

Hybrid-FLBCC: Integrando Aprendizado de Máquina e Lógica Fuzzy para Consolidação de Servidores em Nuvem

Rafael R. Bastos¹, Bruno M. P. Moura⁴, Giancarlo Lucca²,
Helida S. Santos³, Adenauer C. Yamin¹, Renata H. R. Reiser¹

¹ Centro de Desenvolvimento Tecnológico – Universidade Federal de Pelotas (UFPel)
Pelotas - RS - Brasil

{rrbastos, adenauer, reiser}@inf.ufpel.edu.br

²PGEEC - Universidade Católica de Pelotas (UCPEL), Pelotas - RS - Brasil

giancarlo.lucca@ucpel.edu.br

³C3 - Universidade Federal do Rio Grande (FURG), Rio Grande - RS - Brasil

helida@furg.br

⁴Diretoria de Tecnologia de Informação e Comunicação (DTIC)
Universidade Federal do Pampa (UNIPAMPA) - Bagé-RS - Brasil

brunomoura@unipampa.edu.br

Abstract. *The Hybrid-FLBCC approach proposes a fuzzy model integrated with Machine Learning algorithms, enabling dynamic variable selection and automatic generation of basic rules to predict optimal Virtual Machine migrations. As an extension of Int-FLBCC, it adopts the concept of Flexible Computing to enhance server consolidation in Cloud Computing environments, focusing on refining the inference process regarding Physical Machine utilization levels. The variable selection identifies the most relevant attributes for consolidation, guiding the definition of decision-making criteria. This refinement produces more interpretable fuzzy rule sets, simplifies system implementation, and contributes to reducing computational resource usage. The results demonstrate the potential of hybrid approaches for intelligent decision-making in cloud infrastructures.*

Resumo. *A abordagem Hybrid-FLBCC propõe um modelo fuzzy integrado a algoritmos de Aprendizado de Máquina, permitindo a seleção dinâmica de variáveis e a geração automática de regras básicas para prever migrações ideais de Máquinas Virtuais. Como extensão da Int-FLBCC, adota o conceito de Computação Flexível para aprimorar a consolidação de servidores em ambientes de Computação em Nuvem, com foco no refinamento do processo de inferência sobre os níveis de utilização de Máquinas Físicas. A seleção de variáveis identifica atributos mais relevantes para a consolidação, orientando a definição de critérios decisórios. Esse aprimoramento gera regras fuzzy mais interpretáveis, simplifica a implementação do sistema e contribui para a redução do consumo de recursos computacionais. Os resultados demonstram o potencial de abordagens híbridas na tomada de decisões inteligentes em infraestruturas em nuvem.*

1. Introdução

A Computação em Nuvem (CN) permite a alocação dinâmica de recursos, viabilizando ambientes de alto desempenho com custos ajustados à demanda [Gourisaria et al. 2020,

Nathani et al. 2012]. No entanto, essa flexibilidade implica em elevado consumo energético. Segundo a Agência Internacional de Energia (IEA)¹, *data centers* consumiram cerca de 460 TWh em 2022, podendo ultrapassar 1000 TWh até 2026, valor próximo ao consumo do Japão.

Nesse contexto, a otimização energética torna-se uma prioridade. Estratégias como o balanceamento de carga têm sido adotadas para maximizar a utilização de recursos físicos [Choudhary et al. 2024], sendo a consolidação de servidores uma das mais relevantes. Essa estratégia envolve a detecção de Máquinas Físicas (*hosts*) sobrecarregadas ou subutilizadas, seleção e migração de Máquinas Virtuais (MV) e realocação eficiente de recursos [Rjeib and Kecskemeti 2024, Banerjee et al. 2024, He and Buyya 2023].

A Lógica Fuzzy (LF), especialmente a Lógica Fuzzy Valorada Intervalarmente (IvFL) [Sambuc 1975], tem se destacado no apoio à tomada de decisão sob incerteza e imprecisão, sendo amplamente aplicada em sistemas de controle da Computação Flexível [Zadeh 1965]. Os Sistemas de Classificação Baseados em Regras Fuzzy (FRBCS) [Ishibuchi et al. 2005] aprendem padrões a partir dos dados, oferecendo interpretabilidade e reduzindo a necessidade de regras manuais.

O objetivo deste trabalho é propor e avaliar uma abordagem que combina IvFL com algoritmos de Aprendizado de Máquina (AM), com base em estudos prévios [Bastos et al. 2024] e simulações realizadas no CloudSim [Calheiros et al. 2010], para aprimorar a seleção de variáveis na migração de MV.

A abordagem Int-FLBCC [Moura et al. 2022] foi expandida, originando a proposta Hybrid Fuzzy Load Balancing for Cloud Computing (Hybrid-FLBCC), que integra seleção inteligente de variáveis e geração de regras fuzzy para melhorar a consolidação de servidores. As principais contribuições incluem:

- Emprego de algoritmos de AM para seleção de variáveis, possibilitando a análise de cenários complexos de classificação;
- Aplicação de IvFL para decisões mais confiáveis em contextos marcados por incertezas na identificação de sobrecarga ou subutilização de *hosts*.

A proposta viabiliza a migração de MV com base na seleção de atributos mais relevantes. Testamos novas políticas de seleção com o objetivo de refinar os modelos de inferência fuzzy e promover eficiência energética. Além disso, foram incorporadas métricas específicas para uma análise de desempenho mais precisa, consolidando a Hybrid-FLBCC como uma abordagem voltada à utilização eficiente dos recursos computacionais.

Este artigo está estruturado da seguinte forma: a Seção 2 apresenta os fundamentos conceituais de AM e dos FRBCS; a dinâmica de seleção de variáveis é descrita na Seção 3; os resultados preliminares são apresentados na Seção 4; e, por fim, a Seção 5 traz as conclusões.

2. Preliminares

Esta seção apresenta os fundamentos teóricos do trabalho, começando pelos algoritmos de AM e logo após introduzindo os FRBCS.

¹<https://www.iea.org/reports/electricity-2024>

2.1. Aprendizado de Máquina

O AM permite que sistemas aprendam automaticamente a partir de dados, ajustando-se e melhorando seu desempenho com o tempo, sem a necessidade de regras explícitas [Géron 2019, Faceli et al. 2021]. Essa abordagem é eficaz em tarefas complexas, nas quais a definição manual de regras seria inviável.

O processo envolve o uso de dados de treinamento para identificar padrões e construir modelos matemáticos capazes de realizar previsões com novos dados [Raschka 2020]. Neste estudo, utilizamos os seguintes algoritmos de AM para a seleção de variáveis, também adotado em [Souza 2024]:

- (i) **Logistic Regression** [Raschka 2020]: Classificador simples e eficiente para dados linearmente separáveis; utiliza função logística e requer exclusão de atributos irrelevantes.
- (ii) **Random Forest** [Raschka 2020]: Técnica de *ensemble* baseada em múltiplas árvores de decisão; robusta e com boa capacidade de generalização.
- (iii) **Multilayer Perceptron** [Géron 2019]: Rede neural com múltiplas camadas, capaz de modelar funções complexas; treinada via *backpropagation*.
- (iv) **Linear Discriminant Analysis** [Géron 2019]: Método linear que reduz dimensionalidade e maximiza a separação entre classes; indicado para problemas multiclasse.
- (v) **eXtreme Gradient Boosting** [Raschka 2020]: Implementação eficiente do *Gradient Boosting*, com paralelismo e otimização do espaço de busca.

2.2. Sistemas de Classificação Baseados em Regras Fuzzy

Os FRBCS são amplamente reconhecidos pela capacidade de lidar com incertezas e oferecer modelos interpretáveis com alta precisão [Ishibuchi et al. 2005, Lucca et al. 2018, Sanz et al. 2021]. São compostos por: (i) Base de Conhecimento, com regras e base de dados adaptadas ao problema; e (ii) Método de Raciocínio Fuzzy, responsável pela atribuição de classes com base em lógica fuzzy [Cordón et al. 1998].

Neste trabalho, foram empregados os seguintes FRBCS, amplamente aceitos na área de Computação Flexível [Sanz et al. 2013]:

- (i) **FARC-HD** [Alcalá-Fdez et al. 2011]: Modelo eficiente para alta dimensionalidade, com uso de seleção genética de regras e ajuste de parâmetros.
- (ii) **Chi et al. algorithm** [Chi et al. 1996]: Estabelece regras fuzzy com base em partições linguísticas e pertinência das instâncias.
- (iii) **FURIA** [Hühn and Hüllermeier 2009]: Gera regras fuzzy não ordenadas, modelando fronteiras de decisão mais flexíveis.
- (iv) **IVTURS** [Sanz et al. 2013]: Extensão do FARC-HD com raciocínio fuzzy intervalar, seleção evolutiva de regras e maior capacidade de adaptação à incerteza dos dados.

3. Dinâmica de Seleção de Variáveis proposta para a Hybrid-FLBCC

Esta seção apresenta a seleção de variáveis e a avaliação do desempenho para diferentes combinações da Política de Alocação (AP) com Políticas de Seleção (SP) de MV, com foco na consolidação dinâmica e eficiência energética em *data centers* em nuvem.

A avaliação de estratégias em ambientes de CN requer ferramentas de simulação eficazes. Neste estudo, utilizamos o *framework* CloudSim, amplamente reconhecido na literatura por sua estrutura modular voltada à análise de políticas e algoritmos em CN [Calheiros et al. 2010, Arshad et al. 2022].

A seleção de variáveis contribui para a redução do tempo computacional, melhora o desempenho preditivo e favorece a interpretação dos dados [Chandrashekar and Sahin 2014]. Neste trabalho, a seleção de variáveis foi realizada com base em dados provenientes de simulações no CloudSim.

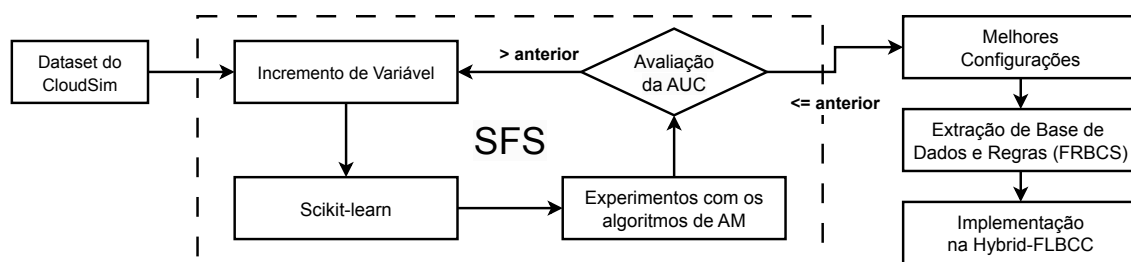
Considerando a natureza dinâmica das cargas de trabalho, limiares fixos de utilização tornam-se inadequados. Assim, adotou-se a política de alocação **Inter Quartile Range (IQR)**, que utiliza o segundo e terceiro quartis para representar a dispersão central dos dados. As PS utilizadas foram: **Maximum Correlation (MC)**, **Minimum Migration Time (MMT)**, **Minimum Utilization (MU)** e **Random Selection (RS)**.

Os dados experimentais foram obtidos em simulações de 24 horas com coletas a cada 300 segundos, utilizando traços reais do PlanetLab². Cada registro contém métricas como uso de CPU, memória, largura de banda, armazenamento, energia e MIPS. Foram geradas 80 mil instâncias, com média de 20 mil por cenário ($PA \times PS$), rotuladas em três classes de utilização do *host*: subutilizado, regular ou sobrecarregado [Bastos et al. 2024].

A técnica Sequential Forward Selection (SFS) foi implementada em Python com a biblioteca Scikit-learn³, utilizando os algoritmos de AM descritos na Seção 2.1.

O processo de seleção inicia-se com a preparação do *dataset* contendo os registros extraídos do ambiente de simulação. Na primeira iteração, cada variável é avaliada isoladamente, e aquela com melhor desempenho de classificação é selecionada. Nas iterações seguintes, combinações com as variáveis já escolhidas são testadas, sendo mantidas aquelas que melhoram o desempenho. O procedimento se repete enquanto houver ganho na classificação. A Figura 1 ilustra esse processo.

Figura 1. Fluxo do Processo de Seleção de Variáveis.



Como métrica de avaliação, utilizou-se a Área sob a Curva ROC (AUC), por sua capacidade de mensurar o desempenho preditivo em diferentes limiares de decisão [Bradley 1997, Bastos et al. 2024].

Para os subconjuntos de variáveis com melhor desempenho em cada combinação $PA \times PS$, foram conduzidos novos experimentos com FRBCS. Os resultados obtidos sub-

²<https://planetlab.cs.princeton.edu>

³<https://scikit-learn.org/>

sidiarão a definição das funções de pertinência e da Base de Regras na Hybrid-FLBCC.

Para garantir robustez, adotamos validação cruzada com 10 subconjuntos, nos quais, a cada rodada, um grupo era usado para teste e os demais para treinamento. A AUC foi calculada em cada repetição e reportada a média final. Os resultados foram comparados à configuração da abordagem Int-FLBCC, que considera apenas as variáveis “CPU”, “memória” e “largura de banda”.

A proposta contribui para ampliar a adaptabilidade do sistema, permitindo uma seleção de variáveis sensível ao contexto e decisões mais informadas diante de padrões complexos e incertezas inerentes aos ambientes em nuvem.

4. Resultados Preliminares

Os experimentos realizados contribuíram para avaliar a capacidade do sistema em capturar relações complexas, adaptar-se a diferentes contextos, identificar padrões sutis e mitigar incertezas, promovendo decisões mais precisas e resilientes.

Diferentemente da Int-FLBCC que considerou apenas o cenário $IQR \times RS$, a Hybrid-FLBCC ampliou a análise para múltiplas Políticas de Seleção e adotou uma abordagem dinâmica de seleção de variáveis. Os resultados indicaram que a composição ideal de atributos variou conforme o cenário e o algoritmo de AM utilizado. Em diversos casos, o número de variáveis superou o conjunto fixo da Int-FLBCC, refletindo maior especificidade e complexidade na modelagem.

A comparação entre os algoritmos evidenciou diferenças expressivas de desempenho. Os métodos *eXtreme Gradient Boosting* e *Random Forest* obtiveram os maiores valores médios de AUC, com resultados consistentes, destacando-se em relação aos demais. De modo geral, os cenários com variáveis selecionadas superaram os obtidos com a configuração da Int-FLBCC, demonstrando ganho em desempenho classificatório.

4.1. Análise dos Resultados

A análise baseia-se nos valores médios de AUC para cada algoritmo, considerando os atributos “bw” (largura de banda), “cpu”, “energy”, “mips”, “ram” e “storage”. A Tabela 1 apresenta os resultados para a política de alocação IQR combinada com as PS: MC, MMT, MU e RS, integrando os cinco algoritmos de AM descritos na Seção 2.1. Para cada combinação, são reportados o desempenho de AUC, o desvio padrão e a comparação com a configuração da Int-FLBCC. Os melhores resultados estão destacados.

Em todos os cenários, os algoritmos apresentaram desempenho superior com variáveis selecionadas em comparação à configuração fixa da Int-FLBCC. Isso evidencia o potencial da abordagem proposta para adaptação a diferentes contextos operacionais.

O algoritmo *eXtreme Gradient Boosting* obteve os melhores resultados na maioria das combinações, exceto em $IQR \times MMT$, em que o *Random Forest* se destacou. As variações observadas entre os valores de AUC (de 0.0014 a 0.0615) reforçam a sensibilidade dos algoritmos às configurações de entrada.

A técnica SFS proporcionou ganhos graduais de desempenho a cada incremento de variável e, em vários cenários, o número de variáveis selecionadas superou a configuração original, ajustando-se melhor a cada contexto.

Tabela 1. Resultados da Seleção de Variáveis para a Política de Alocação IQR

PS	Algoritmo de AM	Hybrid-FLBCC								Int-FLBCC	
		Variáveis						AUC	stddev	AUC	stddev
MC	Logistic Regression	cpu	bw	mips	energy	-	-	0.8796	0.0208	0.8475	0.0165
	Random Forest	cpu	mips	energy	-	-	-	0.9952	0.0018	0.9694	0.0215
	Multilayer Perceptron	mem	cpu	-	-	-	-	0.9911	0.0052	0.9791	0.0071
	Linear Discriminant Analysis	mem	cpu	bw	mips	energy	-	0.9768	0.0078	0.9736	0.0080
	eXtreme Gradient Boosting	cpu	storage	energy	-	-	-	0.9960	0.0031	0.9843	0.0108
MMT	Logistic Regression	cpu	bw	mips	energy	-	-	0.8729	0.0147	0.8469	0.0135
	Random Forest	mem	cpu	energy	-	-	-	0.9957	0.0014	0.9674	0.0214
	Multilayer Perceptron	cpu	storage	mips	energy	-	-	0.9876	0.0059	0.9758	0.0048
	Linear Discriminant Analysis	mem	cpu	bw	energy	-	-	0.9767	0.0022	0.9753	0.0017
	eXtreme Gradient Boosting	cpu	mips	energy	-	-	-	0.9947	0.0033	0.9799	0.0087
MU	Logistic Regression	cpu	bw	mips	energy	-	-	0.8922	0.0147	0.8307	0.0131
	Random Forest	cpu	mips	energy	-	-	-	0.9972	0.0014	0.9699	0.0157
	Multilayer Perceptron	mem	cpu	energy	-	-	-	0.9890	0.0059	0.9741	0.0046
	Linear Discriminant Analysis	cpu	bw	energy	-	-	-	0.9688	0.0022	0.9623	0.0086
	eXtreme Gradient Boosting	cpu	storage	energy	-	-	-	0.9982	0.0033	0.9865	0.0012
RS	Logistic Regression	cpu	bw	mips	energy	-	-	0.8684	0.0127	0.8478	0.0135
	Random Forest	mem	cpu	storage	energy	-	-	0.9958	0.0033	0.9805	0.0160
	Multilayer Perceptron	mem	cpu	storage	energy	-	-	0.9917	0.0031	0.9810	0.0043
	Linear Discriminant Analysis	mem	cpu	bw	energy	-	-	0.9768	0.0027	0.9715	0.0068
	eXtreme Gradient Boosting	mem	cpu	energy	-	-	-	0.9979	0.0024	0.9867	0.0012

4.2. Extração da Base de Dados e Geração de Regras

Os melhores conjuntos de variáveis identificados na Seção 4.1 foram utilizados para extrair a Base de Dados e gerar regras fuzzy, fundamentais para a implementação do sistema Hybrid-FLBCC. Nesta etapa, foram empregados os FRBCSs: FARC-HD, Chi, FURIA e IVTURS, conforme definidos na Seção 2.2.

A partir das variáveis selecionadas, os dados foram organizados e importados na ferramenta KEEL [Triguero et al. 2017] como problema de classificação. Embora os resultados ainda não sejam conclusivos, fornecem uma visão inicial do comportamento dos FRBCSs e de seu potencial de aplicação.

As Bases de Regras geradas variaram substancialmente em complexidade. O FURIA produziu o maior número de regras, indicando maior detalhamento, porém com implicações em termos de custo computacional. Já o IVTURS adotou uma abordagem mais econômica, evidenciando o *trade-off* entre complexidade e eficiência. Exemplos de regras geradas são apresentados a seguir. Essas regras seguem o seguinte formato:

Rule R_j : If x_1 is $A_{\{j1\}}$ and . . . and x_n is $A_{\{jn\}}$ then
Class = C_i with RW_i

onde R_j é o rótulo da $j_{ésima}$ regra, $x = (x_1, \dots, x_n)$ é um vetor de atributos n -dimensional, A_{ji} é um conjunto fuzzy antecedente que representa um termo linguístico $i_{ésimo}$, C_j é o rótulo da classe, e RW_j é o peso da regra ou, em alguns casos, CF é o valor de confiança ou Fator de Certeza.

[i] Exemplo de regras geradas pelo FARC-HD

```
bw IS L_0(3): normal CF: 1.0
cpu IS L_1(3) AND mem IS L_1(3) AND storage IS L_1(3): under
CF: 0.5347
```

[ii] Exemplo de regras geradas pelo Chi

```
cpu IS L_0 AND mem IS L_0 AND bw IS L_0 AND storage IS
L_0: normal with Rule Weight: 1.0
cpu IS L_1 AND mem IS L_2 AND bw IS L_2 AND storage IS
L_normal with Rule Weight: 0.5910
```

[iii] Exemplo de regras geradas pelo FURIA

```
(cpu >= 0.1637(-> 0.1599)) and (cpu <= 0.1637(-> 0.1637)) =>
class=normal (CF = 1.0)
(cpu >= 0.0021(-> 0)) and (storage <= 0.0025(-> 0.0050)) and
(energy <= 0(-> 253.732)) => class=under (CF = 0.99)
```

[iv] Exemplo de regras geradas pelo IVTURS

```
bw IS L_0(3): normal CF: [1.0, 1.0]
energy IS L_0(3) AND storage IS L_0(3) AND bw IS L_2(3): under
CF: [0.4182, 0.4238]
```

O FURIA apresentou a maior acurácia, mas, por ser um sistema fuzzy tipo-1, não captura adequadamente os níveis de incerteza típicos da CN. O IVTURS, por sua vez, baseado em fuzzy tipo-2, é mais adequado para esse contexto. Portanto, será considerada a integração das vantagens de desempenho do FURIA com a modelagem de imprecisão do IVTURS.

Quanto à extração da Base de Dados, FARC-HD, Chi e IVTURS oferecem pontos definidos para funções de pertinência. Já o FURIA requer tratamento adicional, pois não utiliza variáveis linguísticas.

4.3. Hybrid-FLBCC: Hybrid Fuzzy Load Balancing for Cloud Computing

A partir dos resultados obtidos com a seleção de variáveis, propõe-se a Hybrid-FLBCC, uma extensão da Int-FLBCC adaptada a diferentes combinações de Políticas de Alocação e de Seleção de MV. A proposta introduz novas configurações para as variáveis do sistema fuzzy e define bases de regras específicas para cada cenário, com o objetivo de aprimorar a classificação do nível de utilização de *hosts* na consolidação de MV.

A Figura 2 apresenta a arquitetura da Hybrid-FLBCC. Diferentemente da abordagem original, que emprega apenas as variáveis “cpu”, “mem” e “bw”, a nova proposta permite a seleção dinâmica de variáveis, com base nas políticas AP×SP adotadas. Seguindo o mesmo princípio, para cada cenário são considerados conjuntos específicos de funções de pertinência e regras fuzzy, gerando um sistema mais adaptável e eficaz.

A definição de novas bases de regras e funções de pertinência fundamenta-se no conhecimento extraído dos FRBCS. Os resultados experimentais demonstraram que o FURIA apresentou o melhor desempenho em todos os cenários avaliados. No entanto, por ser baseado em Lógica Fuzzy do Tipo-1, sua capacidade de representar incertezas é limitada. Por outro lado, o IVTURS, ao empregar IvFL, é mais adequado à modelagem de imprecisões inerentes ao ambiente de CN. Dessa forma, busca-se conciliar o desempenho do FURIA com a robustez do IVTURS, revisando suas configurações para integrar precisão e capacidade de representação da incerteza no sistema proposto.

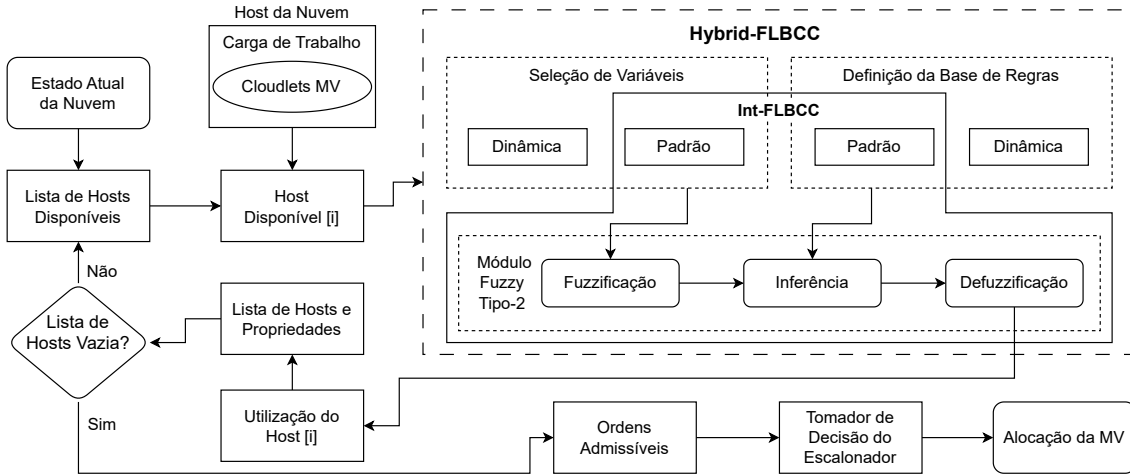


Figura 2. Visão geral da Hybrid-FLBCC estendendo a abordagem Int-FLBCC.

5. Conclusão

A seleção de variáveis, ao identificar os atributos mais relevantes para a consolidação de servidores, reforça a Hybrid-FLBCC como uma evolução da Int-FLBCC, incorporando técnicas de Inteligência Computacional.

Este trabalho buscou otimizar configurações de variáveis para diferentes combinações de políticas de alocação e seleção de MV, simuladas no CloudSim. Essa abordagem aprimorou as funções de pertinência, os conjuntos de regras, a interpretabilidade e o desempenho classificatório, além de indicar potencial redução no custo computacional.

Em todos os cenários analisados, a configuração da Hybrid-FLBCC superou a da Int-FLBCC, demonstrando maior capacidade de adaptação e refinamento do sistema fuzzy frente a contextos dinâmicos em ambientes de nuvem.

A definição de novas bases de regras e funções de pertinência, com base no conhecimento extraído dos FRBCS, mostrou-se eficaz para tornar o sistema mais preciso e eficiente, empregando variáveis selecionadas por uma metodologia reconhecida na literatura.

Os resultados preliminares indicam ganhos significativos em eficiência energética. No cenário $IQR \times MMT$, com 800 *hosts* e 1033 MV, a Hybrid-FLBCC reduziu em até 46% o consumo de energia em relação à configuração anterior, evidenciando seu potencial como solução mais eficaz para a consolidação de recursos em ambientes de CN.

Esses resultados reforçam a Hybrid-FLBCC como uma alternativa promissora à Int-FLBCC, com potencial para impulsionar avanços na consolidação de servidores e na otimização energética em infraestruturas de nuvem.

Agradecimentos

Os autores agradecem as seguintes agências de fomento: CAPES (88887.158560/2025-00), CNPq (309559/2022-7, 409696/2022-6) e FAPERGS (21/2551-0002057-1, 23/2551-0000126-8, 24/2551-0000631-1, 24/2551-0001396-2).

Referências

- Alcalá-Fdez, J., Alcalá, R., and Herrera, F. (2011). A fuzzy association rule-based classification model for high-dimensional problems with genetic rule selection and lateral tuning. *IEEE Transactions on Fuzzy Systems*, 19(5):857–872.
- Arshad, U., Aleem, M., Srivastava, G., and Lin, J. C.-W. (2022). Utilizing power consumption and sla violations using dynamic vm consolidation in cloud data centers. *Renewable and Sustainable Energy Reviews*, 167:112782.
- Banerjee, S., Roy, S., and Khatua, S. (2024). Towards energy and qos aware dynamic vm consolidation in a multi-resource cloud. *Future Generation Computer Systems*, 157:376–391.
- Bastos, R., Seibert, V., Maia, G., de Moura, B. P., Lucca, G., Yamin, A., and Reiser, R. (2024). Exploratory data analysis in cloud computing environments for server consolidation via fuzzy classification models. In *Proceedings of the 26th International Conference on Enterprise Information Systems*, pages 636–643. INSTICC, SCITEPRESS - Science and Technology Publications.
- Bradley, A. P. (1997). The use of the area under the roc curve in the evaluation of machine learning algorithms. *Pattern Recognition*, 30(7):1145–1159.
- Calheiros, R. N., Ranjan, R., Beloglazov, A., De Rose, C. A., and Buyya, R. (2010). Cloudsim: a toolkit for modeling and simulation of cloud computing environments and evaluation of resource provisioning algorithms. *Software: Practice and Experience*, 41(1):23–50.
- Chandrashekar, G. and Sahin, F. (2014). A survey on feature selection methods. *Computers & Electrical Engineering*, 40(1):16–28. 40th-year commemorative issue.
- Chi, Z., Yan, H., and Pham, T. (1996). *Fuzzy Algorithms: With Applications to Image Processing and Pattern Recognition*. World Scientific, Singapore.
- Choudhary, A., Rajak, R., and Prakash, S. (2024). A critical review and analysis of load balancing methods in cloud computing environment. *Wirel. Pers. Commun.*, 137(4):2145–2165.
- Cordón, O., del Jesús, M. J., and Herrera, F. (1998). Analyzing the reasoning mechanisms in fuzzy rule based classification systems. *Mathware and Soft Computing*, 5(2-3):321–332.
- Faceli, K., Lorena, A. C., Gama, J., de Carvalho, A. C. P. d. L. F., and de Almeida, T. A. (2021). *Inteligência Artificial - Uma Abordagem de Aprendizado de Máquina*. LTC, 2a edição edition.
- Géron, A. (2019). *Hands-on machine learning with Scikit-Learn, Keras, and TensorFlow*. O'Reilly, Beijing, second edition edition.
- Gourisaria, M. K., Samanta, A., Saha, A., Patra, S. S., and Khilar, P. M. (2020). An extensive review on cloud computing. *Data Engineering and Communication Technology*, pages 53–78.
- He, T. and Buyya, R. (2023). A taxonomy of live migration management in cloud computing. *ACM Computing Surveys*, 56(3):1–33.

- Hühn, J. and Hüllermeier, E. (2009). Furia: an algorithm for unordered fuzzy rule induction. *Data Mining and Knowledge Discovery*, 19(3):293–319.
- Ishibuchi, H., Nakashima, T., and Nii, M. (2005). *Classification and Modeling with Linguistic Information Granules Advanced Approaches to Linguistic Data Mining*. Advanced Information Processing. Springer, Berlin.
- Lucca, G., Sanz, J. A., Dimuro, G. P., Bedregal, B., and Bustince, H. (2018). A proposal for tuning the α parameter in $c_\alpha c$ -integrals for application in fuzzy rule-based classification systems. *Natural Computing*, 19(3):533–546.
- Moura, B. M., Schneider, G. B., Yamin, A. C., Santos, H., Reiser, R. H., and Bedregal, B. (2022). Interval-valued fuzzy logic approach for overloaded hosts in consolidation of virtual machines in cloud computing. *Fuzzy Sets and Systems*, 446:144–166.
- Nathani, A., Chaudhary, S., and Somani, G. (2012). Policy based resource allocation in iaas cloud. *Future Generation Computer Systems*, 28(1):94–103.
- Raschka, S. (2020). *Python machine learning*. Packt Publishing, Birmingham, 3rd ed. edition. Includes bibliographical references and index.
- Rjeib, H. D. and Kecskemeti, G. (2024). VMP-ER: an efficient virtual machine placement algorithm for energy and resources optimization in cloud data center. *Algorithms*, 17(7):295.
- Sambuc, R. (1975). *Fonctions ϕ -floues. Application l’aide au Diagnostic en Pathologie Thyroïdienne*. PhD thesis, Marseille.
- Sanz, J., Sesma-Sara, M., and Bustince, H. (2021). A fuzzy association rule-based classifier for imbalanced classification problems. *Information Sciences*, 577:265–279.
- Sanz, J. A., Fernández, A., Bustince, H., and Herrera, F. (2013). Ivturs: A linguistic fuzzy rule-based classification system based on a new interval-valued fuzzy reasoning method with tuning and rule selection. *IEEE Transactions on Fuzzy Systems*, 21(3):399–411.
- Souza, A. R. R. d. (2024). *Deterioração Clínica em Unidades de Terapia Intensiva: uma Abordagem de Predição de Situação dos Pacientes Baseada em Inteligência Computacional*. PhD thesis, Universidade Federal de Pelotas.
- Triguero, I., González, S., Moyano, J. M., García López, S., Alcalá Fernández, J., Luengo Martín, J., Fernández Hilario, A. L., Jesús Díaz, M. J. d., Sánchez, L., Herrera Triguero, F., et al. (2017). Keel 3.0: An open source software for multi-stage analysis in data mining. *International Journal of Computational Intelligence Systems*, 10(1):1238–1249.
- Zadeh, L. A. (1965). Fuzzy sets. *Information and Control*, 8(3):338–353.