

# Sistemas Fuzzy aplicados ao Handover em Redes LTE com Falhas de Cobertura

João Paulo S. H. Lima, Álvaro A. M. de Medeiros, Eduardo P. de Aguiar, Daniel D. Silveira, Lara D. Fonseca, Tarciana C. B. Guerra, Ycaro R. Dantas e Vicente A. de Sousa Jr.

**Resumo**—Nas futuras gerações de comunicações móveis, há uma tendência de aumento significativo de requisições de handover, a qual torna essencial a formulação de melhores estratégias para esse processo a fim de fazer uso mais eficiente do espectro e maximizar a QoE. Nesse sentido, esse trabalho apresenta uma comparação concisa entre diferentes técnicas baseadas em sistemas fuzzy, a fim de otimizar a escolha do alvo para handover, em cenários com mobilidade de usuários, obstruções e falhas de coberturas. Os resultados apontam alta precisão para classificação de melhor alvo, mesmo em situações adversas.

**Palavras-Chave**—Aprendizado de máquina, Comunicações Móveis, Falha de Cobertura, Handover, Sistemas Fuzzy, LTE.

**Abstract**—In future generations of mobile communications, there is a tendency of significant augment of handover requisitions, which brings urgency to the formulation of better strategies to this procedure in order to make more efficient use of spectrum and maximize QoE. In this sense, this work presents a concise comparison between different techniques based on fuzzy systems, in order to optimize the choice of handover target, in scenarios with user mobility, obstructions and coverage holes. Results indicate high precision for classification of the best target, even in adverse situations.

**Keywords**—Machine learning, Mobile communications, Coverage Hole, Handover, Fuzzy Systems, LTE.

## I. INTRODUÇÃO

Nos sistemas modernos de comunicação sem fio, graves situações são observadas com respeito à provisão de serviços por parte das operadoras devido à crescente mobilidade. Visto que as futuras tecnologias de comunicações celulares encaminham-se para uma maior densificação de suas células, maior será a quantidade delas numa mesma área, resultando em numerosos procedimentos de *handover* [1]. Tal demanda pode representar uma ameaça à otimização da banda disponível, dado que mais dados de sinalização de rede serão processados pelo seu núcleo, afetando a eficiência espectral. Além disso, a coexistência harmônica de Redes Heterogêneas (*Het Nets*) também é prevista, considerando as projeções de especialistas para o 5G, requisitando conexões sem emendas (*seamless connections*) [2]. Ao mesmo tempo, a Internet das Coisas (IoT), ao passo que se torna mais presente no

João Paulo S. H. Lima, Álvaro A. M. de Medeiros, Eduardo P. de Aguiar, Daniel D. Silveira, Lara D. Fonseca são da Universidade Federal de Juiz de Fora, E-mails: {joao.lima, alvaro, eduardo.aguiar, danielsilveira, lara.dutra}@engenharia.ufjf.br; Tarciana C. B. Guerra, Vicente A. de Sousa Jr. são da Universidade Federal do Rio Grande do Norte, E-mails: {tarcianabrito, vicente.sousa}@ufrn.edu.br. O autor Ycaro R. Dantas está vinculado ao Sidia Instituto de Ciência e Tecnologia, Manaus, Brasil. E-mail: ycaro.d@samsung.com.

cotidiano, é capaz de multiplicar significativamente o número de dispositivos móveis que irão exigir acesso a tecnologias sem fio. É previsto um impacto econômico anual global entre 2,7 e 6,2 trilhões de dólares em 2025, a partir da expansão de tecnologias promissoras, sendo a sua maior parte ligada a sistemas de saúde, energia, indústria, transporte, agricultura, infraestrutura urbana e segurança [3].

Tal conjuntura pode levar a uma forte demanda por procedimentos de handover, a qual seria capaz de degradar a capacidade do sistema como um todo e ameaçar as taxas de transmissão oferecidas aos usuários. Ao conduzir handovers ineficientes, o número de requisições tende a subir, aumentando a indesejada carga de sinalização de rede, especialmente nas bordas de células, o que pode levar aos *handovers ping-pong*. Quando apresentam níveis de potência próximos àqueles de referência para requisição de handover, uma pequena instabilidade de sinal é capaz de levar a uma nova requisição. No entanto, essa instabilidade pode ser momentânea e, muito brevemente, aquele usuário poderá necessitar de outro handover para retornar ao serviço da sua estação base original, situação que acontece com a mobilidade próxima das bordas [4]. Por esses motivos, o procedimento de handover é pressionado a evoluir e apresentar alternativas eficientes que sejam inteligentes e versáteis, evitando handovers ping-pong, reduzindo a sinalização de rede, oferecendo maior eficiência espectral com baixa latência e conexões sem emendas.

Recentemente, vários esforços foram produzidos no sentido de implementar algoritmos de inteligência computacional para otimizar diversos parâmetros e desafios futuros para os sistemas de comunicação sem fio, como discutido em [5]. A mitigação de falhas de links estabelecidos oriundos de más decisões de handover é discutida em [6]. No contexto do uso de lógica fuzzy, [7] e [8] oferecem novas estratégias de otimização para um método tradicional de handover. Adiante, [9] traz uma ampla pesquisa do uso de lógica fuzzy em redes LTE.

Como uma colaboração para enriquecer o contexto da mobilidade em redes LTE, esse trabalho compara estratégias em um cenário de handover, no qual um usuário se move entre células LTE com falhas de cobertura, enquanto realiza um *download* de arquivo. Os modelos utilizados para investigação estão fundamentados em sistemas fuzzy. O estudo indica altas taxas de precisão para a predição do melhor alvo para handover, mesmo em situações adversas com *shadowing* e obstruções. A Seção II aborda o modelo de simulação e a coleta de dados, para alimentar os mecanismos de predição sobre o melhor handover. Em seguida, a Seção III traz de forma

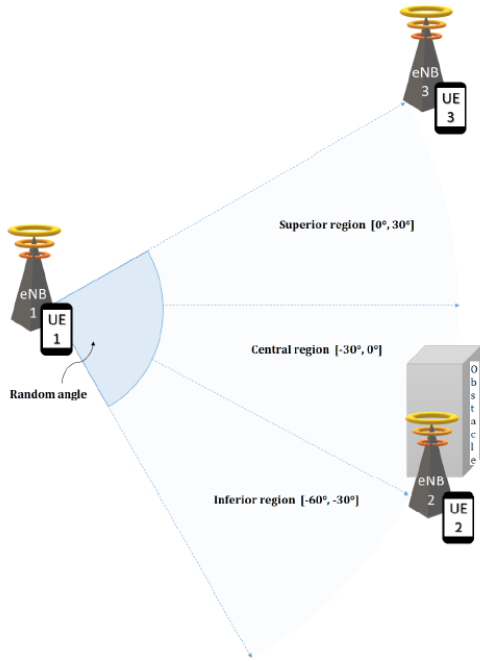



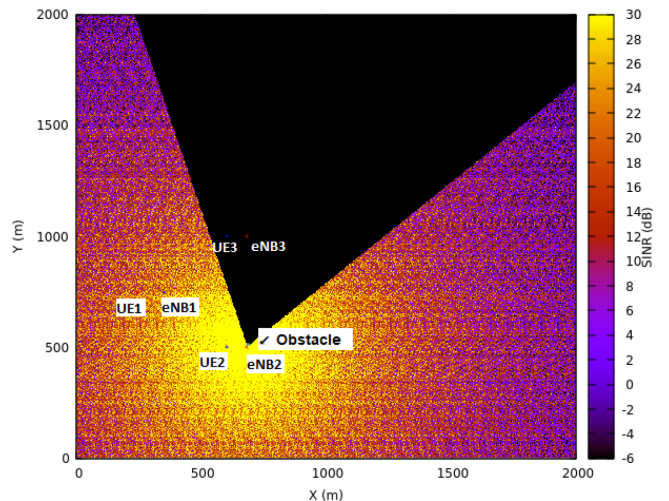
Fig. 1. A configuração da simulação.

sucinta os métodos utilizados nesse trabalho e suas principais características. Após, a Seção IV apresenta os resultados das simulações e, finalmente, a Seção V apresenta as conclusões e possíveis trabalhos futuros.

## II. MODELO DE SIMULAÇÃO

Nessa Seção, é exibido o processo de simulação e aquisição de dados. O ambiente de simulação é baseado em [10], utilizando-se a versão 3.22 do simulador de redes NS-3. Dois cenários foram explorados, como pode ser observado na configuração geral da simulação da Figura 1. O primeiro é assentado no modelo de propagação Okumura-Hata, considerando apenas a perda de percurso como efeitos do canal, o que torna essa configuração determinística. Por outro lado, o segundo considera adicionalmente o efeito *shadowing*, isto é, acrescenta-se um desvanecimento de larga escala aleatório, causado por construções ou obstáculos, incorporando falhas de cobertura para avaliação. A inclusão desse cenário promove uma contribuição para o gerenciamento da mobilidade com falhas de cobertura no contexto da aplicação de algoritmos de aprendizado de máquina. Comparando os *Radio Environment Maps* (REMs) da torre eNB 2 de ambos cenários (Figuras 2 e 3), é visível que as medidas de *Signal to Interference plus Noise Ratio* (SINR) indicam uma aleatoriedade causada pelo *shadowing* ao modelo de propagação.

Ambos os cenários contam com 3 estações base (3 eNBs), 3 usuários da rede (3 UEs) e um obstáculo próximo à torre eNB 2. O UE 1 inicia simultaneamente um download e o movimento em linha reta com velocidade constante de 60 km/h, com um ângulo aleatório entre  $-60^\circ$  e  $30^\circ$ . Rapidamente, esse usuário abandona a área de cobertura da eNB 1 e entra na área das torres eNBs 2 e 3, requisitando o handover. É importante destacar que a região central ( $-30^\circ$  a  $0^\circ$ ) será o local das


 Fig. 2. REM para Cenário 1 (sem *shadowing*).

 Fig. 3. REM para Cenário 2 (com *shadowing*).

maiores divergências, considerando que as regiões superior e inferior são fortemente influenciadas pelas torres próximas. Cada nova semente de simulação representa um novo ângulo aleatório para simulação. Para cada cenário, foram produzidas cerca de 1200 execuções. Os níveis de *Reference Signal Received Power* (RSRP) e *Reference Signal Received Quality* (RSRQ) foram capturados a cada 200 ms, sendo essas as medidas obtidas para alimentar a base de dados de entrada para os modelos. O download utiliza o protocolo *Transmission Control Protocol* (TCP), escolhido pela popularidade desse tipo de tráfego, e possui o tamanho de 15 MB. O arquivo TCP é segmentado em partes de 1448 bytes e o tamanho máximo do buffer de transmissão é 60 KB. Depois do download, não há mais troca de dados entre as partes. Finalmente, a simulação tem tempo de execução de 100 segundos.

Com a finalidade de desenvolver uma estratégia para determinar o melhor alvo de handover, três regras foram estabelecidas. A primeira regra indica que o melhor alvo será aquele que permite o download ser completado. A segunda regra determina que o melhor alvo será aquele que proporciona o

TABELA I  
PARÂMETROS DE SIMULAÇÃO BASEADOS EM [11].

Parâmetro	Valor
Banda do sistema	5 MHz
Distância interna	500 m
Adapt. Enlace, Model. erros	MiErrorModel
Área de simulação	2000m x 2000m
Número de eNBs	3
Pot. de trans. das eNBs	46 dBm
Número de UEs	3
Velocidade do UE 1	60 km/h
Perda de percurso	Okumura-Hata
Shadowing Cenário 1	Sem shadowing
Shadowing Cenário 2	LogNormal ( $\sigma = 8dB$ )
Altura da antena eNB	30 m
Altura do obstáculo	35 m
Tráfego	Bulk file transfer
Tamanho do arquivo	15 MB
Tempo de simulação	100 seconds

menor tempo de download, caso as duas opções sejam capazes de completar o download. Finalmente, a terceira regra diz que a melhor opção para handover será aquela que permite o maior número de bytes recebidos, para o caso de ambas opções não completarem o download. Para uma visualização mais ampla, os parâmetros de simulação são apresentados na Tabela I. Baseado nesse entendimento, certamente é possível inferir que o objetivo da simulação vai de encontro a um problema do tipo classificação, assentado no contexto do aprendizado de máquina.

### III. MÉTODOS COMPARADOS E SISTEMAS FUZZY

Os autores de [11] já foram capazes de demonstrar que ferramentas de inteligência computacional conseguem atingir melhores resultados do que os métodos tradicionais aplicados rotineiramente pelas operadoras. Esse trabalho se preocupa em expandir as comparações entre estratégias computacionais e, com isso, enriquecer o âmbito das implementações de aprendizado de máquinas em procedimentos de handovers em redes de comunicação celular, em particular, os classificadores baseados em regras fuzzy. Os sistemas fuzzy se destacam como ferramentas robustas para modelagem de processos complexos ao passo que preservam uma forma interpretável para a representação do conhecimento. O fato de recorrer a termos linguísticos para expressar os termos envolvidos nas regras fuzzy é um fator chave para associar o formalismo matemático e a inferência lógica à interpretabilidade humana [12]. Adicionalmente, sistemas reais são por natureza ruidosos e qualquer elemento externo pode contribuir com incertezas. Lidar com incertezas é condição *sine qua non* para o emprego de sistemas fuzzy em aplicações reais [13].

Os autores de [14] e [15] apontam que estratégias fuzzy são capazes de fornecer desempenho equivalente (ou até melhor), consumindo menos recursos computacionais, quando confrontados com ferramentas clássicas de inteligência artificial. Por essa razão, muitas técnicas baseadas em regras fuzzy são encontradas em diversas aplicações, como em [16], [8] e [7].

Os métodos aplicados nesse estudo são:

- *Autonomous Learning Multimodel System* (ALMMo) [15];
- *Self-Organizing Fuzzy Logic Classifier* (SOFL) [17];
- *Type-2 Fuzzy Logic Classifier* (T2) [16];

O modelo ALMMo é um algoritmo que pode ser aplicado em diversos tipos de problemas computacionais, como classificação, regressão, identificação, entre outros. O modelo em questão é capaz de extrair as informações necessárias dos dados para constituir seus conjuntos fuzzy e suas regras de inferência. Para isso, ele utiliza o conceito de densidade unimodal, o qual proporciona a relação de distâncias entre os dados para a formação de nuvens de dados e suas funções de pertinência. A partir de uma sequência lógica, analisa-se cada amostra para a constituição de pontos focais, ao redor do qual se formam as nuvens de pontos e, então, faz-se um julgamento da relevância daquela formulação. Caso um conjunto fuzzy formado seja considerado pouco relevante (segundo métricas internas do método), ele será descartado. O mesmo pode ocorrer com regras de inferência produzidas pelo método. Assim, o mesmo é capaz de classificar as amostras e manter um padrão alto de eficiência. Maiores detalhes sobre o modelo implementado podem ser vistos em [15].

Por sua vez, o modelo SOFL utiliza o conceito de densidade multimodal para organizar sua nuvem de pontos a partir da análise feita em cada amostra. Produz-se uma lista ordenada de amostras, baseada em suas distâncias e suas densidades. Com tal lista, são elaborados protótipos que reúnem os pontos com características comuns e, então, as regras fuzzy são depreendidas. A influência de cada protótipo nas nuvens de pontos é definida através do conceito de granularidade, uma métrica que relaciona distâncias entre pontos e é definida pelo usuário. Com isso, o sistema é facilmente adaptável para testes pelo usuário, o qual tem a liberdade de definir o nível de granularidade para seu experimento. Em geral, quanto maior esse parâmetro, maior o refinamento de detalhes, mais protótipos são produzidos e melhor costuma ser o desempenho desse classificador. O modelo implementado neste trabalho pode ser visto em [17].

Mendel em [18] torna o uso de sistemas de inferência fuzzy do tipo-2 (T2) muito mais acessível, fornecendo fórmulas matemáticas e fluxogramas para computação das derivadas necessárias para implementar métodos de máximo declive para treinamento. O mesmo explica os motivos do cálculo de tais derivadas serem muito mais complexas do que são para um sistema de inferência fuzzy do tipo-1. Classificadores baseados em T2 estão sendo cada vez mais usados em diversas aplicações devido a sua capacidade de modelar incertezas do conjunto de dados [13]. O T2 demonstrou melhores habilidades para o trato das incertezas do que sistemas de inferência fuzzy do tipo-1 em diferentes aplicações. A visão geral e as comparações discutidas em [19] e [20] ajudaram os pesquisadores e desenvolvedores de T2 a escolherem a estrutura e os algoritmos de redução de tipo mais adequados, do ponto de vista do custo computacional para implementações.

Com isto posto, a motivação desse trabalho se dá em elucidar como é o comportamento de classificadores fuzzy no ambiente da mobilidade de usuários de uma rede LTE e qual a técnica de classificação mais apta para se adaptar às condições

da configuração apresentada, provendo maior precisão e com um tempo de processamento computacional aceitável.

#### IV. RESULTADOS

Os métodos selecionados para esse estudo foram todos testados com rotinas em Python 3.7 em um computador com processador i7-6700HQ (2.6 GHz). As métricas utilizadas na comparação são a precisão das predições de melhor alvo de handover, seu desvio padrão e o tempo de processamento. Para solidificar os resultados com relevância estatística, foi implementado a técnica de validação cruzada  $k$ -Fold, com  $k = 5$ . Além disso, o teste foi executado 33 vezes para cada método empregado. Essa técnica consiste em dividir os dados em  $k$  subconjuntos mutuamente exclusivos e semelhantes, com o mesmo número de amostras, aproximadamente. Realiza-se, então, o treinamento do classificador com  $k - 1$  subconjuntos de dados e verifica-se a sua eficácia, testando-o com os dados do subconjunto restante. Esse processo é repetido por  $k$  vezes, a fim de utilizar-se todo o conjunto de dados tanto para treino quanto para teste. Isso proporciona uma vantagem para esse método, pois inibe o mau treinamento se houver a presença de *outliers* no conjunto de dados. Além disso, não são perdidos dados coletados para treinamento, já que todo o conjunto é utilizado para ambas as etapas. Dessa forma, os resultados são apresentados nas Tabela II e III, para os Cenários 1 e 2, respectivamente.

TABELA II  
ANÁLISE DE DESEMPENHO PARA O CENÁRIO 1.

Método	Precisão (%)	Desvio Padrão	Tempo (s)
SOFL	99.11	0.22	12.51
T2	98.94	0.68	5845.78
ALMMo	99.61	0.11	257.47

TABELA III  
ANÁLISE DE DESEMPENHO PARA O CENÁRIO 2.

Método	Precisão (%)	Desvio Padrão	Tempo (s)
SOFL	85.32	0.71	14.60
T2	72.40	0.98	7672.62
ALMMo	68.06	1.16	357.74

A Tabela II indica que todas as estratégias testadas possuem ótimo desempenho quando não há efeitos de *shadowing* para perturbar as classificações. Apesar de, nesse cenário, o método ALMMo atingir o maior nível de precisão, seu tempo de execução é consideravelmente alto, ao passo que o método SOFL garante desempenho semelhante, requerendo um tempo reduzido para processamento. Em seguida, ao analisar os resultados para o Cenário 2 na Tabela III, no qual há a presença de obstruções e falhas de cobertura, o algoritmo SOFL mais uma vez foi capaz de apresentar um bom desempenho, apesar da sua precisão cair consideravelmente (em torno de 14%). Seu tempo de execução continua reduzido, ao passo que os outros métodos novamente demandam tempos inaceitáveis.

#### V. CONCLUSÕES E TRABALHOS FUTUROS

Um modelo de simulação foi implementado para analisar o desempenho de métodos de aprendizado de máquina baseados em sistemas fuzzy com o intuito de prever qual alvo de handover é melhor em condições de falhas de cobertura em um ambiente LTE.

Os resultados apresentados na Seção IV indicam que os modelos experimentados conseguem altas precisões para a tarefa de classificação no Cenário 1, no qual não há perturbações oriundas de efeitos *shadowing*. Por sua vez, ao analisar os resultados para o Cenário 2, em que tem-se a presença de obstruções e falhas de cobertura, o algoritmo SOFL apresentou o melhor desempenho, mesmo com a queda da sua precisão (em torno de 14%) em relação ao outro cenário. Tais resultados demonstram a competência de sistemas fuzzy em produzir respostas robustas, mesmo em condições adversas.

Como proposta de trabalhos futuros, a comparação de sistemas fuzzy com métodos tradicionais de inteligência artificial (redes neurais, por exemplo) certamente será relevante para o contexto de aprendizado de máquinas aplicado às comunicações sem fio. Além disso, um esforço para inserir medidas e predições do tempo de download, como um problema de regressão, deverá enriquecer significativamente o trabalho desenvolvido, comparando as diversas técnicas de regressão existentes na literatura, com atenção especial aos métodos fuzzy.

#### AGRADECIMENTOS

Esse estudo foi financiado em parte pela Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Código de Financiamento 001. As simulações fornecidas por esse trabalho foram realizadas com o apoio do Núcleo de Processamento de Alto Desempenho da UFRN (NPAD/UFRN). Os autores também gostariam de registrar o agradecimento ao Programa de Pós-Graduação da Engenharia Elétrica da Universidade Federal de Juiz de Fora (PPEE-UJF).

#### REFERÊNCIAS

- [1] J. Liu, M. Sheng, L. Liu, and J. Li, "Network densification in 5g: From the short-range communications perspective," *IEEE Communications Magazine*, vol. 55, no. 12, pp. 96–102, 2017.
- [2] T. Ma, F. Hu, and M. Ma, "Fast and efficient physical layer authentication for 5g hetnet handover," in *International Telecommunication Networks and Applications Conference*. IEEE, 2017, pp. 1–3.
- [3] M. Mohammadi, A. Al-Fuqaha, S. Sorour, and M. Guizani, "Deep learning for iot big data and streaming analytics: A survey," *IEEE Communications Surveys & Tutorials*, vol. 20, no. 4, pp. 2923–2960, 2018.
- [4] M. K. Thakkar, L. Agrawal, A. K. Rangiseti, and B. R. Tamma, "Reducing ping-pong handovers in lte by using a1-based measurements," in *National Conference on Communications*. IEEE, 2017, pp. 1–6.
- [5] C. Jiang, H. Zhang, Y. Ren, Z. Han, K.-C. Chen, and L. Hanzo, "Machine learning paradigms for next-generation wireless networks," *IEEE Wireless Communications*, vol. 24, no. 2, pp. 98–105, 2017.
- [6] S. Khunteta and A. K. R. Chavva, "Deep learning based link failure mitigation," in *International Conference on Machine Learning and Applications*. IEEE, 2017, pp. 806–811.
- [7] E. Cardoso, K. Silva, and R. Francês, "Intelligent handover procedure for heterogeneous lte networks using fuzzy logic," in *International Wireless Communications and Mobile Computing Conference*. IEEE, 2017, pp. 2163–2168.

- [8] M. Saeed, M. El-Ghoneimy, and H. Kamal, "An enhanced fuzzy logic optimization technique based on user mobility for lte handover," in *National Radio Science Conference*. IEEE, 2017, pp. 230–237.
- [9] A. Mudassir, S. Akhtar, H. Kamel, and N. Javaid, "A survey on fuzzy logic applications in wireless and mobile communication for lte networks," in *International Conference on Complex, Intelligent, and Software Intensive Systems*. IEEE, 2016, pp. 76–82.
- [10] Z. Ali, N. Baldo, J. Mangués-Bafalluy, and L. Giupponi, "Simulating lte mobility management in presence of coverage holes with ns-3," in *International Conference on Simulation Tools and Techniques*, 2015, pp. 279–283.
- [11] —, "Machine learning based handover management for improved qoe in lte," in *Network Operations and Management Symposium*. IEEE, 2016, pp. 794–798.
- [12] J. M. Alonso, C. Castiello, and C. Mencar, "Interpretability of fuzzy systems: Current research trends and prospects," in *Springer Handbook of Computational Intelligence*. Springer, 2015, pp. 219–237.
- [13] J. M. Mendel, "Uncertain rule-based fuzzy systems," in *Introduction and new directions*. Springer, 2017, p. 684.
- [14] P. P. Angelov and X. Gu, "Empirical fuzzy sets," *International Journal of Intelligent Systems*, vol. 33, no. 2, pp. 362–395, 2018.
- [15] P. P. Angelov, X. Gu, and J. C. Príncipe, "Autonomous learning multimodel systems from data streams," *IEEE Transactions on Fuzzy Systems*, vol. 26, no. 4, pp. 2213–2224, 2018.
- [16] P. H. Calderano, M. G. Ribeiro, R. P. Amaral, M. M. Vellasco, R. Tanscheit, and E. P. de Aguiar, "An enhanced aircraft engine gas path diagnostic method based on upper and lower singleton type-2 fuzzy logic system," *Journal of the Brazilian Society of Mechanical Sciences and Engineering*, vol. 41, no. 2, p. 70, 2019.
- [17] X. Gu and P. P. Angelov, "Self-organising fuzzy logic classifier," *Information Sciences*, vol. 447, pp. 36–51, 2018.
- [18] J. M. Mendel, "Computing derivatives in interval type-2 fuzzy logic systems," *IEEE Transactions on Fuzzy Systems*, vol. 12, no. 1, pp. 84–98, 2004.
- [19] D. Wu, "Approaches for reducing the computational cost of interval type-2 fuzzy logic systems: overview and comparisons," *IEEE Transactions on Fuzzy Systems*, vol. 21, no. 1, pp. 80–99, 2013.
- [20] —, "An overview of alternative type-reduction approaches for reducing the computational cost of interval type-2 fuzzy logic controllers," in *International Conference on Fuzzy Systems*. IEEE, 2012, pp. 1–8.