

# Aplicando Análise Consensual Fuzzy para Tomada de Decisão na Alocação de Recursos em Nuvem Computacionais

Guilherme Schneider<sup>1</sup>, Bruno Moura<sup>1</sup>, Eduardo Monks<sup>1</sup>,  
Adenauer Yamin<sup>1</sup>, Helida Santos<sup>2</sup>, Renata Reiser<sup>1</sup>

<sup>1</sup>Universidade Federal de Pelotas, Pelotas-RS, Brasil

{gbschneider, bmpdmoura, emmonks, adenauer, reiser}@inf.ufpel.edu.br

<sup>2</sup>Universidade Federal do Rio Grande, Rio Grande-RS, Brasil

{helida}@furg.br

**Abstract.** *This paper explores consensus measures to support to determining the level of use of physical machines in a cloud computing environment. The fuzzy approach considers the uncertainties present in the cloud computing environment and the consensus analysis of the fuzzy sets is based on arithmetic and exponential means. In the proposal evaluation, a case study aimed at the architecture of the Framework Int-FLBCC, which is under development by the research group was designed.*

**Resumo.** *Este artigo contempla a concepção de uma abordagem que explora medidas de consenso fuzzy, como suporte a problemas de tomada de decisão relacionados à determinação do nível de utilização das máquinas físicas em um ambiente de computação em nuvem. A análise de consenso dos conjuntos fuzzy está baseada nas médias aritméticas e exponenciais. Para avaliar a proposta foi concebido um estudo de caso direcionado a arquitetura do Framework Int-FLBCC em desenvolvimento pelo grupo de pesquisa.*

## 1. Introdução

As infraestruturas computacionais geralmente usadas para execução de aplicações na Computação em Nuvem (CN) utilizam recursos como *data centers* que são conhecidos por consumir grande quantidade de energia elétrica, incrementando o custo operacional de provedores, e contribuindo negativamente com o meio ambiente [Gourisaria et al. 2020]. De acordo com o relatório do Conselho de Defesa dos Recursos Naturais NRDC<sup>1</sup> dos EUA, em 2014, somente os *data centers* nos EUA consumiram uma estimativa de 70 bilhões de quilowatts/hora kWh, representando cerca de 1,8% do consumo total de eletricidade dos EUA [Shehabi et al. 2016]. Com base nestes dados, estima-se que somente os *data centers* dos EUA consumiram aproximadamente 73 bilhões de kWh em 2020.

Neste contexto, a demanda por eficiência energética sem perda de desempenho promove a introdução de novos conceitos com especial destaque na CN, reestruturando a distribuição dos serviços de computação (alocação de servidores, armazenamento, banco de dados) em que não há a necessidade do usuário fazer grande investimento em equipamentos, e ainda, com custo/pagamento associado ao tempo de uso [Nathani et al. 2012].

---

<sup>1</sup><https://www.nrdc.org/>

Destacam-se ainda os principais desafios da CN são: (i) provisionamento automático de serviço; (ii) migração de máquinas virtuais (MV); (iii) consolidação de servidores, (iv) gerenciamento de energia, e ainda, (v) segurança de dados [Zhang et al. 2010].

Considerando estes novos cenários e a investigação em trabalhos relacionados na literatura [Moura et al. 2021], este estudo contempla a migração e consolidação de MV com uma abordagem para utilização eficiente dos servidores físicos do ambiente da CN. O objetivo central deste trabalho é a concepção de uma abordagem que explore as premissas e extensões da Lógica Fuzzy (*Fuzzy Logic - FL*), tratando as incertezas dos especialistas na especificação de suas preferências quanto a definição das funções de pertinência, focando nas medidas de consenso de conjuntos fuzzy e assim, contribuindo no suporte à tomada de decisão para a avaliação de cargas em servidores, e a decorrente alocação de MV, considerando o componente *Int-FLBCC* (*Interval Fuzzy Load Balancing for Cloud Computing*) [Moura et al. 2021].

O artigo está estruturado em cinco seções. A Seção 1 trata dos fundamentos contextuais do trabalho. Na Seção 2 apresenta-se os conceitos da Lógica Fuzzy Tipo-2. A Seção 3, expõe a modelagem do componente *Int-FLBCC*, detalhando a base de dados, fuzzificação, base de regras, inferência e defuzzificação. A Seção 4 descreve o método de medidas de consenso entre conjuntos fuzzy concebido para avaliação da modelagem *Int-FLBCC*. E, por fim, na Seção 5, constam as conclusões e trabalhos futuros.

## 2. Lógica Fuzzy

Lotf Zadeh introduziu a Lógica Fuzzy Tipo-2 (*Type-2 Fuzzy Logic - T2FL*) em 1975 como extensão da FL [Mendel et al. 2014]. Seu surgimento está relacionado com a insuficiência da teoria dos Conjuntos Fuzzy (*Fuzzy Sets - FS*) tradicionais na modelagem das incertezas inerentes à definição das funções de pertinência dos antecedentes e consequentes em um Sistema de Inferência Fuzzy (FIS) [Mendel 2003].

Seja o conjunto-universo  $\chi \neq \emptyset$ . Um conjunto fuzzy  $X = \{(u, \mu_X(u)) : \mu_X(u) \in [0, 1], u \in \chi\} \in \mathcal{F}_\chi$  está definido pela função  $\mu_A : \chi \rightarrow [0, 1]$ , determinando o valor fuzzy  $\mu_X(u)$  que indica o grau de pertinência de  $u \in \chi$  em  $X$ . O conjunto de todos os valores fuzzy será indicado por  $\mathcal{F}_\chi$ , onde  $\emptyset, \chi \in \mathcal{F}_\chi$ , sendo  $\mu_\emptyset(u) = 0$  e  $\mu_\chi(u) = 1, \forall u \in \chi$ , respectivamente. Sendo o conjunto de todos os conjuntos fuzzy indicado por  $\mathcal{F}_\chi$ .

Na extensão desta abordagem multi-valorada, considera-se a Lógica Fuzzy Intervalar Tipo-2 (*Interval Type-2 Fuzzy Set Logic - IT2FL*). Particularmente, a semântica considerada provê a interpretação do grau de pertinência intervalar do elemento  $u \in \chi$  em um conjunto fuzzy  $A$ , como um valor no intervalo de pertinência  $\mu_A(x) \subseteq [0, 1]$ . Nesta interpretação, não é possível precisar o valor exato, apenas fornecemos limites (superior e inferior) correspondendo aos extremos do seu intervalo de pertinência.

Esta interpretação se refere a imprecisão dos especialistas para alcançar um consenso quando da atribuição dos graus de pertinência aos múltiplos atributos considerados no sistema modelado. Neste contexto, uma das métricas que avalia a imprecisão nas diferentes atribuições de especialistas está identificada como o diâmetro do correspondente grau intervalar de pertinência.

**Definição 1** [Karnik and Mendel 1998] *Seja  $\chi \neq \emptyset$  um universo. Um T2FS  $A$  é caracterizado por uma Função de Pertinência do Tipo-2 (Membership Function Type-2 - T2MF)*

onde  $0 \leq \mu_{\tilde{A}}(x, u) \leq 1$ ,  $x \in \mathcal{X}$  e  $u \in J_x \subseteq [0, 1]$ . Para cada T2FS  $\tilde{A}$  tem-se

$$\tilde{A} = \{((x, u), \mu_{\tilde{A}}(x, u)) \mid \forall x \in \mathcal{X}, \forall u \in J_x \subseteq [0, 1]\}.$$

Um T2FS atribui a um elemento no universo  $\mathcal{X}$  um mapeamento  $A(x) : [0, 1] \rightarrow [0, 1]$ , e pode ser definido como  $\{(x, A(x, t)) : x \in \mathcal{X}, t \in [0, 1]\}$  quando  $A(x, \cdot) : [0, 1] \rightarrow [0, 1]$  é dado como  $A(x, t) = A(x)(t)$ , para cada  $x \in \mathcal{X}$ ,  $t \in [0, 1]$ . Em particular,  $A(x)$  é um número real em  $[0, 1]$ , para cada  $x \in \mathcal{X}$ . E ainda, se  $\mu_{\tilde{A}}(x) = 1$  então  $A$  é um conjunto fuzzy intervalar  $A(x) = \{(u, 1) : u \in J_x \subseteq [0, 1]\}$ ,  $\forall x \in \mathcal{X}$ . [Mendel et al. 2006]

Observa-se que os conjuntos fuzzy valorados por intervalos [Gehrke et al. 1996] é um caso particular de T2FS. Seja  $A$  um T2FS  $A(x) = [\underline{A}(x), \overline{A}(x)]$ ,  $\forall x \in \mathcal{X}$ . Além disso, sejam  $A, B \in T2FS$ . Para todo  $x \in \mathcal{X}$ , tem-se os operadores:

- (i) Complemento:  $A_C(x) = [1 - \overline{A}(x), 1 - \underline{A}(x)]$ ;
- (ii) União:  $A(x) \cup B(x) = [\max(\underline{A}(x), \underline{B}(x)), \max(\overline{A}(x), \overline{B}(x))]$ ;
- (iii) Intersecção:  $\mu_{A \cap B}(x) = [\min(\underline{A}(x), \underline{B}(x)), \min(\overline{A}(x), \overline{B}(x))]$ .

Denotando,  $A(x) = X$ ,  $B(x) = Y$ ,  $\forall x \in \mathcal{X}$ ,  $U$  como o conjunto de todos os sub-intervalos reais no intervalo unitário  $[0, 1]$  e  $\cup$  como o conjunto dos valores fuzzy intervalares, a ordem " $\leq$ " parcial em  $\cup$  é a *Ordem Produto* [Klement et al. 2004] dada como:  $X \leq Y \Leftrightarrow \underline{X} \leq \underline{Y} \wedge \overline{X} \leq \overline{Y}$ .

As funções que qualificam as intersecções e uniões fuzzy são modeladas neste trabalho por normas e conormas triangulares, respectivamente. Segundo [Mendel et al. 2006] e considerando os intervalos em  $\cup$ , tem-se que:

- Uma norma triangular (t-norma) intervalar é uma função  $\mathbb{T} : \cup^2 \rightarrow \cup$  que satisfaz as propriedades de comutatividade, associatividade, monotonicidade e tem o  $\mathbb{1} \in U$  como elemento neutro. Alguns exemplos de t-normas mais utilizadas são: Intersecção Padrão, Produto Algébrico, Intersecção Drástica, Lukasiewicz e Nilpotente Mínimo.
- Uma conorma triangular (t-conorma) intervalar é uma função binária  $\mathbb{S} : \cup^2 \rightarrow \cup$  que satisfaz as propriedades de comutatividade, associatividade, monotonicidade e tem o  $\mathbb{0} \in U$  como elemento neutro. Alguns exemplos de t-conormas são: União Padrão, Soma Probabilística, União Drástica, Lukasiewicz e Nilpotente Máximo.

Um sistema baseado em T2FL pode estimar funções de entrada e saída, por meio do uso de heurísticas e técnicas intervalares. A seguir, os blocos que constituem um Sistema de Inferência Fuzzy Tipo-2 (*Type-2 Fuzzy Inference System - T2FIS*) são descritos:

**(1) Interface de Fuzzificação:** O processo de fuzzificação baseado em T2FS é realizado de acordo com a natureza e definição de um FST2, associando um valor de entrada com uma função intervalar e não simplesmente com um único valor em  $U$ . Em outras palavras, é inserido no mecanismo de inferência a incerteza relacionada as funções de pertinência de entrada. Assim, para cada entrada  $A(x)$  um vetor de entrada  $\mathbf{x} = (x_1, x_2, \dots, x_n) \in \mathcal{X}^n$  quando  $n \in \mathbb{N}^*$  está relacionado a um par de vetores em  $\cup^n$  obtidos da seguinte forma:

$$(\overline{A}(x_1), \overline{A}(x_2), \dots, \overline{A}(x_n)), (\underline{A}(x_1), \underline{A}(x_2), \dots, \underline{A}(x_n))).$$

**(2) Base de Regras (Rule Base - RB):** constituída por regras que classificam as Variáveis Linguísticas (VL) de acordo com os T2FS valorados por intervalos;

(3) **Unidade de Decisão Lógica:** realiza as operações de inferência entre os dados de entrada e as condições impostas na RB, gerando a ação a ser realizada no T2FIS;

(4) **Defuzzificação:** nesta fase, são consideradas duas principais etapas, que são elas:

- (i) **Redutor de Tipo:** responsável por reduzir T2FS em FS, ao buscar o melhor FS que representa o T2FS deve satisfazer a seguinte premissa: quando toda a incerteza desaparecer, o resultado do T2FIS reduz-se a um FIS [Wu and Nie 2011].
- (ii) **Defuzzificação:** o T2FIS usa a média dos pontos limites  $\underline{y}$  e  $\bar{y}$  da saída  $B(x)$ :

$$y = \frac{\underline{Y} + \bar{Y}}{2} = \frac{B(x) + \bar{B}(x)}{2}, \forall x \in \mathcal{X}, \quad (1)$$

onde os valores  $\underline{y}$  e  $\bar{y}$  são calculados via método iterativo de Karnik e Mendel (algoritmo KM), ou obtido através do uso de um método convencional, como o centroide, no valor final da inferência.

### 3. Int-FLBCC: Modelagem do Sistema Fuzzy Tipo-2

O *Int-FLBCC* é responsável por verificar o Nível de Utilização (U) da máquina física relacionado ao balanceamento de carga na CN, considerando uma RB atuando em três etapas: Fuzzificação, Inferência e Defuzzificação retornando como saída U de cada máquina física do ambiente da CN, a partir do tratamento das variáveis Poder Computacional (PC), Custo de Comunicação (CC) e *Random Access Memory* (RAM).

**Definição das Funções de Pertinência,** transformando as VLs relativas a cada uma das variáveis de incerteza em FST2, através do estudo das variáveis junto a especialistas. Aplica-se a forma trapezoidal na representação gráfica das suas funções de pertinência. Nesta trabalho, a leitura das configurações aplicadas no ambiente de CN simulado é realizada na mensuração dos três atributos PC, CC e RAM. Estes valores são aplicados a uma escala padrão adotada considerando o intervalo [0; 10], veja Tabela 1:

**Tabela 1. Parâmetros da Escala Padrão**

Parâmetro	Descrição
$h_i$	representando o <i>host</i> ( $i$ ) do ambiente da nuvem;
$MM$	Máximo de MIPS disponível no <i>host</i> $i$ considerando todos os <i>Processing Elements</i> (PE);
$UtoB$	representando a utilização de largura de banda do <i>host</i> $i$ ;
$UtoR$	o uso de memória RAM no <i>host</i> $i$ ;
$MaxPC$	valor total em MIPS do melhor <i>host</i> do ambiente da nuvem;
$MinCC$	o menor custo de comunicação no ambiente da nuvem;
$MaxRAM$	o valor de RAM do melhor <i>host</i> .

Na obtenção dos correspondentes graus de pertinência tem-se os parâmetros:

$$PC = (h_i(MM)/MaxPC * 10) \quad (2)$$

$$CC = ((10 * h_i(UtoB))/MinCC) \quad (3)$$

$$RAM = (h_i(UtoR)/MaxRam) * 10 \quad (4)$$

associadas as T2FS das Figuras 1(a), 1(b), 1(c) e 1(d), modelando as respectivas variáveis PC, CC, RAM e U. A seguir, os termos linguísticos (TL) para definição dos FST2:

(i) FST2 da variável PC são os seguintes: “Limitado” (PCL), “Razoável” (PCR) e “Elevado” e considerando (PCE - como melhor caso). Sendo  $PC = a$  e  $a \in [0; 10]$ , obtém-se as FPT2 apresentadas em modo gráfico na Figura 1(a).

- (ii) FST2 da variável CC são: “Pequeno” (CCP - melhor caso), “Médio” (CCM) e “Grande” (CCG). Sendo  $CC = b$  e  $b \in [0; 10]$ , têm-se as FPT2 da Figura 1(b).
- (ii) FST2 da variável RAM são: “Baixo” (RAMB - melhor caso), “Médio” (RAMM) e “Grande” (RAMG). E, para  $RAM = c$  e  $c \in [0; 10]$ , têm-se as FPT2 da Figura 1(c).
- (iii) FST2 da variável U usados nesse caso são: “Baixa” (UB), “Média” (UM) e “Alta” (UA). Sendo  $U = d$  e  $d \in [0; 10]$ . O nível de utilização U das máquinas também é adaptado para escala padrão conforme mostra a Figura 1, de (a) até (d).




Figura 1. PC, CC, RAM e U na escala padrão

No ambiente da CN, a incerteza e imprecisão no nível de uso das máquinas físicas decorre da flutuação do poder computacional, largura de banda e memória disponível no momento da execução das aplicações submetidas pelos usuários. Considera-se um algoritmo online aplicando abordagem da T2FS que percorre as máquinas físicas disponíveis na arquitetura da CN obtendo o nível de uso a cada iteração. Seguem-se as demais etapas: **Fuzzificação**, ocorrendo o mapeamento dos valores de entrada não fuzzy (já ajustados para escala observada) para o domínio fuzzy.

**Base de Regras**, considerando três fatores: (i) as VL nomeiam os FS, tornando a modelagem do sistema mais próxima do mundo real; (ii) são utilizadas conexões lógicas do tipo “AND” para criar a relação entre as variáveis de entrada; (iii) as implicações são do tipo *modus ponens* (modo afirmativo):

Se “ $x_1$  é  $A_1$ ” E “ $x_2$  é  $A_2$ ” E “ $x_3$  é  $A_3$ ” então “ $y$  é  $B$ ”

**Inferência**, modelando as operações entre os FS, combinação dos antecedentes das regras e implicações via o operador *modus ponens generalizado*. Esta fase ocorre em três etapas:

- (i) Aplicação da Operação Fuzzy “AND” através do método MIN (mínimo);
- (ii) Aplicação do Método de Implicação Fuzzy, utilizando o método MIN (mínimo);
- (iii) Aplicação do Método de Agregação Fuzzy, utilizando o método MAX (máximo).

**Defuzzificação** transformação da região resultado da inferência, a técnica utilizada foi o Centro da Área. Esse método calcula o centroide ( $x$ ) da área composta pela saída T2FIS definido pela seguinte fórmula:

$$u = \frac{\sum_{i=1}^N u_i \mu_{OUT}(u_i)}{\sum_{i=1}^N \mu_{OUT}(u_i)}$$

#### 4. Medidas de Consenso

Medidas de consenso são estudadas em contextos de tomada de decisão [Beliakov et al. 2014] como um fator chave em qualquer problema de tomada de decisão em grupo [Tsuchiya and Hiramoto 2018], abordando o uso de agregações [Oliveira et al. 2021]. Em [Beliakov et al. 2014, Definição 3] foi realizado um estudo baseado: (i) na unanimidade, interpretando o consenso completo; (ii) no consenso mínimo, sempre que as entradas se situam em extremos (0 e 1) no intervalo unitário.

**Definição 2** A função  $C : \bigcup_{i=1}^{\infty} [0, 1]^n \rightarrow [0, 1]$  define uma medida de consenso fuzzy (FCM) sempre que as duas seguintes propriedades são satisfeitas:

- (C1)  $x_1 = \dots = x_n \Rightarrow C(x_1, \dots, x_n) = 1, \forall x_1, \dots, x_n \in [0, 1]$  (unanimidade);  
(C2)  $C(0, 1) = C(1, 0) = 0$  (consenso mínimo para  $n = 2$ ).

Seja  $\chi = \{u_1, \dots, u_{100}\}$  e  $x_i = \mu_X(u_i) \in [0, 1], \forall i \in \mathbb{N}_{100}$ , os valores fuzzy  $X$ . Dos resultados apresentados em [Oliveira et al. 2021], definem-se as medidas de consenso, via funções de agregação estendida. No caso, as médias aritmética e exponencial:

$$C_{AM}(X) = \frac{1}{n} \sum_{i=1}^n 1 - |x_{(i)} - x_{(n-i+1)}| \quad \text{and} \quad C_{\exp_{\alpha}}(X) = \frac{1}{\alpha} \ln \sum_{i=1}^n \frac{e^{1-|x_{(i)} - x_{(n-i+1)}|}}{n}.$$

Numa segunda abordagem, para análise de consenso entre dois ou mais conjuntos fuzzy, as propriedades C1 e C2 são estendidas de  $[0, 1]$  para  $\mathcal{F}_{\chi}$ .

**Definição 3** Para  $\chi = \{x_1, \dots, x_m\} \in \mathcal{F}_{\chi}$ , a função  $C : \bigcup_{n=1}^{\infty} (\mathcal{F}_{\chi})^n \rightarrow [0, 1]$  é uma medida de consenso de conjuntos fuzzy ( $\mathcal{L}_{\mathcal{F}_{\chi}}$ -FSCM) em  $\mathcal{F}_{\chi}$  se satisfaz as condições:

- C1:  $C(X, \dots, X) = 1, \forall X \in \mathcal{F}_{\chi}$ ;  
C2:  $C(X_{\chi}, X_{\emptyset}) = C(X_{\emptyset}, X_{\chi}) = 0, \forall u \in \chi$ .

**Proposição 1** Seja  $C : \bigcup_{n=1}^{\infty} [0, 1]^n \rightarrow [0, 1]$  seja um  $\mathcal{L}_{[0,1]}$ -FCM. Função  $C_C : \bigcup_{n=1}^{\infty} (\mathcal{F}_{\chi_m})^n \rightarrow [0, 1]$  na Eq.(5) é uma  $\mathcal{L}_{\mathcal{F}_{\chi}}$ -FSCM:

$$C_C(X_1, \dots, X_n) = \frac{1}{m} \sum_{i=1}^m C(\mu_{X_1}(u_i), \dots, \mu_{X_n}(u_i)). \quad (5)$$

**Definição 4** [Beliakov et al. 2014, Definição 11, 12] Considerando a média aritmética da distância entre os pares, a função  $C_{SK}^d : \bigcup_{i=1}^{\infty} [0, 1]^n \rightarrow [0, 1]$ , é definida pela expressão:

$$C_{SK}^d(x_1, \dots, x_n) = 1 - \frac{2}{n^2} \sum_{\forall i, j | i \neq j}^n d(x_i, x_j); \quad (6)$$

é uma medida de consenso que satisfaz a monotonicidade em relação a maioria, e  $\mathcal{L}_{[0,1]}$ -RDF definida por  $d : [0, 1]^2 \rightarrow [0, 1]$ , onde  $d(x, y) = (x - y)^2$ .

**Definição 5** A função  $C_{Tastle} : \bigcup_{i=1}^{\infty} [0, 1]^n \rightarrow [0, 1]$  dada por

$$C_{Tastle}(x_1, \dots, x_n) = 1 + \frac{1}{n} \sum_{i=1}^n \log_2(1 - |x_i - \bar{x}|) \quad (7)$$

define uma medida de consenso relacionada à média aritmética sobre o operador logaritmo aplicada à diferença entre 1 e a  $\mathcal{L}_{[0,1]}$ -RDF  $d : [0, 1]^2 \rightarrow [0, 1]$  definida como  $d(x, y) = |x - y|$ . Ambos os operadores  $C_{SK}^d$  e  $C_{Tastle}$  verificam [Beliakov et al. 2014, Definição 11] em relação a  $\mathcal{L}_{[0,1]}$ -RDF  $d$ .


Cada método de consenso  $C_M$  é executado sobre os dados relativos a VL (B, M, A) relacionadas aos conjuntos fuzzy de  $PC$ ,  $CC$  e  $RAM$ , incluindo também  $U$ , a variável de saída. Usamos  $\alpha = 1$  e  $n = 100$  para realizar a análise de consenso fuzzy.

Os resultados para a análise do caso pontual são apresentados na Tabela 2 e Figura 2. Na função  $C_{AM}$  o menor valor de consenso foi de 0.5000, e o maior 0.9938. Já na avaliação da função  $C_{exp_\alpha}$  o menor valor foi 0.5560, e maior 0.9938. No caso da função  $C_{SK}$  o menor valor de consenso foi de 0.3060, e o maior 0.6020. E por último, na execução de  $C_{Tastle}$  0.2375 e 0.4988, o menor e o maior valor respectivamente.

Os melhores resultados foram atingidos com a aplicação da função  $C_{AM}$  e  $C_{exp_\alpha}$  na avaliação das funções de pertinência que definem os termos linguísticos médios em todas as variáveis.

**Tabela 2. Resultado Numérico**

$X$	$C_{AM}$	$C_{exp}$	$C_{SK}$	$C_{Tastle}$
$PC_L$	0.6600	0.7245	0.6020	0.4988
$PC_M$	0.9800	0.9803	0.3060	0.2519
$PC_H$	0.5100	0.5956	0.3061	0.2375
$RAM_L$	0.6351	0.7070	0.5533	0.4530
$RAM_M$	0.9938	0.9938	0.5533	0.2837
$RAM_H$	0.5900	0.6717	0.4811	0.3874
$CC_L$	0.6351	0.7070	0.5533	0.4530
$CC_M$	0.9938	0.9938	0.3457	0.2837
$CC_H$	0.5900	0.6717	0.4811	0.3874
$U_L$	0.5200	0.5755	0.5435	0.4425
$U_M$	0.9800	0.9801	0.4940	0.4114
$U_H$	0.5000	0.5560	0.5533	0.4530



**Figura 2. Resultados Gráfico**

## 5. Conclusão

Neste artigo foi desenvolvida uma proposta de avaliação do grau de consenso para apoio à decisão na determinação do nível de utilização de máquinas físicas da CN. A análise de consenso fuzzy foi desenvolvida sobre os dados relativos aos conjuntos fuzzy referentes ao PC, CC, RAM e U. Foi investigado o problema de mensuração do grau de consenso, não apenas comparando valores fuzzy, mas de forma mais abrangente se reportando aos conjuntos fuzzy associados aos atributos do sistema de inferência.

O objetivo central foi validar a decisão de consenso para a tomada de decisão dentre a opinião de vários especialistas, considerando diferentes critérios, e dando enfoque nesta fase do trabalho para análise através das funções de pertinência tipo-1.

Os resultados obtidos mostraram bons níveis de consenso na modelagem do projeto de *Int-FLBCC*, provendo maior confiabilidade para o tratamento das incertezas presente no ambiente da CN.

Como trabalhos futuros pretende-se aplicar os métodos  $C_{AM}$ ,  $C_{exp_\alpha}$ ,  $C_{SK}$  e  $C_{Tastle}$  para análise do consenso, levando em consideração a modelagem do projeto por funções de pertinência tipo-2, e ainda, empregando métodos de penalidade [Elkano et al. 2018], visando ampliar a avaliação tanto na precisão quanto da incerteza presente no ambiente.

## Referências

- Beliakov, G., Calvo, T., and James, S. (2014). Consensus measures constructed from aggregation functions and fuzzy implications. *Knowl.-Based Syst.*, 55:1–8.
- Elkano, M., Galar, M., Sanz, J. A., Schiavo, P. F., Pereira Jr, S., Dimuro, G. P., Borges, E. N., and Bustince, H. (2018). Consensus via penalty functions for decision making in ensembles in fuzzy rule-based classification systems. *Appl. Soft Comput.*, 67:728–740.
- Gehrke, M., Walker, C., and Walker, E. (1996). Some comments on interval valued fuzzy sets. *Int. Journal of Intelligent Systems*, 11(10):751–759.
- Gourisaria, M. K., Samanta, A., Saha, A., Patra, S. S., and Khilar, P. M. (2020). An extensive review on cloud computing. In *Data Engineering and Communication Technology*, pages 53–78.
- Karnik, N. N. and Mendel, J. M. (1998). Introduction to type-2 fuzzy logic systems. In *1998 IEEE Int. Conf. on Fuzzy Systems Proc.*, volume 2, pages 915–920 vol.2.
- Klement, E., Mesiar, R., and Pap, E. (2004). Triangular norms. position paper I: basic analytical and algebraic properties. *Fuzzy Sets and Systems*, 143(1):5–26.
- Mendel, J., Hagaras, H., Tan, W.-W., Melek, W. W., and Ying, H. (2014). *Introduction to type-2 fuzzy logic control: theory and applications*. John Wiley & Sons.
- Mendel, J. M. (2003). Fuzzy sets for words: a new beginning. In *Fuzzy Systems, 2003. FUZZ '03. The 12th IEEE Int. Conf. on*, volume 1, pages 37–42.
- Mendel, J. M., John, R. I., and Liu, F. (2006). Interval type-2 fuzzy logic systems made simple. *IEEE Trans. Fuzzy Systems*, 14(6):808–821.
- Moura, B. M., Schneider, G. B., Yamin, A. C., Santos, H., Reiser, R. H., and Bedregal, B. (2021). Interval-valued fuzzy logic approach for overloaded hosts in consolidation of virtual machines in cloud computing. *Fuzzy Sets and Systems*.
- Nathani, A., Chaudhary, S., and Somani, G. (2012). Policy based resource allocation in iaas cloud. *Future Generation Computer Systems*, 28(1):94–103.
- Oliveira, L., De Moura, R. C., Schneider, G. B., Pilla, M. L., Yamin, A. C., Reiser, R. H. S., and Bedregal, B. R. C. (2021). Toward a fuzzy logic-based consensus analysis in hybrid memory management. In *2021 IEEE Int. Conf. on Fuzzy Systems (FUZZ-IEEE)*, pages 1–6.
- Shehabi, A., Smith, S., Sartor, D., Brown, R., Herrlin, M., Koomey, J., Masanet, E., Horner, N., Azevedo, I., and Lintner, W. (2016). United states data center energy usage report.
- Tsuchiya, Y. and Hiramoto, N. (2018). Measuring consensus and dissensus: A generalized index of disagreement using conditional probability. *Inf. Sci.*, 439-440:50–60.
- Wu, D. and Nie, M. (2011). Comparison and practical implementation of type-reduction algorithms for type-2 fuzzy sets and systems. In *FUZZ-IEEE*, pages 2131–2138. IEEE.
- Zhang, Q., Cheng, L., and Boutaba, R. (2010). Cloud computing: state-of-the-art and research challenges. *Journal of Internet Services and Applications*, 1(1):7–18.