academia e para a sociedade em tempos anteriores ao meu.

A Universidade foi e é um divisor de águas na forma como vejo e interajo com o mundo. Este é um sentimento cultivado desde meu ensino médio, onde tive professores com uma paixão incrível em fazer acontecer e transformar a vida de jovens de escola pública. Por meio desta vontade e desta rede eu pude conhecer e fazer parte da Universidade. Deste modo, eu deixo um agradecimento super especial aos meus professores, todos eles, que já compartilharam conhecimento por um dia ou por um ano e assim preencheram os degraus que me fizeram chegar aqui hoje, na qualificação do mestrado.

Deixo um agradecimento ainda mais especial aos meus pais, que protagonizaram um dos meus primeiros desafios no mestrado: explicar o que eu pesquiso de uma forma didática para que todos entendem e assim seja um conhecimento democrático. Eles são peças essenciais desde os meus primeiros passos acadêmicos ao desbravar a universidade em uma cidade longe de casa. Estou muito feliz por poder realizar mais essa conquista ao defender a minha proposta de mestrado, algo que nunca imaginei estar vivendo quando eu era apenas um garoto de 17 anos recém-imerso no mundo da universidade e sonhando em ser o primeiro da minha família a ter um diploma de graduação (e agora o primeiro a ter o título de mestre).

Agradeço enormemente à minha orientadora, professora Dra. Tatiane Nogueira Rios. Além de excelente professora, que apresentou e fez despertar em mim o desejo pela pesquisa e por conhecer bem mais a área de sistemas fuzzy desde a graduação em uma aula de Prolog na disciplina de IA, prestou um trabalho de orientação essencial para que eu conseguisse modelar, construir, validar e compartilhar este trabalho elaborado no decorrer destes últimos anos.

Agradeço ao corpo docente do Programa de Pós-Graduação em Ciência da Computação (PGCOMP) por todos os conhecimentos compartilhados por profissionais de excelência que, em sua maioria, me acompanham desde a graduação.

RESUMO

A representação computacional do conhecimento humano, quando composto por dados imprecisos, é uma tarefa facilitada pela utilização de sistemas que utilizam recursos da teoria de conjuntos e lógica fuzzy. Tais sistemas usam regras que permitem mapear o conhecimento obtido a partir dos dados em uma representação linguística de fácil entendimento. A base de regras fuzzy que constitui esse tipo de sistema pode ser gerada por um especialista ou por meio de métodos que consideram as características dos próprios dados, diminuindo a necessidade de um especialista neste processo de criação. Com os devidos ajustes e utilização de métodos automatizados é possível aumentar a interpretabilidade dessas regras sem reduzir a precisão do sistema. Neste sentido, a base de regras de um sistema fuzzy pode ser melhorada por meio do princípio da granularidade justificável para ajustar os conjuntos fuzzy representativos dos dados. Sendo assim, nesta dissertação de mestrado é apresentado o método denominado GEnI-FR (Granularity to Ensure Interpretability of the Fuzzy Rules), o qual realiza ajustes e refinamentos no processo de geração de regras fuzzy, obtendo o equilíbrio entre interpretabilidade e precisão, ajustando conjuntos fuzzy baseando-se nas características dos próprios dados. GEnI-FR apresenta-se como um método promissor visto que proporciona uma redução da quantidade de regras fuzzy mantendo os mesmos níveis de acurácia quando comparado com outros métodos do estado da arte.

Palavras-chave: regras fuzzy, sistemas fuzzy baseados em regras, interpretabilidade, granularidade e especificidade, termos linguísticos

ABSTRACT

The computational representation of human knowledge, when composed of imprecise data, is a task facilitated by the use of systems that use resources from set theory and fuzzy logic. Such systems use rules that allow mapping the knowledge obtained from data into an easy-to-understand linguistic representation. The fuzzy rule base that constitutes this type of system can be generated by a specialist or through methods that consider the characteristics of the data itself, reducing the need for a specialist in this creation process. With the appropriate adjustments and use of automated methods, it is possible to increase the interpretability of these rules without reducing the system's accuracy. In this sense, the rule base of a fuzzy system can be improved through the principle of justifiable granularity to adjust the fuzzy sets representative of the data. Therefore, in this master's thesis, the method called GEnI-FR (Granularity to Ensure Interpretability of the Fuzzy Rules) is proposed, which makes adjustments and refinements in the process of generating fuzzy rules, achieving a balance between interpretability and precision, adjusting sets fuzzy based on the characteristics of the data itself. GEnI-FR presents itself as a promising method as it provides a reduction in the number of fuzzy rules while maintaining the same levels of accuracy when compared to other state-of-the-art methods.

Keywords: fuzzy rules, fuzzy rule-based systems, interpretability, granularity and specificity, linguistics terms

SUMÁRIO

Capítulo 1—Introdução	1
1.1 Problema	4
1.2 Motivação	5
1.3 Hipótese e Objetivos	5
1.3.1 Objetivo Geral	6
1.3.2 Objetivos Específicos	6
1.4 Organização do Trabalho	6
Capítulo 2—Sistemas Fuzzy Baseados em Regras	9
2.1 Considerações iniciais	9
2.2 Conjuntos fuzzy	10
2.3 Sistemas Fuzzy Baseados em Regras	12
2.4 Considerações finais	15
Capítulo 3—O Princípio da Granularidade Justificável na interpretabilidade de regras fuzzy	17
3.1 Considerações iniciais	17
3.2 O Princípio da Granularidade Justificável	18
3.2.1 Cobertura	19
3.2.2 Especificidade	20
3.3 Considerações finais	20
Capítulo 4—GENI-FR	23
4.1 Considerações iniciais	23
4.2 Especificidade e granularidade na geração de regras fuzzy	23
4.3 Granularity to Ensure Interpretability of the Fuzzy Rules (GENI-FR)	24
4.4 Considerações finais	27
Capítulo 5—Resultados	29
5.1 Considerações iniciais	29
5.2 Resultados obtidos	30
5.2.1 Desempenho do GENI-FR em comparação a outros métodos da literatura	32
5.3 Considerações finais	37

Capítulo 6—Conclusão	45
6.1 Avaliação e Resultados obtidos	45
6.2 Trabalhos futuros	46

LISTA DE FIGURAS

1.1	Ilustração do comportamento inversamente proporcional entre interpretabilidade e acurácia (o aumento da interpretabilidade implica na diminuição da acurácia e vice-versa)	4
2.1	Exemplo de funções de pertinência triangular e trapezoidal mapeando um conjunto fuzzy A	12
2.2	Funções características de <i>core</i> e <i>suporte</i> de funções de pertinência de um conjunto fuzzy A , denotadas pelas linhas tracejadas (PEDRYCZ, 2020) .	13
2.3	Exemplos de α -cut e <i>strong</i> α -cut de um conjunto fuzzy A (PEDRYCZ, 2020)	13
2.4	Base de conhecimento de um SFBR (NOGUEIRA, 2008)	14
3.1	Exemplo de faixa elástica em uma função triangular onde são aplicados os conceitos de cobertura e especificidade (Fonte: Autor)	19
3.2	Exemplo do cálculo do índice de desempenho otimizado e definição do ponto ótimo da extremidade esquerda de uma função triangular (Fonte: Autor)	21
5.1	Funções de pertinência com pontos simétricos de uma das colunas do dataset <i>Shuttle</i> (<i>Col3</i>) em um dos folds dos experimentos (Fonte: Autor) .	31
5.2	Funções de pertinência ajustadas pelo GEnI-FR de uma das colunas do dataset <i>Shuttle</i> (<i>Col3</i>) em um dos folds dos experimentos (Fonte: Autor)	31
5.3	Funções de pertinência com pontos simétricos de uma das colunas do dataset <i>Shuttle</i> (<i>Col7</i>) em um dos folds dos experimentos (Fonte: Autor) .	32
5.4	Funções de pertinência ajustadas pelo GEnI-FR de uma das colunas do dataset <i>Shuttle</i> (<i>Col7</i>) em um dos folds dos experimentos (Fonte: Autor)	32
5.5	Comparação dos melhores resultados do GEnI-FR 3 termos vs FRBCS.CHI 3 termos (Fonte: Autor)	33
5.6	Comparação dos melhores resultados do GEnI-FR 3 termos vs FRBCS.CHI 5 termos (Fonte: Autor)	34
5.7	Comparação dos melhores resultados do GEnI-FR 3 termos vs FRBCS.CHI 7 termos (Fonte: Autor)	35
5.8	Comparação dos melhores resultados do GEnI-FR 3 termos vs FRBCS.W 3 termos (Fonte: Autor)	35
5.9	Comparação dos melhores resultados do GEnI-FR 3 termos vs FRBCS.W 5 termos (Fonte: Autor)	36
5.10	Comparação dos melhores resultados do GEnI-FR 3 termos vs FRBCS.W 7 termos (Fonte: Autor)	36

LISTA DE TABELAS

5.1	Informações sobre os datasets utilizados nos experimentos	29
5.2	Resultados médios de acurácia nos folds que utilizaram <i>3 termos</i> linguísticos - GEnI-FR	37
5.3	Resultados médios de acurácia nos folds que utilizaram <i>5 termos</i> linguísticos - GEnI-FR	38
5.4	Resultados médios de acurácia nos folds que utilizaram <i>7 termos</i> linguísticos - GEnI-FR	38
5.5	Função de pertinência com o melhor resultado de acurácia obtido nos folds de cada dataset e a média de regras geradas com o método FRBCS.CHI com <i>3 termos</i>	38
5.6	Função de pertinência com o melhor resultado de acurácia obtido nos folds de cada dataset e a média de regras geradas com o método FRBCS.CHI com <i>5 termos</i>	39
5.7	Função de pertinência com o melhor resultado de acurácia obtido nos folds de cada dataset e a média de regras geradas com o método FRBCS.CHI com <i>7 termos</i>	39
5.8	Função de pertinência com o melhor resultado de acurácia obtido nos folds de cada dataset e a média de regras geradas com o método FRBCS.W com <i>3 termos</i>	39
5.9	Função de pertinência com o melhor resultado de acurácia obtido nos folds de cada dataset e a média de regras geradas com o método FRBCS.W com <i>5 termos</i>	40
5.10	Função de pertinência com o melhor resultado de acurácia obtido nos folds de cada dataset e a média de regras geradas com o método FRBCS.W com <i>7 termos</i>	40
5.11	Comparação das diferenças dos melhores resultados do GEnI-FR 3 termos <i>vs</i> FRBCS.W 3 termos linguísticos	40
5.12	Comparação das diferenças dos melhores resultados do GEnI-FR 3 <i>vs</i> FRBCS.W 5 termos linguísticos	41
5.13	Comparação das diferenças dos melhores resultados do GEnI-FR 3 termos <i>vs</i> FRBCS.W 7 termos linguísticos	41
5.14	Comparação das diferenças dos melhores resultados do GEnI-FR 3 termos <i>vs</i> FRBCS.CHI 3 termos linguísticos	41
5.15	Comparação das diferenças dos melhores resultados do GEnI-FR 3 termos <i>vs</i> FRBCS.CHI 5 termos linguísticos	42
5.16	Comparação das diferenças dos melhores resultados do GEnI-FR 3 termos <i>vs</i> FRBCS.CHI 7 termos linguísticos	42

5.17 Melhores resultados de acurácia de cada método 43

NOMENCLATURA

α	Limiar $\alpha \in [0, 1]$
\mathcal{O}	Notação O-grande que descreve o comportamento limitante de uma função que tende a um valor ou ao infinito
A	Um conjunto <i>fuzzy</i>
a	Elemento da extremidade esquerda sob domínio de uma função de pertinência triangular/trapezoidal
a_{opt}	Ponto extremo esquerdo ótimo de um conjunto fuzzy mapeado por uma função de pertinência linear
b	Elemento da extremidade direita sob domínio de uma função de pertinência triangular/trapezoidal
b_{opt}	Ponto extremo direito ótimo de um conjunto fuzzy mapeado por uma função de pertinência linear
$cov(A)$	Função que determina a cobertura de um conjunto fuzzy A
f^{-1}	Função inversa de uma função de pertinência
$f_A(x)$	Função de pertinência/característica que associa um elemento genérico x a um grau de pertencimento no intervalo $[0, 1]$
K	Quantidade de funções de pertinência (ou regiões) do conjunto <i>fuzzy</i>
$left_range$	Intervalo do lado esquerdo de uma função de pertinência
m	Elemento onde o grau de pertencimento é igual a 1 em funções triangulares; extremidade esquerda do platô das funções trapezoidais onde o grau de pertencimento é igual a 1
m, n	Elementos das funções trapezoidais que indicam o platô onde qualquer elemento x , $m \leq x \leq n$, possui $f_A(x) = 1$
N	Número natural $1 \leq N \leq 3$
n	Elemento da extremidade direita do platô das funções trapezoidais onde o grau de pertencimento é igual a 1

- Q Índice de desempenho ótimo da relação entre cobertura e especificidade de conjuntos fuzzy
- $right_range$ Intervalo do lado direito de uma função de pertinência
- $sp(A)$ Função que determina a especificidade de um conjunto fuzzy A
- X Um espaço de objetos
- x Elemento genérico de um conjunto *fuzzy* X

INTRODUÇÃO

Os vários avanços da Inteligência Artificial (IA) e do Aprendizado de Máquina (AM) permitem o surgimento de modelos robustos e cada vez mais autônomos à medida que novos dados são coletados ao longo do tempo (GUNNING; AHA, 2019; DONG et al., 2023). Em contrapartida, não há garantias de que modelos provenientes da IA e AM sejam confiáveis, uma vez que a maioria dos modelos produzidos são caixas pretas complexas: sua lógica e funcionamento internos estão encapsulados e ocultos dos usuários. Isto impede que um humano, especialista ou não, verifique, interprete e compreenda o raciocínio dos sistemas de IA e a maneira como as decisões são tomadas pelos mesmos (CARVALHO; PEREIRA; CARDOSO, 2019; GUNNING; AHA, 2019; ARRIETA et al., 2020; HASSIJA et al., 2023; JENA; PANDA; KOSE, 2023). Esta falta de confiança e compreensão intuitiva nos sistemas de IA levou a DARPA (*Defense Advanced Research Projects Agency*), agência americana que há 50 anos faz investimentos em tecnologias de ponta, à criação de um programa denominado Inteligência Artificial Explicável (XAI - *eXplainable Artificial Intelligence*) (GUNNING; AHA, 2019). A XAI visa criar um conjunto de técnicas de Aprendizado de Máquina que: (i) Produza modelos mais explicáveis/interpretáveis, mantendo um alto nível de desempenho de aprendizado (precisão de previsão); e (ii) Permita que os usuários humanos entendam, confiem adequadamente e gerenciem efetivamente a geração emergente de sistemas artificialmente inteligentes.

De acordo com a análise bibliométrica apresentada em Alonso, Castiello e Mencar (2018), a qual foi atualizada no tutorial *Paving the way from Interpretable Fuzzy Systems to eXplainable Artificial Intelligence Systems*¹ apresentado no IEEE World Congress on Computational Intelligence (WCCI)² 2020, o uso de modelos fuzzy apresentam-se como promissoras abordagens para alavancar a XAI. Com base nas análises bibliométricas bem detalhadas no artigo e no tutorial, os autores apontam uma oportunidade para estreitar as conexões entre as áreas de sistemas fuzzy e não fuzzy, que atualmente aparecem desnecessariamente separados. Alonso, Castiello e Mencar (2018) acreditam fortemente que a fertilização cruzada entre essas comunidades é necessária para enfrentar com sucesso os

¹<https://sites.google.com/view/tutorial-on-xai-ieee-wcci2020>

²<https://wcci2020.org/>

desafios colocados pela XAI. Neste sentido, a IEEE International Conference on Fuzzy Systems 2021, maior evento internacional da área de sistemas fuzzy, teve como tema ‘*Handling Uncertainty in Interpretable AI*’ (Manipulação da incerteza na IA interpretável) apresentando resultados de pesquisas que enfatizam a manipulação da incerteza, em particular no contexto da XAI, promovendo ativamente o uso da Teoria de Conjuntos e Lógica Fuzzy.

Dessa movimentação para geração de modelos mais explicáveis, os Sistemas Fuzzy (SF) constituem um recurso essencial no incremento da interpretabilidade de sistemas de aprendizado, pois são projetados para um amplo escopo de ação pela definição verbal de conceitos sobre domínios incertos/imprecisos. Sistemas Fuzzy (SF) são baseados na Teoria de Conjuntos e Lógica Fuzzy (TCLF) projetados para fornecer mecanismos matemáticos para tratar incerteza nos dados (ZADEH, 1965). Os Sistemas inteligentes obtidos pela utilização da teoria de conjuntos fuzzy, especificamente, potencializam a XAI por dois principais motivos:

1. Utilização de termos linguísticos em suas operações, favorecendo a interpretabilidade;
2. Obtenção de melhores resultados de predição em situações de incerteza do que modelos baseados em regras clássicos (ARRIETA et al., 2020)

Considerar que existem incertezas nos dados, tal como a forma humana de pensar, e que precisam de interpretações apropriadas (KLIR; YUAN, 1995) favoreceu a aplicação da teoria de conjuntos e lógica fuzzy (ZADEH, 1965). Por meio da Teoria de Conjuntos Fuzzy (TCF), é possível considerar que afirmações do mundo real variam em graus de verdade, entre 0 e 1, e podem ser, portanto, parcialmente verdadeiras ou parcialmente falsas. Isso expande uma gama de recursos para representação de termos linguísticos característicos da linguagem humana, como: *um pouco*, *muito*, *muito pouco*, dentre outros.

Pedrycz (2013) detalha que grânulos de informação, conforme encontrados na linguagem natural, estão implícitos na natureza e precisam ser explicitados para torná-los totalmente operacionais e serem utilizados com eficácia para analisar e projetar sistemas inteligentes.

Em sistemas de diagnóstico médico, por exemplo, é necessária a construção de modelos com alta acurácia devido ao contexto da aplicação, porém, pode ser inviável para o especialista humano investir horas tentando entender um modelo com alta acurácia, mas que não possui meios de interpretabilidade, reduzindo a capacidade de entendimento do modelo pelo especialista.

Da mesma forma, em outros contextos como sistemas de recomendações musicais, por exemplo, podem ser utilizados atributos musicais (como: acústica, dançabilidade, timbres, instrumentalidade, etc.) para construir modelos interpretáveis que identificam que músicas *muito dançantes* ou *com pouco grave* são as mais indicadas para um determinado perfil de usuário. Essa informação humanizada pode ser usada em programas de marketing personalizado para causar aos usuários uma sensação de maior naturalidade e proximidade neste tipo de comunicação.

Enquanto aspectos relacionados à XAI são estudados muito recentemente, os aspectos relacionados à interpretabilidade, por meio de modelos baseados em regras fuzzy já têm sido estudados por um longo tempo (PEDRYCZ; GACEK; WANG, 2021). Aghaeipoor, Javidi e Fernandez (2021) destacam que os paradigmas de classificação baseados em regras fuzzy são soluções adequadas para enfatizar a interpretabilidade dos sistemas. Os Sistemas Fuzzy Baseados em Regras (SFBR) permitem representar conhecimentos incertos e imprecisos por meio do uso de regras fuzzy, que também podem contribuir fortemente na interpretabilidade de dados numéricos por meio de conjuntos fuzzy que representam termos linguísticos mapeados por funções de pertinência.

Métodos para geração de regras fuzzy, como o método conhecido como Wang&Mendel (W&M) (WANG; MENDEL, 1992), possibilitam a geração automática de regras fuzzy a partir de dados numéricos, sem a necessidade de um especialista para modelar essas regras, representando dados numéricos tal como a forma humana de pensar e como os dados apresentam-se em sistemas reais. Pode ser difícil de interpretar regras fuzzy em modelos com inúmeras variáveis de entrada e, conseqüentemente, com muitas condições de entrada, por ser difícil memorizar todos os termos linguísticos presentes e obter legibilidade nas relações de entrada-saída das regras (PEDRYCZ; GACEK; WANG, 2021).

Além disso, processos de geração de regras no contexto de grandes volumes de dados (*BigData*) podem gerar quantidades excessivas de regras com, conseqüentemente, maior ambigüidade. Em se tratando de regras fuzzy, quantidades excessivas de regras e de conjuntos fuzzy afetam o desempenho computacional, a semântica linguística e a interpretabilidade do sistema (AGHAEIPOOR; JAVIDI; FERNANDEZ, 2021). Um grande número de conjuntos fuzzy, em qualquer modelagem de SFBR, aumenta a dimensionalidade vertical da base de regras fuzzy, ou seja, a quantidade de regras do sistema, que juntamente com um grande número de variáveis de entrada (alta dimensionalidade horizontal), prejudica a interpretabilidade do domínio representado por essas regras.

Métodos foram desenvolvidos para aprimorar a interpretabilidade de sistemas de especialistas baseados em regras para tornar decisões mais compreensíveis e confiáveis em diferentes áreas de aplicação (CAO et al., 2021). Em Razak et al. (2021) é proposto um quadro para capturar a interpretabilidade de sistemas hierárquicos de lógica fuzzy, utilizando uma abordagem de design participativo para melhorar a compreensão, transparência e interpretabilidade de sistemas fuzzy complexos.

Neste contexto, a principal contribuição dessa dissertação de mestrado está na possibilidade de geração automática de regras (sem a necessidade de um especialista) guiada pelos próprios dados que definem as melhores configurações de parâmetros, formas e tipos de funções de pertinência fuzzy, adequadas de acordo com o princípio da granularidade justificável.

Segundo Pedrycz e Wang (2016), o princípio da granularidade justificável surge como um dos fundamentos da computação granular e trata da formação de grânulos de informação com base em evidências experimentais de dados numéricos suficientes e alta especificidade. Este princípio incrementa os índices de interpretabilidade das regras fuzzy ao obter o melhor equilíbrio da relação entre cobertura e especificidade, inversamente proporcionais, em cada função de pertinência que mapeia o conjunto de dados. O método apresentado nesse trabalho aplica o princípio durante a construção do sistema fuzzy sem

a necessidade da existência prévia de uma base de regras.

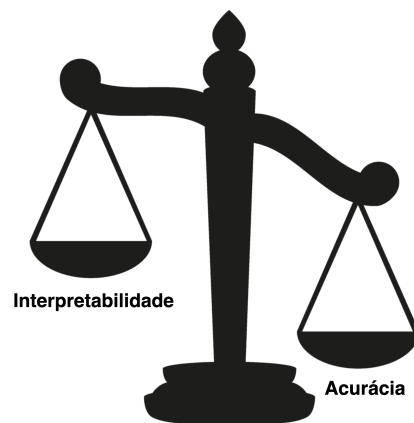
O método apresentado em mais detalhes nessa dissertação é aplicável a um domínio de evidências experimentais de dados numéricos cujo objetivo final é a criação de regras fuzzy, guiada pelos próprios dados (*data-driven*).

1.1 PROBLEMA

Sistemas Fuzzy Baseados em Regras são compostos principalmente de uma *Base de Conhecimento*, que inclui a base de regras fuzzy, e do *Mecanismo de Inferência*. Mecanismos de inferência projetados para oferecer modelos muito precisos, com alta acurácia, podem perder em interpretabilidade. Esse impasse entre acurácia e interpretabilidade resulta em dois paradigmas principais para o modelo: orientado para acurácia e orientado para interpretabilidade (DUTU; MAURIS; BOLON, 2015/06) (Figura 1.1). Em geral, um sistema ou modelo fuzzy é interpretável se o usuário pode, de maneira independente, entender e traduzir os elementos do modelo ou sistema para a forma natural da linguagem humana. Essa interpretabilidade pode ser impactada e, portanto, depende de fatores como a quantidade de regras fuzzy do sistema, a relação entre índice de acurácia com quantidade de termos linguísticos e de regras fuzzy necessárias, a quantidade de variáveis, a quantidade de termos linguísticos, a configuração e formas das funções de pertinência, dentre outros fatores.

É preciso considerar que o conjunto de regras que compõem uma base de regras fuzzy competem e colaboram entre si com o objetivo de produzir bons *trade-offs* (relação de troca) de generalidade-especificidade e interpretabilidade-acurácia (ALONSO; PANCHO; MAGDALENA, 2012) dos conjuntos fuzzy que representam os termos linguísticos. A Figura 1.1 ilustra, de forma geral, a relação inversamente proporcional entre interpretabilidade e acurácia e o desafio em encontrar o melhor *trade-off* entre elas.

Figura 1.1 Ilustração do comportamento inversamente proporcional entre interpretabilidade e acurácia (o aumento da interpretabilidade implica na diminuição da acurácia e vice-versa)



Fonte: Autor

Segundo Pedrycz, Gacek e Wang (2021), a elaboração manual de regras fuzzy com mais de 3 ou 4 variáveis de entrada e pelo menos 5 conjuntos fuzzy não é nada viável. Consequentemente, tendo muitas condições nessas variáveis de entrada, é difícil inter-

pretar plenamente todos os termos linguísticos presentes na base de regras e obter uma interpretação coerente das relações de entrada-saída da estrutura das regras (PEDRYCZ; GACEK; WANG, 2021).

1.2 MOTIVAÇÃO

Modelar os conjuntos fuzzy para que se ajustem adequadamente às características dos dados de entrada por meio do princípio da granularidade justificável na criação de regras fuzzy refinadas, bem como das próprias características dos dados, pode possibilitar o incremento do valor semântico dos termos linguísticos e, conseqüentemente, o incremento da interpretabilidade do SFBR. Neste sentido, é importante:

- Representar os mais variados dados numéricos por meio de conjuntos fuzzy, utilizando recursos semânticos de termos linguísticos (por exemplo: *muito baixo, baixo, médio, alto etc.*).
- Incrementar a interpretabilidade desses dados por meio de termos linguísticos obtidos a partir de formas de funções de pertinência bem ajustadas e, portanto, com um significado linguístico mais apurado.

Segundo Pedrycz, Gacek e Wang (2021), arquiteturas baseadas em regras relacionais (que agregam regras e inferem os resultados por meio de operadores de composição e relações de conjuntos) são altamente interpretáveis. Sendo assim, tornam-se viáveis os esforços para utilizar um método de geração automática de regras fuzzy, sem a necessidade de um especialista, como o proposto por Wang e Mendel (1992) (**W&M**), que possibilita a aplicação do princípio da granularidade justificável para definir adequadamente os melhores parâmetros e tipos das funções de pertinência durante a sua construção.

Nas funções de pertinência triangulares e trapezoidais existem parâmetros que identificam os pontos das extremidades dos dados sob cobertura da função, esses pontos de extremidades serão representados, neste trabalho, por a e b , que representam a extremidade esquerda e direita de uma função triangular ou trapezoidal, respectivamente. Para simplificação, no decorrer deste trabalho o intervalo entre o parâmetro a e o ponto médio da função de pertinência, ponto m , será chamado de "lado esquerdo". Já a diferença entre o ponto médio, m ou n , e o parâmetro b será chamado de "lado direito".

As funções de pertinência obtidas pelo método apresentado neste trabalho podem possuir tipos e configurações diferentes em cada um dos seus "lados", por exemplo, trapezoidal no lado esquerdo e triangular no lado direito. Para designar esse comportamento, será utilizada a expressão *função de pertinência mista* no decorrer desse trabalho.

1.3 HIPÓTESE E OBJETIVOS

Diante dos problemas relacionados ao tema e da motivação em solucioná-los, a seguinte hipótese foi desenvolvida para fundamentar esse trabalho:

A utilização do princípio da granularidade justificável em uma abordagem *data-driven* de criação de funções de pertinência fuzzy possibilita a construção

de sistemas fuzzy baseados em regras com funções de pertinência com parâmetros ajustados, adequadas a cada conjunto de dados de entrada, aumentando a interpretabilidade do sistema ao manter os mesmos níveis de acurácia e gerando uma quantidade menor de regras com menos termos linguísticos.

Para provar esta hipótese, o objetivo geral deste trabalho é definido a seguir, o qual, por sua vez, foi alcançado por meio de alguns objetivos específicos.

1.3.1 Objetivo Geral

A partir da necessidade do desenvolvimento de sistemas fuzzy com abordagens *data-driven* cada vez mais interpretáveis, com explicações compreensíveis de seu comportamento e sem prejuízos nos níveis de acurácia, o seguinte objetivo geral é definido:

- Gerar Sistemas Fuzzy Baseados em Regras com alta interpretabilidade e com os mesmos níveis de acurácia de métodos conhecidos.

1.3.2 Objetivos Específicos

1. Reduzir a quantidade de termos linguísticos, e conseqüentemente a quantidade de regras, do sistema fuzzy de forma que sejam mantidos os mesmos níveis de acurácia comparáveis com métodos conhecidos que não tem esse foco.
2. Definir os melhores tipos e formas para as funções de pertinência das regras fuzzy, dadas as características dos conjuntos de dados de entrada;
3. Modelar variáveis de entrada-saída como variáveis linguísticas com $K = 2N + 1$ conjuntos fuzzy, sendo $1 \leq N \leq 3$.
4. Garantir a interpretabilidade das regras fuzzy construídas pelo método proposto;
5. Minimizar os impactos nos custos computacionais com a implantação do método no processo de criação do sistema.

Sendo assim, nesta dissertação de mestrado é apresentado o método denominado GEnI-FR (sigla em inglês para *Granularity to Ensure Interpretability of the Fuzzy Rules*), que consiste em realizar ajustes e refinamentos no processo de geração de regras fuzzy, obtendo o equilíbrio entre interpretabilidade e precisão, aplicando o princípio da granularidade justificável para ajustar conjuntos fuzzy baseando-se nas características dos próprios dados.

1.4 ORGANIZAÇÃO DO TRABALHO

Com o intuito de provar a hipótese criada e alcançar os objetivos propostos, será apresentado nesse trabalho um estudo sobre os seguintes assuntos: IA explicável, interpretabilidade de regras fuzzy, sistemas fuzzy baseados em regras, conjuntos fuzzy, lógica fuzzy e geração de regras fuzzy de W&M. Embasado pela fundamentação teórica e formal desses

assuntos, a proposta desse trabalho será avaliada por meio de experimentos realizados utilizando *datasets* conhecidos.

Para uma melhor organização deste trabalho, três principais fundamentos teóricos foram tomados como guias:

- Teoria de Conjuntos fuzzy
- Princípio da Granularidade Justificável
- Interpretabilidade de Regras fuzzy

Dessa forma, a estrutura desse trabalho está organizada como segue:

- *Capítulo 2 - Sistemas Fuzzy Baseados em Regras*: neste capítulo serão apresentados os fundamentos acerca dos assuntos elementares relacionados a sistemas fuzzy que serão discutidos no decorrer do trabalho: conjuntos fuzzy, sistemas fuzzy baseados em regras, geração de regras com o método de Wang e Mendel (1992).
- *Capítulo 3 - O Princípio da Granularidade Justificável na interpretabilidade de regras fuzzy*: neste capítulo serão discutidos temas relacionados ao uso do princípio da granularidade justificável como informação granular para incremento da interpretabilidade de regras de um sistema fuzzy baseado em regras.
- *Capítulo 4 - Proposta*: neste capítulo será adequadamente descrita e detalhada o método proposto, utilizando o formalismo necessário para isto, juntamente com a representação algorítmica do método baseado em uma abordagem data-driven para design de regras fuzzy interpretáveis.
- *Capítulo 5 - Resultados*: neste capítulo serão apresentadas as análises finais dos experimentos que foram realizados, detalhadas as características das bases de dados utilizadas e apresentadas as discussões dos resultados.
- *Capítulo 6: Conclusão*: neste capítulo serão apresentadas as conclusões obtidas por meio das análises dos experimentos além de possibilidades de melhoria da proposta.

SISTEMAS FUZZY BASEADOS EM REGRAS

2.1 CONSIDERAÇÕES INICIAIS

A modelagem de conhecimentos imprecisos e incertos que fazem parte do domínio humano depende de mecanismos adequados para a tradução de sentenças em linguagem natural para sentenças manipuláveis computacionalmente. Uma das formas de tornar essas sentenças manipuláveis é representá-las por meio de Regras Fuzzy (RF), que utilizam recursos da lógica fuzzy para captar e representar conhecimentos humanos com fácil compreensão.

Neste sentido, o conceito de variável linguística proveniente da Teoria de Conjuntos Fuzzy (TCF) (ZADEH, 1965) é útil para a representação de domínios de conhecimento incerto, uma vez que conseguem mapear as incertezas do domínio por meio de termos linguísticos imprecisos como, por exemplo, *um pouco baixo*, *baixo*, *médio*, *alto* e *muito alto*, representados por conjuntos fuzzy que são facilmente manipuláveis por métodos computacionais projetados para este fim.

As regras fuzzy, em geral, baseiam-se em dois principais sistemas de inferência, o sistema fuzzy Mamdani (MAMDANI; ASSILIAN, 1975) ou o sistema fuzzy Takagi-Sugeno (TS) (SUGENO, 1985) (TAKAGI; SUGENO, 1985). De forma geral, as regras fuzzy construídas utilizando o sistema TS apresentam uma saída tradicional para modelo, enquanto as regras fuzzy do sistema Mamdani utilizam métodos de defuzzificação para calcular essa saída (quando fazer inferência fizer parte do objetivo do sistema).

As regras fuzzy construídas e utilizadas neste trabalho seguem o sistema Mamdani e possuem a seguinte forma:

“SE antecedente ENTÃO conseqüente”

onde o *antecedente* compreende as variáveis de entrada, combinadas por meio de *t-norms* (conector **AND**) e/ou *t-conorms* (conector **OR**), e o *conseqüente* corresponde a uma (utilizando o sistema **MISO** - *Multiple Input and Single Output*) ou mais variáveis de saída (utilizando o sistema **MIMO** - *Multiple Input and Multiple Output*) (NOGUEIRA, 2008).

O poder expressivo e de interpretabilidade da saída em sistemas Mamdani é perdido em sistemas Takagi-Sugeno, pelo fato de que os consequentes das regras não são fuzzy (HAMAM; GEORGANAS, 2008). Dessa forma, como este trabalho é focado principalmente em ajustes nas funções de pertinência de conjuntos fuzzy para refinamento e exploração da interpretabilidade de Sistemas Fuzzy (SF), será utilizado apenas o sistema Mamdani com uma única variável consequente ou variável de saída.

As regras fuzzy podem ser criadas por métodos de geração de regras fuzzy, como o método W&M proposto por Wang e Mendel (1992), e inseridas em uma Base de Regras Fuzzy que faz parte da Base de Conhecimento de um Sistema Fuzzy Baseado em Regras (**SFBR**). Em associação com um Mecanismo de Inferência, a Base de Conhecimento pode ser utilizada para realizar inferência fuzzy a partir das regras fuzzy construídas ou ainda utilizar a base de conhecimento como um forte mecanismo para interpretação do conhecimento representado pelas regras fuzzy.

A modelagem de funções de pertinência é um fator importante no projeto de sistemas fuzzy baseados em regras, pois a quantidade, as configurações dos parâmetros e a forma dessas funções afetam o desempenho, a interpretabilidade e, eventualmente, o custo computacional do sistema fuzzy (KABIR; KABIR, 2021). Portanto, é importante considerar um ajuste adequado dos parâmetros dessas funções de pertinência em um SFBR, pois elas são a base do sistema e uma vez bem refinadas poderão ser impactantes nos resultados finais do modelo. O trabalho de Kabir e Kabir (2021) têm o objetivo principal de encontrar o tipo de função de pertinência adequado para o modelo fuzzy, usando uma abordagem chamada ANFIS, e para validação do modelo, em tarefas de regressão, é usado RMSE (**R**oot **M**ean **S**quare **E**rror) para funções de pertinência do tipo linear que podem ter seus desempenhos avaliados em aplicações da vida real.

2.2 CONJUNTOS FUZZY

Pela definição apresentada por Zadeh (1965), um conjunto fuzzy A em X (sendo X um espaço de objetos), com seus elementos genéricos denotados por x , é caracterizado por uma função de pertinência $f_A(x)$ que associa a cada ponto em X um número no intervalo $[0, 1]$, com o valor de $f_A(x)$ em x representando o “grau de adesão/pertencimento” de x em A . Sendo assim, os conjuntos fuzzy são caracterizados pela função $A : X \rightarrow [0, 1]$ (KLIR; YUAN, 1995).

Uma das aplicações mais importantes das funções de pertinência está na representação do conhecimento humano incerto e ambíguo, por meio da qual é possível o tratamento da imprecisão e incerteza inerentes a dados brutos de experimentações humanas. Sendo assim, é importante modelar soluções adequadas em ambientes que envolvam incerteza e imprecisão, explorando recursos oferecidos por conjuntos fuzzy e da sua aplicação em regras fuzzy para representação adequada de uma base de conhecimento.

A escolha das configurações adequadas das funções de pertinência, segundo Mendel e Bonissone (2021), pode ser mais crítica para a Inteligência Artificial Explicável (XAI) pois é essencial definir com qualidade descrições linguísticas de conjuntos fuzzy.

As funções de pertinência fuzzy podem assumir diferentes formas e tipos específicos, definidos em grande parte por seus parâmetros. Para as investigações e resultados con-

cluídos, analisados e apresentados neste trabalho foram utilizadas funções de pertinência lineares detalhadas da seguinte forma:

- As *funções de pertinência triangulares*, definidas pela Equação 2.1, são constituídas por três parâmetros representados por: a representa o ponto da extremidade esquerda da função triangular, m representa o ponto médio da função e b representa a extremidade direita.
- As *funções de pertinência trapezoidais*, definidas pela Equação 2.2, são constituídas por quatro parâmetros representados por: a representa o ponto da extremidade esquerda da função, m representa a extremidade esquerda do platô da função, n representa a extremidade direita do platô da função e b representa o ponto da extremidade direita da função. Os valores presentes entre as extremidades dos pontos m e n possuirão graus de pertencimento igual a 1.

$$A(x, a, m, b) = \begin{cases} 0 & \text{se } x \leq a \\ \frac{x-a}{m-a} & \text{se } x \in (a, m) \\ 1 & \text{se } x = m \\ \frac{b-x}{b-m} & \text{se } x \in (m, b) \\ 0 & \text{se } x \geq b \end{cases} \quad (2.1)$$

$$A(x, a, m, n, b) = \begin{cases} 0 & \text{se } x \leq a \\ \frac{x-a}{m-a} & \text{se } x \in (a, m) \\ 1 & \text{se } x \in [m, n] \\ \frac{b-x}{b-n} & \text{se } x \in (n, b) \\ 0 & \text{se } x \geq b \end{cases} \quad (2.2)$$


Ainda segundo Mendel e Bonissone (2021), funções de pertinência triangulares e trapezoidais podem ser mais adequadas para XAI do que funções de pertinência Gaussianas, pelo fato de que as primeiras dividem o espaço de estados de forma evidente (são exatamente zero nas suas extremidades), enquanto as últimas dividem o espaço de estados de forma ambígua (tendem mas não são exatamente zero).

Na Figura 2.1 (PEDRYCZ, 2020) são exemplificadas as formas que as funções de pertinência fuzzy triangular e trapezoidal podem possuir ao mapear um conjunto fuzzy A e como seus parâmetros (descritos nas Equações 2.1 e 2.2) estão posicionados.

Segundo Pedrycz (2020), diante da grande diversidade de funções de pertinência potencialmente úteis, existem certos descritores que são conceituais e operacionalmente qualificados para capturar a essência das construções granulares representadas por conjuntos fuzzy.

Dentre os diversos descritores existentes, serão detalhados logo a seguir o conceito de alguns comumente conhecidos e utilizados, descritos em Pedrycz (2020):

Figura 2.1 Exemplo de funções de pertinência triangular e trapezoidal mapeando um conjunto fuzzy A



- *supp*: suporte de um conjunto fuzzy A , denotado por $supp(A)$, é um conjunto de todos os elementos de X com graus de pertinência diferentes de 0 (zero) em A (Figura 2.2). É descrito formalmente pela Equação 2.3 a seguir;

$$supp(A) = \{x \in X | A(x) > 0\} \quad (2.3)$$

- *core*: O *core* (núcleo) de um conjunto fuzzy A , denotado por $core(A)$, é um conjunto de todos os elementos do universo que possuem graus de pertinência iguais a 1 (um) em A (Figura 2.2). É descrito formalmente pela Equação 2.4 a seguir.

$$core(A) = \{x \in X | A(x) = 1\} \quad (2.4)$$

- α -*cut*: O α -*cut* (*corte- α*) de um conjunto fuzzy A , denotado por A_α , é um conjunto constituído pelos elementos do universo cujos graus de pertinência são maiores ou iguais a um limiar α onde $\alpha \in [0, 1]$. A Equação 2.5 descreve formalmente esse conceito.

$$A_\alpha = \{x \in X | A(x) \geq \alpha\} \quad (2.5)$$

O conceito de *strong α -cut* (*corte- α forte*, Figura 2.3) difere do α -*cut* no sentido de que considera apenas elementos maiores que o limiar α , sendo formalmente descrito pela fórmula a seguir:


$$A_\alpha = \{x \in X | A(x) > \alpha\} \quad (2.6)$$

- *Cardinalidade e Especificidade*: Tais conceitos também são descritos por Pedrycz (2020) e são equivalentes aos conceitos de Cobertura e Especificidade descritos com mais detalhes no Capítulo 3.

2.3 SISTEMAS FUZZY BASEADOS EM REGRAS

Sistemas Fuzzy Baseados em Regras (SFBR) possibilitam a construção de modelos fuzzy para representação de conhecimentos e inferência fuzzy. É na concepção do SFBR que são definidos o domínio de conhecimento que será representado, os tipos, parâmetros e formas das funções de pertinência que representarão esse conhecimento, a estrutura das


Figura 2.2 Funções características de *core* e *suporte* de funções de pertinência de um conjunto fuzzy A , denotadas pelas linhas tracejadas (PEDRYCZ, 2020)



Fonte:

Autor

Figura 2.3 Exemplos de α -cut e *strong* α -cut de um conjunto fuzzy A (PEDRYCZ, 2020)



Fonte:

Autor

regras fuzzy que serão construídas e o mecanismo de inferência construído a partir destes fatores.

Os SFBRs são compostos principalmente por dois principais componentes (NOGUEIRA, 2008):

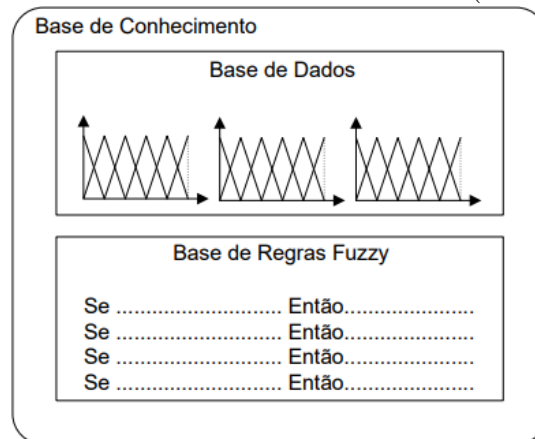
- **Base de Conhecimento:** composta pela Base de Dados que, por sua vez, contém as definições dos conjuntos fuzzy utilizados na construção das regras fuzzy que modelam um determinado problema e compõem a Base de Regras Fuzzy (Figura 2.4);
- **Motor de Inferência Fuzzy:** responsável pelo processamento das regras fuzzy utilizando algum método de raciocínio (KLIR; YUAN, 1995). A partir das regras fuzzy é possível aplicar um procedimento de inferência para derivar a conclusão.

Uma vez definidos os parâmetros, tipos e formas das funções de pertinência que mapearão o conjunto de dados, o modo de operação de um SFBR segue as seguintes etapas:

1. Definição dos parâmetros, tipos e formas das funções de pertinência que mapearão o conjunto de dados;
2. Fuzzyficação: transformação dos valores numéricos de entrada em conjuntos fuzzy. É realizado o cálculo do grau de pertinência de cada valor de entrada no conjunto fuzzy correspondente, indicando a compatibilidade da entrada com o antecedente de cada regra;

3. Cálculo do Grau de Disparo da regra: agregação de antecedentes de cada regra (geralmente utilizando operadores *t-norms* e/ou *t-conorms*);
4. Aplicação da inferência em cada regra: derivação de resultados individuais para cada regra;
5. Combinação das saídas das regras fuzzy.

Figura 2.4 Base de conhecimento de um SFBR (NOGUEIRA, 2008)



Caso o modelo resultante do SFBR seja utilizado em uma tarefa de inferência, é então realizado ao final um processo de defuzzificação (não é mandatória), que transforma os resultados fuzzy em resultados nítidos clássicos (classe ou valor inferido pelo sistema). Esta etapa nem sempre ocorre, pois depende do tipo de problema que o Sistema Fuzzy pretende abordar.

Métodos de geração de regras fuzzy têm sido desenvolvidos para permitir a geração automática de bases de regras em modelos fuzzy sem a necessidade de um especialista no domínio do conhecimento a ser representado. O método apresentado por Wang e Mendel (1992) (chamado de **W&M** no decorrer deste trabalho), bastante utilizado, analisa e considera características de dados numéricos para a criação das funções de pertinência triangulares e trapezoidais simétricas e sem refinamentos ou ajustes mais elaborados. Estas funções de pertinência formam uma base combinada de regras fuzzy utilizada para criar um modelo de inferência fuzzy ou para representar linguisticamente os dados nebulosos.

O método **W&M** para a geração de regras juntamente com um mecanismo de inferência pode ser dividido nas seguintes principais etapas:

1. Assume que o intervalo do domínio de x_1, x_2 e y seja $[x_1^-, x_1^+]$, $[x_2^-, x_2^+]$ e $[y^-, y^+]$, respectivamente, onde "intervalo do domínio" de uma variável significa que muito provavelmente esta variável estará neste intervalo. Em seguida, divide os espaços de entrada e saída dos dados numéricos em K funções de pertinência fuzzy, que representam as funções de pertinência projetadas para mapear os pares de dados. Em geral, $K = 2N + 1$ funções de pertinência, com $N \geq 1$.

2. Gerar regras fuzzy a partir de cada par de dados. Primeiramente, determina os graus de pertinência de cada $x_1^{(i)}$, $x_2^{(i)}$ e $y^{(i)}$ em diferentes funções de pertinência fuzzy (que representam os termos linguísticos) onde os dados obtêm graus máximos.
3. Atribuir um grau de disparo para cada regra gerada, aplicando algum operador fuzzy (*t-norms* e/ou *t-conorms*) nas variáveis de entrada (*min/AND* ou *max/OR*).
4. Eliminar regras redundantes e conflitantes, ou seja, regras *IFTHEN* que possuem os mesmos termos antecedentes e termos consequentes diferentes, mantendo, por exemplo, a regra gerada por cada par de dados com o máximo grau de disparo. Desse modo, haverá uma redução considerável no número de regras.
5. Criar uma base combinada de regras fuzzy aplicando, se houver, pesos de especialistas humanos às regras geradas. Uma base combinada de regras fuzzy é constituída por regras geradas a partir de dados numéricos ou de regras linguísticas (atribuído por um especialista humano, por exemplo).

Após o procedimento de geração de regras, durante o procedimento de inferência, pode ser realizada uma estratégia de defuzzificação para determinar a variável de saída y de entradas (x_1, x_2) . Esta etapa pode não ser necessária a depender do propósito de uso da base de regras, no entanto, é útil aplicar esta etapa ao gerar regras para um motor de inferência fuzzy, pois, por meio dela, é possível realizar o mapeamento do espaço de entrada (composto por graus de pertinência atribuídos pelas regras) para o espaço de saída dos dados y (composto pelos valores numéricos da variável de saída). Vários são os métodos de defuzzificação conhecidos: *Centro de Gravidade*, *Centro de Área*, *Centro de Máximos*, *Média de Máximos Ponderado*, *Valor mais plausível*, dentre outros.

Em Alvarez-Estevéz e Moret-Bonillo (2018) é proposta uma revisão do algoritmo de Wang&Mendel, originalmente voltado para regressão (designar um valor real como saída) e não para classificação, visando usá-lo em tarefas de classificação que envolvam incerteza e imprecisão.

2.4 CONSIDERAÇÕES FINAIS

O uso de conjuntos fuzzy para representar dados numéricos é adequadamente a base para a construção de um sistema fuzzy interpretável e de fácil entendimento da natureza do conhecimento mapeado.

Funções de pertinência cumprem muito bem o papel de mapear conjuntos fuzzy utilizando recursos linguísticos que melhoram a interpretabilidade dos dados. Espera-se que a interpretabilidade seja melhorada pelos ajustes feitos ainda durante o processo inicial de criação das funções de pertinência e por seus termos linguísticos derivados ao utilizar as propriedades dos conjuntos fuzzy e ajustar adequadamente os parâmetros das funções de pertinência conforme o conjunto de dados de entrada.

A base de regras fuzzy e todo o SFBR podem ter efeitos consequentes ao fato de serem criados com base em funções de pertinência refinadas e ajustadas com princípios adequados que fortalecem os ganhos de interpretabilidade ao mapear conjuntos numéricos de dados reais. Esses efeitos podem impactar a interpretabilidade e a acurácia, não

necessariamente de maneira correlacionada; por isso, é importante mensurar os efeitos entre esses dois conceitos na dinâmica da interpretabilidade de regras e sistemas fuzzy.

No capítulo a seguir é apresentado o princípio da granularidade justificável, o qual será utilizado como motivação para a proposta apresentada neste trabalho.

O PRINCÍPIO DA GRANULARIDADE JUSTIFICÁVEL NA INTERPRETABILIDADE DE REGRAS FUZZY

3.1 CONSIDERAÇÕES INICIAIS

Enquanto a Inteligência Artificial Explicável (XAI, em inglês) é considerada apenas recentemente, aspectos relacionados à interpretabilidade de modelos baseados em regras fuzzy já são estudados por um longo tempo (PEDRYCZ; GACEK; WANG, 2021) e têm ganhado ainda mais visibilidade e importância com a XAI.

O princípio da granularidade justificável tem sido utilizado como um dos meios para aumento da interpretabilidade de conjuntos fuzzy. Esse princípio é utilizado em Liu et al. (2018) para descrição e predição em séries temporais, escolhendo os melhores pontos das extremidades das funções de pertinência, além de escolher o tipo de função de pertinência mais adequado, conforme a melhor relação entre cobertura e especificidade conforme as características dos dados de cada conjunto fuzzy. Os conjuntos fuzzy, segundo Pedrycz, Gacek e Wang (2021), apresentam dualidade porque podem ser considerados tanto construções numéricas por meio das funções de pertinência quanto termos linguísticos, tornando-se mecanismos possíveis de ajustes para incremento da interpretabilidade da base de regras.

Dado um conjunto de dados numérico como entrada para um SFBR, com os conjuntos fuzzy definidos para representar termos linguísticos e utilizando algum método de geração de regras fuzzy, é possível submeter esses conjuntos fuzzy ao princípio da granularidade justificável e, como resultado, ajustá-los para uma melhor interpretabilidade e representatividade dos dados.

O estudo realizado por Pedrycz e Homenda (2013) apresenta e discute o princípio da granularidade justificável, que projeta coerentemente grânulos de informação na presença de evidências experimentais (dados numéricos). Considera-se como justificável a construção do grânulo de informação altamente legítimo (justificado) com evidência experimental e semântica bem articulada (específico). O design dessa construção do grânulo de informação associa-se a um índice de otimização bem definido com os dois requisitos de *justificativa experimental* e *especificidade*.

3.2 O PRINCÍPIO DA GRANULARIDADE JUSTIFICÁVEL

Segundo (PEDRYCZ; WANG, 2016), o princípio da granularidade justificável enfatiza que qualquer grânulo de informação deve refletir a evidência experimental (dados de entrada numéricos, por exemplo) preservando sua semântica e mantendo um nível aceitável de especificidade. Ainda segundo Liu et al. (2018), o princípio oferece uma maneira de construir um grânulo de informação com base em algumas evidências experimentais de modo que o grânulo de informação resultante seja experimentalmente justificável e semanticamente sólido. Por justificativa experimental, Liu et al. (2018) quer dizer que o grânulo tem uma cobertura sobre os dados e, por consequência, legitima a existência deste grânulo.

Em Fu et al. (2019) é apresentada uma abordagem de classificação granular baseada em lógica fuzzy fundamentada no princípio de granularidade justificável que permite melhorar a acurácia e interpretabilidade de sistemas de classificação, possibilitando que objetos sejam agrupados em diferentes níveis de granularidade com base em suas características. O objetivo é tornar a classificação mais flexível e adaptável às necessidades específicas de um problema, possibilitando uma melhor representação das nuances entre diferentes categorias.

O princípio da granularidade justificável é de natureza geral, por oferecer suporte a descrições de construção não apenas de conjuntos fuzzy, mas de grânulos de informação em geral (PEDRYCZ; WANG, 2016). Este princípio é um dos fundamentos da computação granular que leva à construção de grânulos de informação, especialmente conjuntos fuzzy, cuja relevância se torna crucial quando usada na modelagem de sistemas fuzzy baseados em regras.

Ainda em Pedrycz e Wang (2016), o problema de otimização do grânulo de informação é descrito da seguinte forma:

- É formado um representante numérico dos dados e, em torno dele, é construído um grânulo de informação procurado como uma faixa elástica que pode ser ajustada (esticada ou contraída) para ambos os requisitos de cobertura e especificidade poderem ser cumpridos significativamente.
- É de caráter geral e produz grânulos de informação em termos de intervalos e conjuntos fuzzy.
- É possível incluir pesos de dados: diferentes níveis de contribuição de dados para a realização do grânulo de informações.

Cobertura e especificidade são definições com relações conflitantes, ou seja, quanto maior a cobertura $cov(.)$ de um conjunto de dados menor será sua especificidade $sp(.)$ e vice-versa. Ambas serão descritas nas Subseções 3.2.1 e 3.2.2.

Com o princípio da granularidade justificável, o grânulo de informação A associado a um conjunto de dados $\{x_1, x_2, \dots, x_N\}$ pode ser formado maximizando a relação entre cobertura e especificidade. A Equação 3.1 (LIU et al., 2018) descreve essa otimização do grânulo de informação (ou Índice de Desempenho Otimizado) a partir dos conceitos de cobertura e especificidade aplicado a um grânulo de informação A .

$$Q = cov(A) * sp(A) \quad (3.1)$$


Por meio do índice obtido na Equação 3.1 é possível definir os pontos ótimos das extremidades das funções de pertinência triangulares e trapezoidais por meio da Equação 3.2 (LIU et al., 2018) ao maximizar Q considerando as faixas elásticas das extremidades do limite esquerdo e direito da função de pertinência:

$$a_{opt} = argmax_A Q(A) \quad (3.2)$$

Desse modo, $Q(A)$ determina quais os novos pontos das extremidades das funções de pertinência que maximizam a relação de cobertura e especificidade nos parâmetros para os limites esquerdo e direito de cada função (triangular ou trapezoidal).

Na Figura 3.1 é exemplificado o comportamento ao percorrer cada elemento a_i e b_i para determinar o novo ponto de extremidade com o máximo índice de desempenho otimizado em cada faixa elástica da função.

Figura 3.1 Exemplo de faixa elástica em uma função triangular onde são aplicados os conceitos de cobertura e especificidade (Fonte: Autor)



3.2.1 Cobertura

A cobertura (representada por $cov(.)$) é um índice usado para identificar quanto um subconjunto abrange o conjunto ao qual ele está contido e, dessa forma, o legitima. Conforme apresentado em Liu et al. (2018), a cobertura de um conjunto fuzzy pode ser obtida conforme a Equação 3.3 a seguir:

$$cov(A_{ij}) = \sum_{k=a'_{ij}}^{b'_{ij}} \min(f_{ij}(x_k), w_k) \quad (3.3)$$

Onde A representa o conjunto de atributos do dado de entrada; i e j representam a quantidade de atributos e de tipos de funções de pertinência, respectivamente; A_{ij}

representa o i -ésimo atributo no contexto de uma função de pertinência fuzzy f_{ij} ; a'_{ij} e b'_{ij} são, respectivamente, os limites de um subconjunto fuzzy da função de pertinência f_{ij} ; n é o tamanho do dado de entrada (quantidade de elementos os registros do conjunto de dados); $f_{ij}(x_k)$ é o grau de pertinência de um valor x_k dado pela j -ésima função fuzzy f_j do i -ésimo atributo do conjunto de dados e w_k é o peso desse valor x_k . Neste trabalho, os pesos dos valores numéricos são determinados pelas suas respectivas distribuições de frequências normalizadas na escala $0-1$ portanto, finalmente, o conjunto de valores será representado por um conjunto de tuplas da seguinte forma $\{(x_1, w_1), \dots, (x_n, w_n)\}$

3.2.2 Especificidade

A especificidade (representada por $sp(\cdot)$) é descrita como uma medida que avalia o quão específico (detalhado) é um subconjunto. Dessa forma, como apresentado por Pedrycz e Wang (2016), a especificidade $sp(\cdot)$ exibe algumas propriedades:

1. $sp(x) = 1$. A especificidade de um único elemento é máxima e igual a 1.
2. se $X_1 \subset X_2$, $sp(X_1) \geq sp(X_2)$

A equação da especificidade é calculada sob o aspecto ascendente ou descendente da função de pertinência, que varia conforme o "lado" da extremidade determinada por um parâmetro (a ou b) da função. Dessa forma, a Equação 3.4 a seguir, conforme apresentada em Liu et al. (2018), descreve a forma de obter a especificidade de um subconjunto fuzzy que cobre o aspecto descendente ou "lado direito" (tendo o parâmetro m como delimitador) de uma função de pertinência triangular.

$$sp(A_{right}) = \int_0^1 \left(1 - \frac{f^{-1}(x) - m}{right_range}\right) dx = 1 - 0.5 \frac{b - m}{right_range} \quad (3.4)$$

Onde, $right_range = b - m$ e f^{-1} representa a função inversa de uma função de pertinência fuzzy. Para o lado decrescente (direito) de funções triangulares, a função inversa é descrita por $b - (b - m) \times x$.

Similarmente, a especificidade de um subconjunto fuzzy que representa o lado crescente (esquerdo) de uma função de pertinência (triangular, nesse caso) pode ser obtida com a Equação 3.5

$$sp(A_{left}) = \int_0^1 \left(1 - \frac{(a + (m - a) \times x) - m}{left_range}\right) dx = 1 - 0.5 \frac{|a - m|}{left_range} \quad (3.5)$$

Do mesmo modo, $left_range = m - a$.


3.3 CONSIDERAÇÕES FINAIS

Nos resultados do trabalho de Pedrycz e Wang (2016), conjuntos fuzzy formados com base no princípio de granularidade justificável retêm sua semântica (capturada pelos critérios de cobertura e especificidade). Por certo, este é um recurso que pode ser utilizado na construção e refinamento de modelos fuzzy com conjuntos com valor semântico.

Cobertura e especificidade são conceitos elementares importantes utilizados no desenvolvimento do método proposto neste trabalho. A partir desses conceitos, é possível calcular um índice de desempenho otimizado que permite ajustar, configurar formas granulares e definir tipos apropriados de funções de pertinência que se adéquem melhor ao conjunto de dados.

Na Figura 3.2, é realizada uma demonstração do procedimento para cálculo do índice de desempenho otimizado que determina o ponto ótimo a' da extremidade esquerda de uma função de pertinência triangular (originalmente definido por $a = 1$). Considerando os valores do exemplo em questão, é possível notar que o ponto ótimo resultante para o parâmetro a da função de pertinência foi o valor $x = 4$ com grau de pertinência $f(4) = 0.3$, cobertura 3.5 em relação ao ponto m , especificidade 0.66 também em relação ao ponto m e finalmente com o máximo índice de desempenho otimizado igual a **2.31**.

Figura 3.2 Exemplo do cálculo do índice de desempenho otimizado e definição do ponto ótimo da extremidade esquerda de uma função triangular (Fonte: Autor)



Os conceitos apresentados neste capítulo sobre o princípio da granularidade justificável reforçam seu grande potencial para exploração da interpretabilidade em conjuntos fuzzy e, conseqüentemente, em regras fuzzy de Sistemas Fuzzy Baseados em Regras. Os conceitos de cobertura e especificidade justificam os grânulos de informação das funções de pertinência que representam termos linguísticos em bases de regras fuzzy. Nesta dissertação, portanto, o método apresentado refina o processo de geração de regras fuzzy para criar uma base de regras capaz de modelar um sistema fuzzy a partir de ajustes em parâmetros das funções de pertinência, buscando aumentar a legibilidade e interpretabilidade dos dados.

4.1 CONSIDERAÇÕES INICIAIS

Sistemas Fuzzy Baseados em Regras possibilitam a construção de um modelo para inferência fuzzy com ou sem a necessidade de um especialista. A construção da base de regras fuzzy é uma etapa importante desse processo, pois, dentre outras questões, a sua construção pode influenciar diretamente na acurácia do resultado da inferência e na interpretabilidade do modelo gerado.

Este trabalho tem como objetivo a apresentação de uma abordagem *data-driven* que explore o Princípio da Granularidade Justificável (PGJ) para dar forma às funções de pertinência utilizadas para construção da base de regras baseando-se nos dados de entrada, melhorando a interpretabilidade dessas regras e do modelo fuzzy gerado com funções de pertinência que melhor representam os dados sob cobertura delas.

4.2 ESPECIFICIDADE E GRANULARIDADE NA GERAÇÃO DE REGRAS FUZZY

A proposta apresentada por Sudkamp (2001) já revisitava as relações entre granularidade, especificidade, interpretabilidade e eficiência de regras fuzzy, questões estas consideradas na formulação da presente proposta.

A granularidade e especificidade são conceitos que já têm sido explorados em estudos que visam algum tipo de otimização de modelos numéricos, como o trabalho apresentado por Zhu, Pedrycz e Li (2021), no qual os autores elaboraram uma proposta para design e análise de dados granulares e modelagem granular dos espaços de saída de modelos numéricos. Os autores alocam um nível de granularidade de informação entre as variáveis de entrada para obter uma visão melhor sobre a classificação destas variáveis e obter saídas do modelo granular como grânulos de informação (como conjuntos fuzzy, intervalos ou conjuntos aproximados) maximizando a especificidade e cobertura das saídas. Os autores ainda citam dois princípios fundamentais da computação granular para construção do espaço de entrada granular: 1) o princípio da granularidade justificável (PGJ) e 2) a alocação ideal da granularidade da informação. Com isso, os autores quantificam a

qualidade desse espaço de entrada em termos da especificidade dos resultados produzidos pelo modelo granular e a cobertura dos dados experimentais fornecidos pelo modelo.

O método para geração de regras fuzzy, proposto por Wang e Mendel (1992) (**W&M**) será reformulado na proposta deste trabalho para ser possível a geração das regras fuzzy já com a aplicação do princípio da granularidade justificável no processo de otimização dos parâmetros das funções de pertinência. A proposta desse trabalho será incluída nesse processo de geração de regras, construindo funções de pertinência com formas e tipos otimizadas pelo PGJ.

4.3 GRANULARITY TO ENSURE INTERPRETABILITY OF THE FUZZY RULES (GENI-FR)

Diante da necessidade de um método para geração de regras em um sistema fuzzy com base no PGJ que lide com variáveis linguísticas mapeadas por diferentes tipos de termos linguísticos e com funções de pertinência heterogêneas de diferentes tipos e configurações, faz-se necessário o desenvolvimento de métodos como o apresentado nesse trabalho, que viabiliza a construção ajustada da base de regras fuzzy norteando-se pelo PGJ tornando o sistema altamente legível e interpretável.

O principal objetivo desse trabalho concentra-se em desenvolver um método com abordagem *data-driven* para design granular de regras fuzzy chamado GENI-FR (**G**ranularity to **E**nsure **I**nterpretability of the **F**uzzy **R**ules), que visa representar de forma linguística, por meios de termos representados por funções de pertinência que passaram por um refinamento de suas configurações, dados numéricos mapeados entre 0 – 1 utilizando partições fuzzy, mantendo a incerteza presente nesses dados e apresentando-a em grânulos de informação por meio de regras fuzzy. Destaca-se a importância de um sistema que tenha a interpretabilidade como medida de desempenho para melhor representação dessa incerteza.

De modo geral, o método GENI-FR visa construir uma representação granular de regras fuzzy para suporte das variáveis linguísticas de um conjunto de dados em diferentes termos linguísticos e, dessa forma, podem ser projetadas diferentes tipos, configurações e quantidades de funções de pertinência (observando o impacto do aumento dessa quantidade na interpretabilidade do modelo e da base de regras fuzzy) e diferentes formatos, ajustados com a aplicação do PGJ para incremento da interpretabilidade e legibilidade dessas regras, sem perdas nos níveis de acurácia quando comparado com métodos já conhecidos da literatura.

Na proposta apresentada por Pedrycz, Gacek e Wang (2021), que trata de uma abordagem para interpretabilidade de modelos de séries temporais, o ponto de partida é um modelo fuzzy baseado em regras já previamente construído e disponível, altamente dependente do design definido para essas regras. A proposta do referido trabalho tem uma abordagem dividida em três etapas principais: decomposição das partes de condições das regras fuzzy, construção da informação granular e construção de regras que possibilitam a visualização de conjuntos fuzzy ou grânulos de informação como símbolos. Assim como no trabalho em questão, na proposta desse estudo é objetivada a formação de regras fuzzy cujos termos linguísticos são ajustados adequadamente conforme as características

do conjunto de dados e da aplicação do princípio da granularidade justificável, o que possibilita o aumento da interpretabilidade em datasets de diferentes contextos.

Para possibilitar um melhor entendimento do método proposto nesse trabalho, serão detalhas no Algoritmo 1 as etapas do processo para construção da base de regras fuzzy com os refinamentos realizados nas funções de pertinência, possibilitados pelo PGJ.

O Algoritmo 1, de maneira geral, é composto principalmente pelas seguintes etapas:

1. Criar uma lista de tipos de funções de pertinência lineares que serão aplicadas aos dados (ex: triangular, trapezoidal, etc.) [Parâmetro *types_of_mbf*];
2. Mapear as colunas do conjunto de dados como variáveis linguísticas compostas por K partições fuzzy obtidos da aplicação de funções de pertinência simétricas [Linha 5] e posterior refinamento e ajustes de seus parâmetros;
3. Percorrer cada coluna do conjunto de dados, para cada conjunto de tipos de função de pertinência e seus respectivos termos linguísticos, serão calculados os índices de otimização do princípio da granularidade justificável para cada extremidade (ou "lado") da função de pertinência [Linhas 7 à 21]. Na Linha 21 é escolhido o ponto ótimo do intervalo com o maior valor de índice obtido da relação entre cobertura e especificidade;
4. Definir, ao final, dentre todas as funções de pertinência verificadas em cada extremidade ("lado") dos intervalos, a que obteve o maior índice de otimização (Linha 22 com a chamada para a função do Algoritmo 2).

O Algoritmo 2 é responsável por determinar qual é a função de pertinência, em cada uma das extremidades, que possui o melhor índice de desempenho otimizado Q obtido da relação entre cobertura e especificidade para cada um dos possíveis pontos de extremidade com as melhores configurações encontradas pelo Algoritmo 1. Isso permite, por exemplo, que exista uma função de pertinência triangular do "lado"esquerdo (crescente) ao ponto médio m e que exista uma função de pertinência trapezoidal à direita do ponto médio, pois estas podem ter sido definidas por terem o máximo índice de desempenho em cada um dos lados em questão para um determinado conjunto de dados com determinadas características.

Vale ressaltar, que no trabalho apresentado por Liu et al. (2018), o ponto modal m das funções de pertinência é determinado pela média ponderada dos dados. Nesse trabalho, o parâmetro m pode ser ajustado em trabalhos futuros pela média ponderada dos parâmetros dos pontos limites das funções de pertinência (entre o limite inferior a_{kj} e superior b_{kj}) ou pela mediana considerando o subconjunto de dados entre esses pontos. Para funções trapezoidais, o ponto médio entre os pontos m e n podem ser determinados da mesma forma, sendo p esse ponto médio e $\alpha \in \mathbb{Z}^+$, os valores de m e n podem ser determinados como $m = p - \alpha, n = p + \alpha$.

Na análise dos experimentos realizados, apresentados no Capítulo a seguir, foram utilizadas apenas as funções de pertinência triangulares e trapezoidais e o conjunto resultante de cada variável contém uma, as duas ou um misto de ambas as funções no mesmo

Algorithm 1 GENI_FR(*data*, *types_of_mbf*, *K*)

```

1: sides  $\leftarrow$  {'left', 'right'}
2: data  $\leftarrow$  normalize(data)
3: columns  $\leftarrow$  data.columns
4: n_rows, m_columns  $\leftarrow$  data.length(), columns.length()
5: fuzzy_sets  $\leftarrow$  create_fuzzy_sets(m_columns, types_of_mbf, k)    ▷ Define os
    parâmetros e quantidade dos conjuntos fuzzy em cada domínio e para cada tipo de
    função de pertinência
6: opt_ff  $\leftarrow$   $\emptyset$ 
7: for i_col  $\leftarrow$  1, m_columns do
8:   for i_fs  $\leftarrow$  1, fuzzy_sets.length() do
9:     fs  $\leftarrow$  fuzzy_sets[i_col][i_fs]
10:    for i_ff  $\leftarrow$  1, fs.length() do                                     ▷
    Percorre todos os conjuntos fuzzy definidos para cada tipo de função de pertinência
    em cada domínio. O tamanho length dessa variável é justamente a quantidade de
    configurações diferentes de funções de pertinência nos conjuntos (cujo índice dessas
    funções é representado por i_ff)
11:      ff  $\leftarrow$  fs[i_ff]    ▷ Obtém os parâmetros da i-ésima função de pertinência
    e atribui à variável ff
12:      for j  $\leftarrow$  1, sides.length() do    ▷ O tamanho da quantidade de sides é
    sempre 2 (lados esquerdo e direito)
13:        start_point  $\leftarrow$  idxmin(ff[sides[j]].parameters)    ▷ Menor valor x
    para cada side
14:        end_point  $\leftarrow$  idxmax(ff[sides[j]].parameters)    ▷ Maior valor x para
    cada side
15:        opt  $\leftarrow$  (ff.midpoint, 0.0, 1.0, 0.0)    ▷ Define parâmetros padrões que
    serão substituídos pelos parâmetros refinados
16:        for i_row  $\leftarrow$  start_point, end_point do    ▷  $O(n)$ 
17:          new_boundary  $\leftarrow$  data[i_col][i_row]
18:          ig  $\leftarrow$  info_granule(new_boundary, data[i_col], fs, ff, side)    ▷
     $O(n)$ : Calcula o índice de desempenho otimizado para o grânulo de informação em
    questão
19:          if ig[2] > opt[2] then
20:            opt  $\leftarrow$  ig    ▷ Obtém o argmax dos índices de desempenho
    calculados
21:          fuzzy_sets[i_col][i_fs][i_ff].set_optimal_bounds(opt, side)    ▷
    Atualiza os parâmetros de cada função de pertinência em cada conjunto fuzzy com
    os parâmetros ótimos calculados
22:    opt_ff.push(get_optimal_functions(fuzzy_sets, k))    ▷ Define a melhor
    função de pertinência para cada lado side de acordo com a que obtive o maior dos
    índices de desempenho otimizado

```

Algorithm 2 `get_optimal_functions(fuzzy_sets, k)`

```

1:  $n \leftarrow \text{fuzzy\_sets.length}()$ 
2:  $\text{opt\_functions}[1..k] \leftarrow \emptyset$ 
3: for  $i \leftarrow 1, k$  do
4:    $\text{opt\_f} \leftarrow \text{fuzzy\_sets}[1, i]$ 
5:   for  $j \leftarrow 2, n$  do
6:      $\text{fuzzy\_f} \leftarrow \text{fuzzy\_sets}[j, i]$ 
7:     if  $\text{fuzzy\_f}['\text{left\_side}'].opt\_bound() > \text{opt\_f}['\text{left\_side}'].opt\_bound()$ 
8:       then
9:          $\text{opt\_f}['\text{left\_side}] \leftarrow \text{fuzzy\_f}$ 
10:    if  $\text{fuzzy\_f}['\text{right\_side}'].opt\_bound() > \text{opt\_f}['\text{right\_side}'].opt\_bound()$ 
11:      then
12:         $\text{opt\_f}['\text{right\_side}] \leftarrow \text{fuzzy\_f}$ 
13:     $\text{opt\_functions}[i] \leftarrow \text{opt\_f}$ 

```

termo fuzzy linguístico. O lado esquerdo de uma função de pertinência pode ser, por exemplo, trapezoidal com pontos a' e m e o lado direito dessa função pode ser triangular com pontos m' e b' , resultando em uma função visualmente trapezoidal, mas com uma forma refinada, tendo o parâmetro m' (ajustado) no lugar de onde seria o parâmetro n de uma função trapezoidal.

4.4 CONSIDERAÇÕES FINAIS

O método GENI-FR trata, elementarmente, da definição das configurações dos parâmetros ótimos das funções de pertinência que serão utilizadas no processo de construção da base de regras fuzzy. Neste trabalho, foi utilizado o método de W&M para gerar a base de regras fuzzy a partir desses parâmetros otimizados e refinados pelo método proposto. Isto ressalta, mais uma vez, o propósito geral do método em poder ser utilizado por quaisquer outros mecanismos de geração de regras ou de inferência fuzzy.

As medidas de complexidade do processo de definição e construção da base de regras fuzzy não são altamente prejudicados pelo cálculo da cobertura e especificidade, pois este procedimento acontece nas mesmas iterações que acontecem para definição dos parâmetros e configurações dos conjuntos fuzzy e não como outra execução independente que precise de uma base de regras já previamente construída.

Desse modo, é então incluído o custo computacional $\mathcal{O}(n^2m)$ associado ao cálculo da cobertura (ao calcular os melhores parâmetros das extremidades das funções de pertinência de todo o conjunto de dados de todos os atributos do conjunto de dados) e a complexidade $\mathcal{O}(1)$ para cálculo da especificidade em cada elemento x (considerando que a ela pode ser calculada no mesmo contexto de laço de repetição onde a cobertura é calculada).

Em Pedrycz, Gacek e Wang (2021) é apresentada uma proposta que visa a interpretabilidade de modelos baseados em regras fuzzy, que conclui que os mecanismos de interpretabilidade do estudo podem ser também aplicados em técnicas de outros domí-

nios de conhecimento, como em modelos de agrupamento com o intuito de aumentar a interpretabilidade de seus resultados ou do próprio modelo.

Dessa forma, o método apresentado neste trabalho é aplicável em cenários livres de domínio, possibilitando que o GENI-FR que tem como base sua aplicação diretamente no processo de construção de regras fuzzy possa ser ajustado para posteriores aplicações em tarefas de agrupamento, regressão ou classificação de dados em outros contextos para além dos analisados neste trabalho, desde que possíveis de serem representados como informação granular em conjuntos fuzzy.

Como resultado do método GENI-FR, são obtidos conjuntos fuzzy com funções de pertinência construídas com parâmetros ajustados às características dos dados, como demonstrado na Figura 5.2.

No próximo capítulo serão apresentados os experimentos realizados para sustentação da proposta deste trabalho.

RESULTADOS

5.1 CONSIDERAÇÕES INICIAIS

Os resultados dos experimentos apresentados neste capítulo foram obtidos a partir da execução dos métodos considerando os datasets (bases de dados) disponíveis no *UCI Repository*¹, utilizados em tarefas de classificação e listados na Tabela 5.1. Todos os datasets foram submetidos a testes utilizando *10-fold-cross-validation* e registradas as médias de acurácia e médias da quantidade de regras em execuções com 3, 5 e 7 termos linguísticos representados por funções de pertinência triangulares ou trapezoidais.

Tabela 5.1 Informações sobre os datasets utilizados nos experimentos

<i>Dataset</i>	<i>Instâncias</i>	<i>Atributos</i>	<i>Classes</i>	<i>Classe Majoritária</i>
Abalone	4174	7	28	1 (36.58%)
Banana	5300	2	2	1 (55.17%)
Bupa	345	6	2	2 (57.97%)
Haberman	306	3	2	1 (73.53%)
Phoneme	5404	5	2	1 (70.65%)
Pima	768	8	2	1 (65.10%)
Saheart	462	9	2	1 (65.37%)
Shuttle	58000	9	7	1 (78.60%)
Titanic	2201	3	2	1 (67.70%)

O método GENI-FR foi analisado e comparado com os métodos FRBCS.CHI e FRBCS.W, ambos já conhecidos na literatura em tarefas de classificação e disponíveis no pacote *frbs*² da linguagem de programação *R*³. Para realização da inferência, o pacote *frbs* recebe como

¹<https://archive.ics.uci.edu/datasets?Task=Classification>

²<https://cran.r-project.org/web/packages/frbs/>

³<https://www.r-project.org/>

entrada a base de regras gerada pelo GEnI-FR e realiza a classificação considerando que as regras com os maiores graus de compatibilidade determinam a classe consequente. Os métodos aos quais o GEnI-FR foi comparado são descritos a seguir:

- **FRBCS.CHI:** Sistema de classificação baseado em regras fuzzy que utiliza a técnica de Chi, proposta por Chi, Yan e Pham (1996) com o intuito de estender o método de W&M para lidar com problemas de classificação, utilizando, no entanto, rótulos de classes nos consequentes das regras fuzzy SE-ENTÃO uma vez que é baseado no modelo FRBCS (Fuzzy Rule-based Classification System).
- **FRBCS.W:** Sistema de classificação baseado em regras fuzzy com fator de ponderação, proposto por Ishibuchi e Nakashima (2000) onde cada regra fuzzy SE-ENTÃO consiste em valores linguísticos antecedentes e uma única classe consequente com graus de certeza (que funcionam como pesos das regras). É um método adequado apenas para problemas de classificação onde a classe consequente é definida como a classe dominante no subespaço fuzzy correspondente à parte antecedente de cada regra fuzzy.

O método GEnI-FR foi submetido a todos os datasets gerando uma base de regras fuzzy com termos linguísticos representados tanto por funções de pertinência triangulares quanto por funções trapezoidais na mesma variável linguística, não seguindo a abordagem de métodos tradicionais em se limitar a atribuir um único tipo de função de pertinência a todo o conjunto fuzzy. Desse modo, foram construídas partições fuzzy que se ajustaram mais adequadamente às frequências e características dos dados de cada variável linguística e cujos resultados serão apresentados no decorrer deste capítulo.

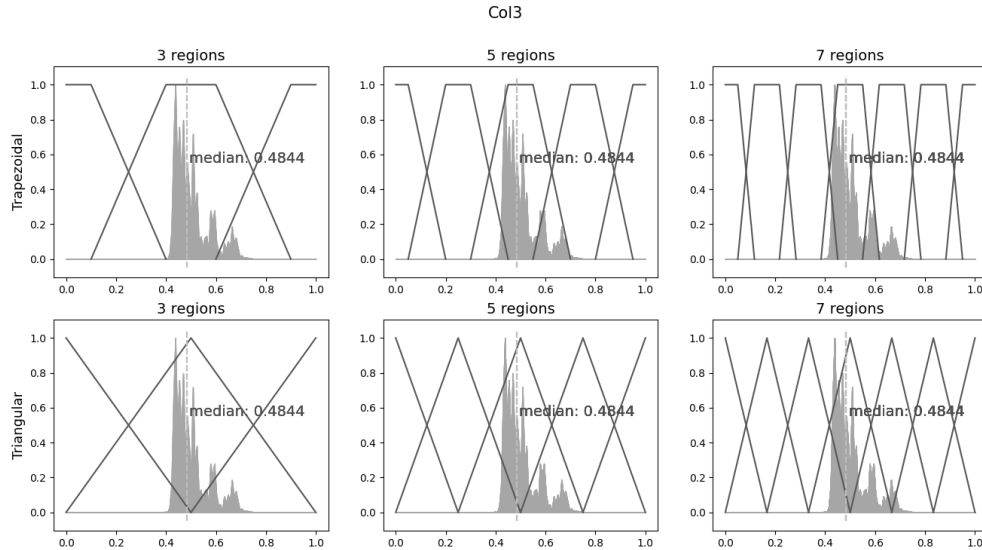
5.2 RESULTADOS OBTIDOS

Na Figura 5.1 é apresentado o conjunto de dados normalizados de uma das variáveis do dataset **Shuttle**, em um de seus folds durante os experimentos, mapeado com funções de pertinência com pontos que dividem o conjunto de dados de forma simétrica cuja configuração foi definida pelo desenvolvedor sem nenhuma abordagem baseada nas características dos dados. Esses mesmos folds do conjunto de dados são submetidos ao GEnI-FR para criação de funções de pertinência ajustadas conforme o princípio da granularidade justificável e do índice de otimização, ambos baseados nas características dos próprios dados.

Na Figura 5.2 é possível identificar os ajustes feitos nas formas das funções de pertinência com 3, 5 e 7 termos linguísticos, respectivamente. É possível notar, em especial, um ajuste bem claro realizado das funções de pertinência do conjunto com 3 termos, apresentando funções de pertinência mais ajustadas ao conjunto de dados. É possível notar ajustes feitos nas partições com 5 e 7 termos linguísticos, inclusive com tipos mistos de funções de pertinência (tanto trapezoidal quanto triangular), nas distâncias entre os pontos m e n das funções trapezoidais e uma representação muito clara dos termos linguísticos que possuem maior cobertura sobre o conjunto de dados.


É possível notar que as partições com 5 e 7 termos linguísticos são representações difíceis de serem lidas e interpretadas por um agente humano mesmo com os ajustes e

Figura 5.1 Funções de pertinência com pontos simétricos de uma das colunas do dataset *Shuttle* (*Col3*) em um dos folds dos experimentos (Fonte: Autor)



refinamentos feito pelo GENI-FR. Mesmo com as funções se adequando bem às distribuições dos dados, o número de termos linguísticos impacta na quantidade e legibilidade das regras fuzzy. No entanto, esses prejuízos à legibilidade e interpretabilidade são maiores nas representações com funções de pertinência com pontos simétricos, uma vez que os formatos e características dos termos linguísticos não observam a natureza dos dados (não consideram a característica e distribuição dos dados).

Figura 5.2 Funções de pertinência ajustadas pelo GENI-FR de uma das colunas do dataset *Shuttle* (*Col3*) em um dos folds dos experimentos (Fonte: Autor)



As Imagens 5.3 e 5.4 apresentam as funções triangulares e trapezoidais originais e as funções ajustadas resultantes da execução do GENI-FR, respectivamente, em outra variável (*Col7*) do mesmo fold do dataset *Shuttle*. Nestas respectivas imagens é possível verificar mais uma vez o comportamento do GENI-FR no ajuste feito nas funções de pertinência fuzzy com base na frequência dos dados e como elas passaram a representar

os dados sob sua cobertura.

Figura 5.3 Funções de pertinência com pontos simétricos de uma das colunas do dataset *Shuttle* (*Col7*) em um dos folds dos experimentos (Fonte: Autor)

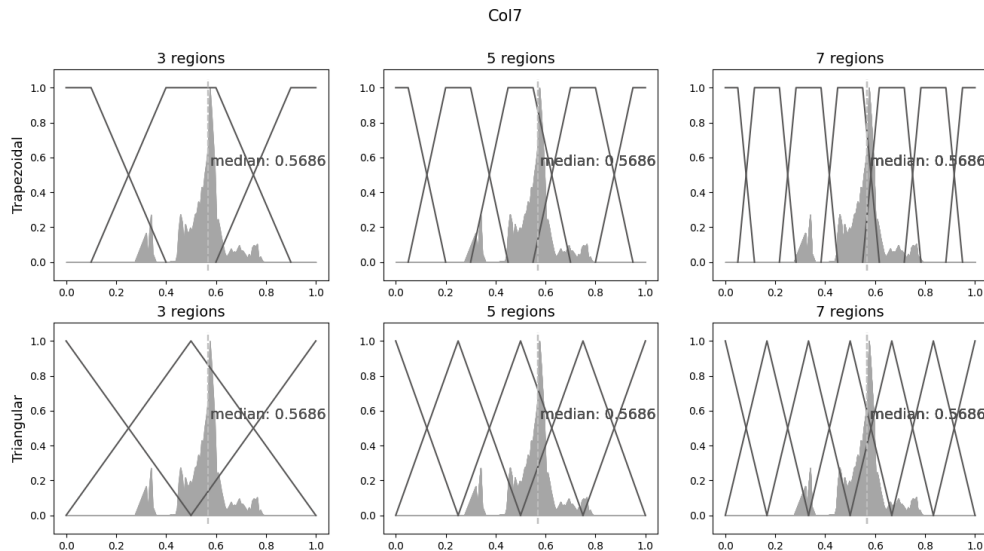



Figura 5.4 Funções de pertinência ajustadas pelo GENI-FR de uma das colunas do dataset *Shuttle* (*Col7*) em um dos folds dos experimentos (Fonte: Autor)



5.2.1 Desempenho do GENI-FR em comparação a outros métodos da literatura


Diante dos resultados dos experimentos foram realizadas comparações do método proposto com métodos de classificação fuzzy já conhecidos na literatura (FRBCS.W e FRBCS.CHI). Foram comparados os resultados do GENI-FR com 3, 5 e 7 partições fuzzy (para possibilitar uma quantidade variada de termos fuzzy nas comparações dos resultados) com as respectivas quantidades de termos também nos demais métodos. Um dos grandes potenciais observado do GENI-FR é o fato dele poder implementar até dois tipos de funções

de pertinência em cada conjunto fuzzy, enriquecendo o modelo gerado de uma forma que os demais métodos de geração de regras clássicos não fazem.

Com as ponderações apresentadas, as comparações foram realizadas procurando entender como a versão mais simplificada de configurações do GENI-FR (com apenas 3 termos linguísticos) se comporta quando comparada com a mesma versão de 3 termos dos demais métodos e com as versões mais acuradas dos mesmos (com 5 e 7 termos linguísticos). Esse comportamento foi analisado em termos de como se comportavam a média da acurácia e a média da quantidade de regras fuzzy geradas em cada um dos métodos e em cada uma das configurações de quantidade de termos.

Nas Imagens 5.5, 5.6 e 5.7 são expressos os comportamentos dos resultados do GENI-FR com 3 termos linguísticos, não aumentando os índices de acurácia, porém mantendo-os bem próximos aos resultados do método FRBCS.CHI com as configurações de 3, 5 e 7 partições. Além disso, o GENI-FR gera uma quantidade de regras fuzzy muito inferior na sua configuração de 3 termos linguísticos e ainda assim mantendo os mesmos níveis de acurácia.

Figura 5.5 Comparação dos melhores resultados do GENI-FR 3 termos vs FRBCS.CHI 3 termos (Fonte: Autor)



O mesmo comportamento apresentado anteriormente na comparação com o dataset FRBCS.CHI também é perceptível nos resultados do GENI-FR comparados ao método FRBCS.W (apresentados nas Imagens 5.8, 5.9 e 5.10), mantendo os mesmos níveis de acurácia (sem necessariamente aumentá-los) ao utilizar apenas 3 termos linguísticos, porém gerando uma quantidade inferior de regras fuzzy.

Figura 5.6 Comparação dos melhores resultados do GEnI-FR 3 termos vs FRBCS.CHI 5 termos (Fonte: Autor)

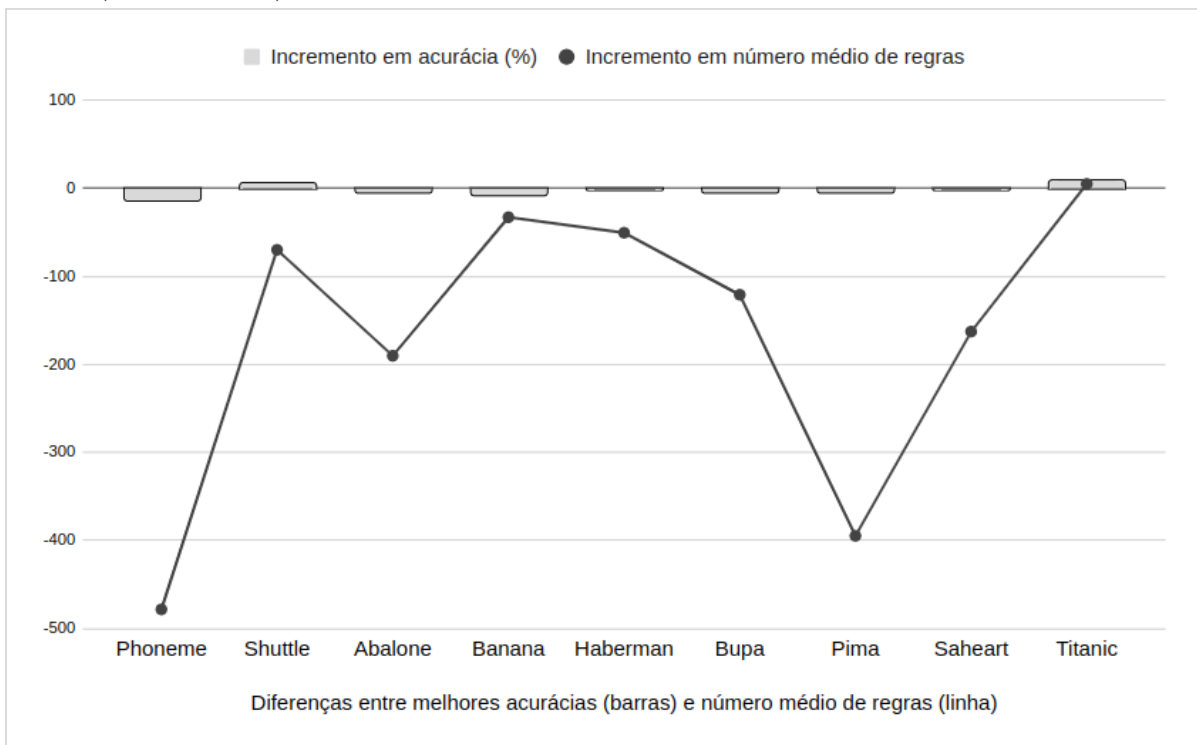


Figura 5.7 Comparação dos melhores resultados do GEnI-FR 3 termos vs FRBCS.CHI 7 termos (Fonte: Autor)




Figura 5.8 Comparação dos melhores resultados do GEnI-FR 3 termos vs FRBCS.W 3 termos (Fonte: Autor)




Figura 5.9 Comparação dos melhores resultados do GEnI-FR 3 termos vs FRBCS.W 5 termos (Fonte: Autor)





Figura 5.10 Comparação dos melhores resultados do GEnI-FR 3 termos vs FRBCS.W 7 termos (Fonte: Autor)



Os dados detalhados com os resultados dos experimentos em cada uma das configurações de termos e tipos de funções de todos os métodos estão exibidos nas Tabelas 5.2, 5.3, 5.4 (resultados do GENI-FR), 5.5, 5.6, 5.7 (melhores resultados do FRBCS.CHI com os respectivos tipos de funções de pertinência), 5.8, 5.9, 5.10 (melhores resultados do FRBCS.W com os respectivos tipos de funções de pertinência). Desse modo, o GENI-FR não possui como objetivo principal obter o melhor resultado de acurácia comparado aos outros métodos (linhas destacadas em **negrito**), porém fica evidente que seus resultados de acurácia se mantêm bem próximos aos demais métodos, no entanto, gerando uma quantidade muito inferior de regras fuzzy.

Foram construídas e analisadas tabelas (5.11, 5.12, 5.13, 5.14, 5.15, 5.16) que comparam o percentual de incremento em acurácia e o percentual de incremento na média de regras fuzzy obtidos com os resultados dos experimentos do GENI-FR comparados com o FRBCS.W e FRBCS.CHI. É importante destacar que, analisando cada um dos conjuntos de dados das tabelas, quando o percentual de incremento em acurácia é positivo, significa que o GENI-FR teve um resultado superior quando analisada a acurácia do experimento e, portanto, um resultado inferior quando possui esse percentual negativo. Em contrapartida, quando o percentual de incremento na média de regras é negativo, significa que o número de regras fuzzy necessárias geradas pelo GENI-FR foi inferior ao modelo comparado e, portanto, torna a base de regras e os resultados do modelo mais interpretáveis. Quando esse percentual de incremento na média de regras é positivo significa que o GENI-FR gerou mais regras do que o modelo comparado.

Tabela 5.2 Resultados médios de acurácia nos folds que utilizaram 3 termos linguísticos - GENI-FR

Dataset	Média (acurácia)	Desvio padrão (acurácia)	Média (regras)
Phoneme	0.64747	0.02316	28.8
Shuttle	0.79392	0.12119	14.7
Abalone	0.39765	0.01719	16.1
Banana	0.64264	0.02385	7.9
Haberman	0.70312	0.08827	16
Bupa	0.52547	0.09169	26.2
Pima	0.63284	0.04382	69.6
Saheart	0.62530	0.10362	77.3
Titanic	0.73424	0.04687	7.9

5.3 CONSIDERAÇÕES FINAIS

Diante da análise dos resultados obtidos e apresentados neste capítulo, o método GENI-FR é capaz de aumentar a interpretabilidade do sistema fuzzy, ajustando diretamente na parametrização e construção das funções de pertinência do sistema fuzzy. Os resultados demonstram que o GENI-FR com apenas 3 termos linguísticos pode alcançar acurácia comparável aos modelos aos quais foi comparado e que utilizaram mais regras fuzzy para obter resultados similares. Além disso, GENI-FR melhora a interpretabilidade dos

Tabela 5.3 Resultados médios de acurácia nos folds que utilizaram *5 termos* linguísticos - GEnI-FR

Dataset	Média (acurácia)	Desvio padrão (acurácia)	Média (regras)
Phoneme	0.71207	0.01910	63.7
Shuttle	0.74393	0.13231	29.5
Abalone	0.38255	0.02572	27.0
Banana	0.58075	0.02034	15.0
Haberman	0.72570	0.06263	32.8
Bupa	0.44639	0.06529	57.4
Pima	0.58850	0.06169	92.4
Saheart	0.63626	0.06340	94.8
Titanic	0.72058	0.04886	5.9

Tabela 5.4 Resultados médios de acurácia nos folds que utilizaram *7 termos* linguísticos - GEnI-FR

Dataset	Média (acurácia)	Desvio padrão (acurácia)	Média (regras)
Phoneme	0.73742	0.02236	70.9
Shuttle	0.92631	0.02639	29.0
Abalone	0.41872	0.02581	31.8
Banana	0.68283	0.04501	22.0
Haberman	0.70280	0.08413	44.4
Bupa	0.49227	0.08630	68.1
Pima	0.64701	0.03876	99.7
Saheart	0.65130	0.07504	98.7
Titanic	0.72058	0.04886	5.9

Tabela 5.5 Função de pertinência com o melhor resultado de acurácia obtido nos folds de cada dataset e a média de regras geradas com o método FRBCS.CHI com *3 termos*

Dataset	Acurácia média (desvio padrão)	Média (regras)	Função
Phoneme	0.71040 (0.01654)	91.9	TRI
Shuttle	0.81103 (0.01642)	64.5	TRA
Abalone	0.40602 (0.04662)	70.1	TRI
Banana	0.65679 (0.01356)	16.9	TRA
Haberman	0.72591 (0.05952)	30.0	TRA
Bupa	0.50731 (0.08037)	72.7	TRA
Pima	0.70188 (0.03697)	195.6	TRA
Saheart	0.58839 (0.06506)	214.0	TRA
Titanic	0.44432 (0.11762)	19.9	TRA

Tabela 5.6 Função de pertinência com o melhor resultado de acurácia obtido nos folds de cada dataset e a média de regras geradas com o método FRBCS.CHI com *5 termos*

Dataset	Acurácia média (desvio padrão)	Média (regras)	Função
Phoneme	0.78405 (0.01830)	507.1	TRA
Shuttle	0.73063 (0.00799)	84.7	TRI
Abalone	0.45104 (0.02314)	206.4	TRI
Banana	0.72811 (0.01653)	40.9	TRA
Haberman	0.71602 (0.07437)	66.6	TRI
Bupa	0.57042 (0.10308)	147.2	TRA
Pima	0.67958 (0.04836)	464.4	TRA
Saheart	0.64477 (0.09146)	240.1	TRI
Titanic	0.64106 (0.12650)	3.0	TRI

Tabela 5.7 Função de pertinência com o melhor resultado de acurácia obtido nos folds de cada dataset e a média de regras geradas com o método FRBCS.CHI com *7 termos*

Dataset	Acurácia média (desvio padrão)	Média (regras)	Função
Phoneme	0.79977 (0.02209)	971.9	TRA
Shuttle	0.83995 (0.00320)	149.0	TRA
Abalone	0.50995 (0.03047)	388.8	TRI
Banana	0.80113 (0.02086)	54.4	TRI
Haberman	0.70957 (0.06998)	88.2	TRI
Bupa	0.57672 (0.06395)	211.8	TRI
Pima	0.66798 (0.03730)	599.8	TRA
Saheart	0.58432 (0.05656)	395.7	TRA
Titanic	0.64106 (0.12650)	3.0	TRI

Tabela 5.8 Função de pertinência com o melhor resultado de acurácia obtido nos folds de cada dataset e a média de regras geradas com o método FRBCS.W com *3 termos*

Dataset	Acurácia média (desvio padrão)	Média (regras)	Função
Phoneme	0.71836 (0.01217)	188.1	TRA
Shuttle	0.84229 (0.00429)	64.5	TRA
Abalone	0.36678 (0.01927)	70.1	TRI
Banana	0.54226 (0.03456)	16.9	TRA
Haberman	0.58237 (0.23861)	30.0	TRA
Bupa	0.56538 (0.07463)	64.5	TRI
Pima	0.54031 (0.06750)	85.6	TRI
Saheart	0.63608 (0.06440)	214.0	TRA
Titanic	0.32302 (0.03595)	2.0	TRI

Tabela 5.9 Função de pertinência com o melhor resultado de acurácia obtido nos folds de cada dataset e a média de regras geradas com o método FRBCS.W com 5 termos

Dataset	Acurácia média (desvio padrão)	Média (regras)	Função
Phoneme	0.73038 (0.01121)	324.7	TRI
Shuttle	0.84346 (0.00426)	105.8	TRA
Abalone	0.36797 (0.01752)	206.4	TRI
Banana	0.58340 (0.01776)	40.9	TRA
Haberman	0.71290 (0.07484)	74.1	TRA
Bupa	0.57092 (0.05299)	147.2	TRI
Pima	0.70569 (0.02926)	464.4	TRA
Saheart	0.65569 (0.05362)	240.1	TRI
Titanic	0.63152 (0.12373)	3.0	TRI

Tabela 5.10 Função de pertinência com o melhor resultado de acurácia obtido nos folds de cada dataset e a média de regras geradas com o método FRBCS.W com 7 termos

Dataset	Acurácia média (desvio padrão)	Média (regras)	Função
Phoneme	0.75241 (0.01188)	971.9	TRA
Shuttle	0.91312 (0.00345)	149.0	TRA
Abalone	0.36869 (0.01833)	529.7	TRA
Banana	0.64792 (0.01421)	67.4	TRA
Haberman	0.72935 (0.07189)	108.0	TRA
Bupa	0.56235 (0.06946)	205.0	TRA
Pima	0.68747 (0.03385)	599.8	TRA
Saheart	0.61892 (0.05711)	395.7	TRA
Titanic	0.63152 (0.12373)	3.0	TRI

Tabela 5.11 Comparação das diferenças dos melhores resultados do GENI-FR 3 termos vs FRBCS.W 3 termos linguísticos

Dataset	Incremento da acurácia (%)	Incremento da média de regras
Phoneme	-7.0885	-159.3
Shuttle	-4.8363	-49.8
Abalone	3.0869	-54.0
Banana	10.0382	-9.0
Haberman	12.0748	-14.0
Bupa	-3.9918	-38.3
Pima	9.2534	-16.0
Saheart	-1.0779	-136.7
Titanic	41.1223	5.9

Tabela 5.12 Comparação das diferenças dos melhores resultados do GEnI-FR 3 *vs* FRBCS.W 5 termos linguísticos

Dataset	Incremento da acurácia (%)	Incremento da média de regras
Phoneme	-8.2905	-295.9
Shuttle	-4.9533	-91.1
Abalone	2.9679	-190.3
Banana	5.9242	-33.0
Haberman	-0.9782	-58.1
Bupa	-4.5458	-121.0
Pima	-7.2846	-394.8
Saheart	-3.0389	-162.8
Titanic	10.2723	4.9

Tabela 5.13 Comparação das diferenças dos melhores resultados do GEnI-FR 3 termos *vs* FRBCS.W 7 termos linguísticos

Dataset	Incremento da acurácia (%)	Incremento da média de regras
Phoneme	-10.4935	-943.1
Shuttle	-11.9193	-134.3
Abalone	2.8959	-513.6
Banana	-0.5278	-59.5
Haberman	-2.6232	-92.0
Bupa	-3.6888	-178.8
Pima	-5.4626	-530.2
Saheart	0.6381	-318.4
Titanic	10.2723	4.9

Tabela 5.14 Comparação das diferenças dos melhores resultados do GEnI-FR 3 termos *vs* FRBCS.CHI 3 termos linguísticos

Dataset	Incremento da acurácia (%)	Incremento da média de regras
Phoneme	-6.2925	-63.1
Shuttle	-1.7103	-49.8
Abalone	-0.8371	-54.0
Banana	-1.4148	-9.0
Haberman	-2.2792	-14.0
Bupa	1.8152	-46.5
Pima	-6.9036	-126.0
Saheart	3.6911	-136.7
Titanic	28.9923	-12.0

Tabela 5.15 Comparação das diferenças dos melhores resultados do GENI-FR 3 termos *vs* FRBCS.CHI 5 termos linguísticos

Dataset	Incremento da acurácia (%)	Incremento da média de regras
Phoneme	-13.6575	-478.3
Shuttle	6.3297	-70.0
Abalone	-5.3391	-190.3
Banana	-8.5468	-33.0
Haberman	-1.2902	-50.6
Bupa	-4.4958	-121.0
Pima	-4.6736	-394.8
Saheart	-1.9469	-162.8
Titanic	9.3183	4.9

Tabela 5.16 Comparação das diferenças dos melhores resultados do GENI-FR 3 termos *vs* FRBCS.CHI 7 termos linguísticos

Dataset	Incremento da acurácia (%)	Incremento da média de regras
Phoneme	-15.2295	-943.1
Shuttle	-4.6023	-134.3
Abalone	-11.2301	-372.7
Banana	-15.8488	-46.5
Haberman	-0.6452	-72.2
Bupa	-5.1258	-185.6
Pima	-3.5136	-530.2
Saheart	4.0981	-318.4
Titanic	9.3183	4.9

modelos, tornando-os mais acessíveis aos utilizadores e facilitando os processos de tomada de decisão.

Foi verificado que em todos os métodos que os modelos que utilizaram 7 termos linguísticos, por mais que obtenham bons resultados de acurácia, prejudicam a interpretabilidade, aumentando as dimensões da base de regras fuzzy. Ainda assim, notou-se que o GEnI-FR consegue ter resultados próximos utilizando 3 ou 5 termos linguísticos e consequentemente com uma base de regras fuzzy com menos dimensões.

Na Tabela 5.17 é apresentado um resumo dos melhores resultados de acurácia (destacados em negrito) e as respectivas médias de quantidade de regras e termos (melhores resultados em itálico) utilizados na obtenção dessas acurácias em cada um dos métodos analisados. É possível verificar, portanto, que o GEnI-FR só obteve o melhor resultado de acurácia em 2 datasets quando comparado com os demais métodos, no entanto, em 7 datasets ele utilizou menos termos e regras do que os demais métodos e com diferenças de acurácia próximas à zero. Esses pontos evidenciam muito a possibilidade de utilização do método para obter resultados similares de acurácia utilizando uma base de regras fuzzy bem menor.

Tabela 5.17 Melhores resultados de acurácia de cada método

	GEnI-FR		FRBCS.W		FRBCS.CHI	
	Acurácia	Termos / Regras	Acurácia	Termos / Regras	Acurácia	Termos / Regras
Phoneme	0.7374	<i>7/70.9</i>	0.7524	<i>7/971.9</i>	0.7998	<i>7/971.9</i>
Shuttle	0.9263	<i>7/29.0</i>	0.9131	<i>7/149.0</i>	0.8399	<i>7/149</i>
Abalone	0.4187	<i>7/31.8</i>	0.3687	<i>7/529.7</i>	0.5099	<i>7/388.8</i>
Banana	0.6828	<i>7/22.0</i>	0.6479	<i>7/67.4</i>	0.8011	<i>7/54.4</i>
Haberman	0.7257	<i>5/32.8</i>	0.7294	<i>7/108.0</i>	0.7259	<i>3/30.0</i>
Bupa	0.5255	<i>3/26.2</i>	0.5709	<i>5/147.2</i>	0.5767	<i>7/211.8</i>
Pima	0.6470	<i>7/99.7</i>	0.7057	<i>5/464.4</i>	0.7019	<i>3/195.6</i>
Saheart	0.6513	<i>7/98.7</i>	0.6557	<i>5/240.1</i>	0.6448	<i>5/240.1</i>
Titanic	0.7342	<i>3/7.9</i>	0.6315	<i>5/3.0</i>	0.6411	<i>5/3.0</i>

Os resultados apresentados e discutidos neste capítulo evidenciam que os ajustes feitos pelo método nas funções de pertinência, baseados nos dados de treinamento, resultaram em uma construção inteligente do formato e da definição do tipo de função de pertinência, definidos com base na aplicação da granularidade justificável que por sua vez considera as características de cobertura e especificidade do conjunto de dados.

CONCLUSÃO

Dado um conjunto de funções de pertinência fuzzy é possível configurar um conjunto de funções de pertinência ajustadas de acordo com parâmetros como granularidade e especificidade que integram o princípio da granularidade justificável e, portanto, refinar os parâmetros das funções de pertinência de forma que as regras geradas sejam compostas por funções que mesclam tipos diferentes (triangular e/ou trapezoidal) melhorando a interpretabilidade do modelo e mantendo a acurácia do sistema.

O método apresentado nesta dissertação, GEnI-FR, oferece ganhos em interpretabilidade de modelos fuzzy gerando SFBRs com menos termos fuzzy e, conseqüentemente, com uma base de regras fuzzy menor. Os resultados demonstram que o método GEnI-FR com 3 termos fuzzy pode alcançar acurácia comparável com modelos conhecidos da literatura com configurações que utilizam mais termos e mais regras. Desse modo, a simplicidade da abordagem proposta incrementa a interpretabilidade dos modelos fuzzy, tornando-os mais acessíveis para os usuários e facilitando processos de tomada de decisão. Essas descobertas mostram o potencial do método na construção de sistemas fuzzy interpretáveis em vários campos, dando espaço para, em trabalhos futuros, ser experimentado em cenários do mundo real.

6.1 AVALIAÇÃO E RESULTADOS OBTIDOS

A partir dos resultados obtidos, constatou-se uma significativa redução no número de regras fuzzy, sem comprometer os níveis de acurácia, ao comparar o método proposto com abordagens existentes. Em resumo, a aplicação do método proposto demonstra ser viável com apenas três termos fuzzy, em contraposição aos métodos tradicionais que requerem a utilização de cinco ou sete termos fuzzy para alcançar níveis significativos de acurácia. Este avanço representa um passo importante na eficiência e simplicidade da modelagem fuzzy, promovendo potenciais benefícios em diversas aplicações práticas.

O principal resultado obtido com o GEnI-FR é a realização de um refinamento nas funções de pertinência que mapeiam um conjunto fuzzy, determinando os tipos e formas ideais conforme o conjunto de dados fornecido como entrada. Este avanço é crucial para

aprimorar a precisão e a eficácia das técnicas de modelagem fuzzy, proporcionando um instrumento mais robusto e adaptável para lidar com diversas situações e domínios de aplicação.

Dado que a interpretabilidade das regras fuzzy está intrinsecamente ligada à representatividade dos termos associados às funções de pertinência em relação aos dados dentro de seu domínio, o aprimoramento dessas funções possibilita conferir um significado semântico mais robusto aos termos fuzzy. Este refinamento é orientado pelos próprios dados do domínio, resultando em uma representação mais precisa e coerente das relações entre as variáveis dos conjuntos de dados em análise.

Autores têm avaliado como índice de interpretabilidade, em geral, o número de regras e a soma do tamanho das regras individualmente (SHANGHOOSHABAD; ABADEH, 2016), além de também considerar a legibilidade da base de regras fuzzy, como na maioria dos trabalhos que tratam de interpretabilidade de SFBR.

Para as validações e comparações dos resultados obtidos com o GENI-FR comparado aos demais métodos descritos no decorrer do trabalho foram consideradas análises no sentido de verificar se o método proposto apresenta mecanismos que impactam no aumento da interpretabilidade, com a redução da quantidade média de regras fuzzy geradas, mantendo os mesmos índices de acurácia dos métodos já conhecidos na literatura. Esses resultados foram revisados e publicados em:

GONCALVES, G. C. B.; RIOS, T. N.. GENI-FR: Granularity to Ensure Interpretability of the Fuzzy Rules. In: 2023 IEEE International Conference on Fuzzy Systems (FUZZ-IEEE). ISSN 1558-4739. DOI: 10.1109/FUZZ52849.2023.10309765.

6.2 TRABALHOS FUTUROS

Com base nos resultados obtidos e na publicação do GENI-FR em uma conferência de grande relevância (GONCALVES; RIOS, 2023), abre-se uma perspectiva promissora para futuras investigações. Recomenda-se avaliar a eficácia e possíveis limitações do método em cenários do mundo real, mediante testes em conjuntos de dados mais complexos. Ademais, é pertinente realizar comparações com abordagens semelhantes da literatura, como os estudos conduzidos por Cao et al. (2021), Razak et al. (2021) e Fu et al. (2019), a fim de posicionar a contribuição do GENI-FR de maneira mais abrangente no contexto científico atual. Este passo adicional permitirá uma compreensão mais profunda do potencial e do alcance do GENI-FR em relação a outras propostas existentes.

REFERÊNCIAS BIBLIOGRÁFICAS

- AGHAEIPOOR, F.; JAVIDI, M. M.; FERNANDEZ, A. Ifc-bd: An interpretable fuzzy classifier for boosting explainable artificial intelligence in big data. *IEEE Transactions on Fuzzy Systems*, v. 30, p. 830–840, 2021. ISSN 1941-0034. Disponível em: <<https://doi.org/10.1109/TFUZZ.2021.3049911>>.
- ALONSO, J. M.; CASTIELLO, C.; MENCAR, C. A bibliometric analysis of the explainable artificial intelligence research field. In: SPRINGER. *International Conference on Information Processing and Management of Uncertainty in Knowledge-Based Systems*. 2018. v. 853, p. 3–15. Disponível em: <https://doi.org/10.1007/978-3-319-91473-2_1>.
- ALONSO, J. M.; PANCHO, D. P.; MAGDALENA, L. Enhancing the fuzzy modeling tool guaje with a new module for frigrams-based analysis of fuzzy rule bases. In: *2012 IEEE International Conference on Fuzzy Systems*. [s.n.], 2012. p. 1–8. ISSN 1098-7584. Disponível em: <<https://doi.org/10.1109/FUZZ-IEEE.2012.6251214>>.
- ALVAREZ-ESTEVEZ, D.; MORET-BONILLO, V. Revisiting the wang-mendel algorithm for fuzzy classification. *Expert Systems*, Wiley Online Library, v. 35, n. 4, p. e12268, 2018. Disponível em: <<https://doi.org/10.1111/exsy.12268>>.
- ARRIETA, A. B. et al. Explainable artificial intelligence (xai): Concepts, taxonomies, opportunities and challenges toward responsible ai. *Information Fusion*, Elsevier, v. 58, p. 82–115, 2020. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S1566253519308103>>.
- CAO, Y. et al. On the interpretability of belief rule-based expert systems. *IEEE Transactions on Fuzzy Systems*, v. 29, n. 11, p. 3489–3503, Nov 2021. ISSN 1941-0034.
- CARVALHO, D. V.; PEREIRA, E. M.; CARDOSO, J. S. Machine learning interpretability: A survey on methods and metrics. *Electronics*, Multidisciplinary Digital Publishing Institute, v. 8, p. 832, 2019. Disponível em: <<https://www.mdpi.com/2079-9292/8/8/832>>.
- CHI, Z.; YAN, H.; PHAM, T. *Fuzzy algorithms: with applications to image processing and pattern recognition*. World Scientific, 1996. Disponível em: <<https://doi.org/10.1142/3132>>.
- DONG, J. et al. Why did the ai make that decision? towards an explainable artificial intelligence (xai) for autonomous driving systems. *Transportation Research Part C: Emerging Technologies*, v. 156, p. 104358, 2023. ISSN 0968-090X. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0968090X23003480>>.

DUTU, L.-C.; MAURIS, G.; BOLON, P. A linear-complexity rule base generation method for fuzzy systems. In: *Proceedings of the 2015 Conference of the International Fuzzy Systems Association and the European Society for Fuzzy Logic and Technology*. Atlantis Press, 2015/06. p. 520–527. ISBN 978-94-62520-77-6. ISSN 1951-6851. Disponível em: <<https://doi.org/10.2991/ifsa-eusflat-15.2015.75>>.

FU, C. et al. Fuzzy granular classification based on the principle of justifiable granularity. *Know.-Based Syst.*, Elsevier Science Publishers B. V., NLD, v. 170, n. C, p. 89–101, apr 2019. ISSN 0950-7051. Disponível em: <<https://doi.org/10.1016/j.knosys.2019.02.001>>.

GONCALVES, G. C. B.; RIOS, T. N. Geni-fr: Granularity to ensure interpretability of the fuzzy rules. In: *2023 IEEE International Conference on Fuzzy Systems (FUZZ)*. [s.n.], 2023. p. 1–6. ISSN 1558-4739. Disponível em: <<https://doi.org/10.1109/FUZZ52849.2023.10309765>>.

GUNNING, D.; AHA, D. W. Darpa’s explainable artificial intelligence program. *AI Magazine*, Association for the Advancement of Artificial Intelligence, v. 40, n. 2, p. 44–58, 2019.

HAMAM, A.; GEORGANAS, N. D. A comparison of mamdani and sugeno fuzzy inference systems for evaluating the quality of experience of haptic-audio-visual applications. In: *2008 IEEE International Workshop on Haptic Audio visual Environments and Games*. [S.l.: s.n.], 2008. p. 87–92.

HASSIJA, V. et al. Interpreting black-box models: a review on explainable artificial intelligence. *Cognitive Computation*, Springer, p. 1–30, 2023.

ISHIBUCHI, H.; NAKASHIMA, T. Effect of rule weights in fuzzy rule-based classification systems. In: *Ninth IEEE International Conference on Fuzzy Systems. FUZZ- IEEE 2000 (Cat. No.00CH37063)*. [S.l.: s.n.], 2000. v. 1, p. 59–64 vol.1. ISSN 1098-7584.

JENA, O.; PANDA, M.; KOSE, U. *Medical Data Analysis and Processing using Explainable Artificial Intelligence*. CRC Press, 2023. (Explainable AI (XAI) for Engineering Applications). ISBN 9781000983654. Disponível em: <<https://books.google.com.br/books?id=iHfXEAAAQBAJ>>.

KABIR, M.; KABIR, M. M. J. Fuzzy membership function design: An adaptive neuro-fuzzy inference system (anfis) based approach. In: . [S.l.: s.n.], 2021. p. 1–5. ISSN 2329-7190.

KLIR, G. J.; YUAN, B. *Fuzzy Sets and Fuzzy Logic: Theory and Applications*. Upper Saddle River, NJ, USA: Prentice-Hall, Inc., 1995. ISBN 0-13-101171-5.

LIU, S. et al. Development of information granules of higher type and their applications to granular models of time series. *Engineering Applications of Artificial Intelligence*, v. 71, p. 60–72, 2018. ISSN 0952-1976. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0952197618300332>>.

MAMDANI, E.; ASSILIAN, S. An experiment in linguistic synthesis with a fuzzy logic controller. *International Journal of Man-Machine Studies*, v. 7, n. 1, p. 1–13, 1975. ISSN 0020-7373. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0020737375800022>>.

MENDEL, J. M.; BONISSONE, P. P. Critical thinking about explainable ai (xai) for rule-based fuzzy systems. *IEEE Transactions on Fuzzy Systems*, p. 1, 7 2021. ISSN 1941-0034.

NOGUEIRA, T. M. Modelagem fuzzy usando agrupamento condicional. In: . [s.n.], 2008. p. 1–101. Disponível em: <<https://repositorio.ufscar.br/handle/ufscar/386>>.

PEDRYCZ, W. *Granular computing: analysis and design of intelligent systems (1st ed)*. [S.l.]: CRC press, 2013. 1-309 p. ISBN 9781138074491.

PEDRYCZ, W. *An Introduction to Computing with Fuzzy Sets: Analysis, Design, and Applications*. Springer, 2020. 1-283 p. ISBN 9783030528003. Disponível em: <<https://www.springer.com/gp/book/9783030527990>>.

PEDRYCZ, W.; GACEK, A.; WANG, X. A hierarchical approach to interpretability of ts rule-based models. *IEEE Transactions on Fuzzy Systems*, p. 1, 8 2021. ISSN 1941-0034.

PEDRYCZ, W.; HOMENDA, W. Building the fundamentals of granular computing: A principle of justifiable granularity. *Applied Soft Computing*, v. 13, n. 10, p. 4209–4218, 2013. ISSN 1568-4946. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S1568494613002068>>.

PEDRYCZ, W.; WANG, X. Designing fuzzy sets with the use of the parametric principle of justifiable granularity. *IEEE Transactions on Fuzzy Systems*, v. 24, p. 489–496, 2016. ISSN 1941-0034. Disponível em: <<https://ieeexplore.ieee.org/document/7152901>>.

RAZAK, T. R. et al. Toward a framework for capturing interpretability of hierarchical fuzzy systems—a participatory design approach. *IEEE Transactions on Fuzzy Systems*, v. 29, n. 5, p. 1160–1172, May 2021. ISSN 1941-0034.

SHANGHOOSHABAD, A. M.; ABADEH, M. S. Robust, interpretable and high quality fuzzy rule discovery using krill herd algorithm. *J. Intell. Fuzzy Syst.*, IOS Press, NLD, v. 30, n. 3, p. 1601–1612, jan 2016. ISSN 1064-1246. Disponível em: <<https://doi.org/10.3233/IFS-151867>>.

SUDKAMP, T. Granularity and specificity in fuzzy rule-based systems. In: *Granular Computing*. [S.l.]: Springer, 2001. p. 257–274.

SUGENO, M. *Industrial Applications of Fuzzy Control*. USA: Elsevier Science Inc., 1985. 213-226 p. ISBN 0444878297. Disponível em: <<https://doi.org/10.1016/j.compind.2010.10.001>>.

TAKAGI, T.; SUGENO, M. Fuzzy identification of systems and its applications to modeling and control. *IEEE Transactions on Systems, Man, and Cybernetics*, SMC-15, n. 1, p. 116–132, Jan 1985. ISSN 2168-2909.

WANG, L. X.; MENDEL, J. M. Generating fuzzy rules by learning from examples. *IEEE Transactions on Systems, Man, and Cybernetics*, v. 22, n. 6, p. 1414–1427, Nov 1992. ISSN 0018-9472.

ZADEH, L. A. Fuzzy sets. *Information and Control*, Academic Press, v. 8, p. 338–353, 6 1965. ISSN 00199958.

ZHU, X.; PEDRYCZ, W.; LI, Z. A development of granular input space in system modeling. *IEEE Transactions on Cybernetics*, v. 51, p. 1639–1650, 2021. ISSN 2168-2275.