

# Uma Abordagem Baseada em Sistemas de Inferência *Fuzzy* de Mamdani e Algoritmos Genéticos para Estimação da Qualidade de Rotas em Redes de Sensores Sem Fio Multi-Sink

**Ricardo de Andrade Lira Rabêlo**

Universidade de São Paulo - USP

ricardor\_usp@yahoo.com.br

**Líliam Barroso Leal, Marcus Vinícius de S. Lemos, Raimir Holanda Filho**

Universidade de Fortaleza - UNIFOR

{liliamleal, marvinlemos}@gmail.com, raimir@unifor.br

**Fábbio A. S. Borges**

Centro de Ensino Unificado de Teresina - CEUT

fabbioanderson@gmail.com

**Resumo** – Redes de Sensores Sem Fio (RSSFs) são compostas por um conjunto de nós sensores com o objetivo de detectar e transmitir alguma característica do meio físico. Estes nós sensores, depois de captar algum evento, devem se comunicar com um nó especial, denominado *sink node*. A utilização de um único *sink node* implica em um gargalo na rede de sensores, especialmente para aplicações de tempo real. Desta forma, as pesquisas têm direcionado estudos para a seleção de rotas em redes de sensores com múltiplos *sink nodes*. A abordagem proposta por este trabalho apresenta a aplicação de Sistemas *Fuzzy* Genéticos (SFGs) para a estimação da qualidade de rotas em RSSFs, de modo a realizar a comunicação entre múltiplos nós sensores e múltiplos *sink nodes*. Um Sistema de Inferência *Fuzzy* de Mamdani é utilizado para estimar o *sink node* mais adequado para a comunicação em um determinado instante, baseado em algumas características da rede, como a energia e o número de saltos. Algoritmos Genéticos (AGs) são empregados para obter o ajuste otimizado dos parâmetros de projeto do sistema de inferência *fuzzy* de Mamdani. A classificação das rotas proposta foi aplicada, por meio de simulações computacionais, para demonstrar a viabilidade da abordagem implementada. Os resultados obtidos apresentam uma rede de sensores com maior tempo de vida, por meio da escolha adequada do *sink node* utilizado para o envio de pacotes por meio da rede, de forma a encontrar as melhores rotas.

**Palavras-chave** – Sistemas de Inferência *Fuzzy*, Algoritmos Genéticos, Redes de Sensores Sem Fio, Sistemas *Fuzzy* Genéticos, *Sink Nodes*, Roteamento em Redes de Sensores Sem Fio.

**Abstract** – Wireless sensor networks (WSNs) are composed of sensor nodes in order to detect and transmit features from the physical environment. Generally, the sensor nodes transmit information to a special node, called sink. The approach proposed by this paper presents the application of Fuzzy Genetic Systems (FGSs) to the selection of routes in WSNs, in order to make the communication between multiple sensor nodes and multiple sink nodes. The Fuzzy Inference System (FIS) of Mamdani is used to estimate the most suitable sink for communication at a given moment, based on some network features such as energy and the number of hops. Genetic Algorithms (GAs) are employed to adjust the design parameters of the FIS. Proposed route selection was applied through of computer simulations, to show the viability of the implemented approach. The results obtained through simulation show a sensors network with longer lifetime, because the adequated choice of the sink used for sending packets through the network in order to find the best routes.

**Keywords** – Fuzzy Inference System, Genetic Algorithms, Wireless Sensor Networks, Fuzzy Genetic Systems, Sink Nodes, Wireless Sensor Networks Routing.

## 1 Introdução

Redes de Sensores Sem Fio são compostas por um conjunto de nós sensores que interagem entre si de maneira cooperativa. Esses nós sensores são dispositivos computacionais autônomos com capacidade de sensoriamento, processamento e comunicação de dados [1]. Nós sensores podem ser empregados para detectar e transmitir características do ambiente no qual eles estão inseridos tais como pressão atmosférica, nível de poluição, temperatura, umidade, luminosidade dentre outras. Estes nós sensores após captar algum evento devem se comunicar com um nó especial, denominado *sink node*, o qual irá analisar os dados recebidos para tomar alguma decisão. Alguns dos paradigmas de comunicação mais comuns nas RSSFs envolvem a comunicação de múltiplos nós sensores depositados em uma área de observação, reportando informações a um único *sink* (muitos-para-um). Entretanto, o uso de um único *sink* representa um gargalo em uma rede, especialmente para aplicações de tempo real e fluxo

contínuo de dados [2]. Nesse sentido, algumas pesquisas têm direcionado esforços para o uso de múltiplos *sinks*, nos quais a comunicação aborda um paradigma alternativo, composto de múltiplos nós sensores para múltiplos *sinks* (muitos-para-muitos).

Os nós sensores em uma RSSF são considerados muito limitados, pois contêm pouco espaço de armazenamento e baixa capacidade de processamento. Adicionalmente, os nós sensores têm uma fonte de energia limitada, proveniente de uma bateria. Neste cenário, o tempo de vida de um sensor depende da quantidade de energia disponível. Paralelamente, RSSFs podem operar por períodos de tempo que dependem fundamentalmente da quantidade de energia disponível para cada nó sensor da rede. Portanto o projeto de uma RSSF deve balancear o uso dos nós sensores levando em consideração os recursos limitados desses nós para aumentar o tempo de vida da rede.

Em muitas aplicações, o acesso aos nós sensores é dificultado devido à escala da RSSF ou ao depósito de nós sensores em áreas remotas. Desta forma, o acesso para manutenção da rede de sensores visando o abastecimento de energia torna-se impraticável. Portanto, a conservação de energia é uma das principais características a serem levadas em conta no projeto e aplicação de uma RSSF.

Este trabalho foca a estimação da qualidade de rotas para o envio de dados entre os nós sensores e os múltiplos *sink nodes* de uma RSSF. Medidas de qualidade de cada rota é empregada para auxiliar um protocolo de roteamento no processo de seleção de uma rota de comunicação dentre as várias rotas possíveis em um determinado instante de tempo. A abordagem combina sistemas de inferência *fuzzy* de Mamdani [3] e Algoritmos Genéticos (AGs) [4]. Sistemas de inferência *fuzzy* de Mamdani são utilizados para classificar as rotas de forma a determinar o *sink node* mais adequado, por meio da consideração de algumas características da RSSF, como a energia e o número de saltos (quantidade de nós intermediários que uma mensagem deve percorrer até alcançar o *sink node*). Algoritmos Genéticos são empregados para obter o ajuste otimizado dos parâmetros de projeto do sistema de inferência *fuzzy* de Mamdani. Com uma boa estimação da qualidade das rotas em uma RSSF, o protocolo de roteamento pode fazer um melhor uso das reservas de energia se este seletivamente escolher rotas que utilizam nós com maior quantidade de energia disponível de tal forma que partes da rede com poucas reservas de energia possam ser preservadas.

No projeto de um sistema de inferência *fuzzy*, constitui-se aspecto relevante a definição da base de conhecimento *fuzzy*, a qual é formada pela base de dados *fuzzy* e pela base de regras *fuzzy* [5, 6]. A base de dados *fuzzy* é composta principalmente pelas variáveis linguísticas [7, 8] e seus termos primários (termos linguísticos) [9], os quais são definidos por conjuntos *fuzzy* e suas funções de pertinência [10]. A base de regras é composta por um conjunto de regras de produção *fuzzy* [11, 12], que definem a estratégia de tomada de decisão para uma determinada aplicação. Vale ressaltar que alguns estudos têm mostrado que a performance do sistema de inferência *fuzzy* é muito mais sensível à escolha da base de dados *fuzzy* do que à composição da base de regras de produção *fuzzy* [5, 13–15]. Entretanto, a interdependência entre a base de dados *fuzzy* e a base de regras *fuzzy* sugere que um projeto automático simultâneo destes dois componentes consiste em uma metodologia mais apropriada e robusta [16].

O projeto de um sistema de inferência *fuzzy* pode ser visto como um problema de busca/otimização em um espaço de busca de alta dimensionalidade (multidimensional). Cada ponto do espaço de busca representa uma base de conhecimento *fuzzy* particular (base de dados *fuzzy* + base de regras de produção *fuzzy*). Portanto, encontrar o melhor projeto de um sistema de inferência *fuzzy* corresponde a obter um ponto ótimo deste espaço de busca. Entretanto, este espaço de busca é caracterizado como infinitamente grande, não-diferenciável, complexo, ruído, multimodal e “enganador” (*deceptive*) [17]. Desta maneira, a obtenção de um sistema de inferência *fuzzy* otimizado para uma determinada aplicação de interesse pode ser visto como uma tarefa muito complexa.

Portanto, este trabalho utiliza AGs para determinar a quantidade de termos primários para as variáveis linguísticas, o ajuste das funções de pertinência relativas aos termos primários, e o conjunto de regras de produção *fuzzy*. Com a aplicação dos AGs, pretende-se obter simultaneamente uma base de dados *fuzzy* e uma base de regras *fuzzy* para maximizar a performance da aplicação do sistema de inferência de Mamdani na classificação de rotas em Redes de Sensores Sem Fio. Os sistemas inteligentes híbridos obtidos da integração entre modelos de inferência *fuzzy* e Algoritmos Genéticos são denominados Sistemas *Fuzzy* Genéticos (SFGs) [18]. Importante ressaltar que os AGs são algoritmos de otimização global, baseados nos mecanismos da seleção natural e da genética, que têm se mostrado eficientes em uma grande variedade de problemas, pois se sobrepõem a muitas das limitações encontradas nos métodos de busca/otimização tradicionais [19]. Algumas das aplicações de SFGs envolvem a operação e controle de motor a diesel [20], a operação de estabilizadores em sistemas de potência sujeitos a perturbações e a faltas trifásicas [21], planejamento da operação de sistemas hidrotérmicos de potência [22], diagnóstico de câncer de mama [23], estimação de custo de manutenção em uma rede elétrica de distribuição [24], detecção de perigo em vigas e em lâminas de rotores de helicópteros [25], predição de requisitos de potência [26], sistema de controle de água em reservatórios [27], sistema de bomba com pressão constante para o fornecimento de água [28], classificação de dados da íris [29] e dados de vinhos [30], controle de locomotivas para um sistema de transporte baseado em trilhas [14], robótica [31, 32], controle adequado de PH nas indústrias químicas e de minerais [33], problema de controle e de estacionamento de veículos e caminhões [34], operação de um motor em série em corrente contínua [35], controle do pêndulo invertido [36] e diagnóstico de diabetes [29].

## 2. Conceitos Gerais

### 2.1 Redes de Sensores Sem Fio

Nos últimos anos tem-se presenciado um aumento considerável de pesquisas envolvendo Redes de Sensores Sem Fio (RSSFs), devido a sua aplicabilidade em diversas áreas como, militar, segurança, saúde, agricultura, ambientes inteligentes, automação industrial, dentre outras [37], [38], [39], [40]. Entretanto, os nós sensores são dispositivos com pouco espaço de armazenamento,

fonte de energia limitada e baixa capacidade de processamento. Portanto, RSSFs possuem características peculiares bem distintas das redes tradicionais, principalmente no que diz respeito a quantidade de nós presentes nas redes, restrições de energia, poder de processamento, memória disponível e largura de banda de comunicação [41]. Estas características dificultam a reutilização de vários algoritmos desenvolvidos para sistemas computacionais tradicionais. Ressalta-se que os *sink nodes* são dispositivos com características bem superiores aos nós sensores, não possuindo limitações de energia.

Em nossa proposta consideramos que na região observada os nós sensores são posicionados de modo uniforme e os múltiplos *sinks* são dispostos de forma a abranger a cobertura de toda a área.

Cada *sink node* é responsável por receber mensagens de notificação de eventos ocorridos em qualquer ponto da rede. Para isso, cada nó sensor deve selecionar o *sink node* mais apropriado em um determinado instante, levando-se em consideração características da rede, como por exemplo, energia, número de saltos, colisões e *delay*. Devemos enfatizar que neste trabalho consideramos inicialmente apenas duas características, energia e número de saltos, principais métricas consideradas em RSSFs [42].

## 2.2 Sistemas de Inferência Fuzzy

Os sistemas de inferência *fuzzy* são fundamentados em regras de produção linguísticas do tipo “*se...então*”, no qual a teoria de conjuntos *fuzzy* [43] e a lógica *fuzzy* [44] fornecem a base matemática necessária para se lidar com processos bastante complexos, baseados em informações imprecisas, incertas e qualitativas.

Os sistemas de inferência *fuzzy* têm seu funcionamento baseado em três etapas: fuzzificação, procedimentos de inferência e defuzzificação. A *fuzzificação* é um mapeamento do domínio da variável de entrada para o domínio *fuzzy*, representando a atribuição de termos primários (valores linguísticos ou qualitativos), definidos por funções de pertinência, às variáveis de entrada do sistema de inferência. O procedimento de inferência *fuzzy* é responsável por avaliar os termos primários das variáveis de entrada por meio da aplicação das regras de produção *fuzzy* de forma a obter o valor da saída *fuzzy* do sistema de inferência. A *defuzzificação* é usada para associar um valor numérico ao conjunto *fuzzy* de saída, o qual é obtido do procedimento de inferência *fuzzy*.

## 2.3 Algoritmos Genéticos

Algoritmos Genéticos são algoritmos de busca e/ou otimização baseados nos mecanismos da genética e da seleção natural. Seu funcionamento segue a inspiração biológica, a qual pressupõe que, em uma dada população, indivíduos com “boas” características genéticas têm mais chances de sobrevivência e de gerarem indivíduos cada vez mais fortes (aptos), enquanto os indivíduos menos aptos tendem a desaparecer durante o processo evolutivo. Ao utilizar AGs, cada indivíduo da população, denominado cromossomo, corresponde a uma solução potencial para o problema a ser resolvido.

O funcionamento básico dos Algoritmos Genéticos consiste em gerar uma população inicial, formada por um conjunto de indivíduos. Durante o processo evolucionário, aplica-se uma função de avaliação para cada indivíduo, de forma a atribuir-lhe um índice de aptidão que caracteriza a qualidade do indivíduo como solução do problema. Baseado no índice de aptidão, uma parte dos indivíduos é selecionada aleatoriamente, enquanto os outros são descartados. Os indivíduos mantidos pelo processo de seleção estão sujeitos a formarem descendentes para a próxima geração por meio de modificações em suas características genéticas através da aplicação dos operadores genéticos de mutação e cruzamento (recombinação ou *crossover*). Esse processo iterativo continua até que uma solução satisfatória para o problema seja encontrada. Cada uma das iterações do processo é denominada de uma geração do AG. Para prevenir que os indivíduos mais aptos não desapareçam da população pela aplicação dos operadores genéticos, pode-se aplicar uma estratégia elitista [4], que consiste em colocar automaticamente os melhores indivíduos na próxima geração.

Apesar de aparentemente simples, devido em parte a sua fundamentação bioinspirada, os AGs são capazes de resolver problemas complexos de uma maneira muito elegante. Além disso, eles não são afetados por suposições sobre diferenciabilidade ou continuidade da função objetivo do problema, pois AGs não utilizam informações de derivadas no processo evolutivo, nem necessitam de informações sobre a vizinhança dos indivíduos. Isto implica que os AGs podem ser muito adequados para lidar com problemas com funções não-diferenciáveis e descontínuas. Adicionalmente, AGs operam sobre uma população de indivíduos, de forma a explorar diferentes pontos do espaço de busca paralelamente.

# 3 Abordagem Proposta

## 3.1 Protocolo de Roteamento

O principal requisito envolvido com a operação de uma RSSF é o consumo de energia. Além do mais, a comunicação em RSSF consome mais energia do que o processamento e o sensoriamento efetuado pelos nós sensores da rede. Esta restrição impõe a necessidade de protocolos de roteamento que possibilitem que os nós sensores comuniquem-se de forma eficiente com um mínimo consumo de energia possível.

É importante destacar que é necessária a escolha de um protocolo de roteamento, pois o Sistema *Fuzzy-Genético* funcionará em conjunto com ele. Para a comunicação dos nós com os *sink nodes*, utiliza-se o protocolo de roteamento *Directed Diffusion* [45], que é projetado para Redes de Sensores Sem Fio, onde o projetista da rede é responsável por definir o tipo de evento que deve ser observado pelos nós sensores e a área monitorada. Basicamente, o funcionamento do *Directed Diffusion* aplica dois

conceitos. O primeiro, denominado *data-center*, propõe que os dados gerados pelos nós sensores sejam identificados por um par (atributo, valor). O segundo conceito é o *data-aggregation*, no qual os nós intermediários procuram agregar as mensagens com os eventos recebidos em um único evento a ser transmitido, de forma a reduzir o número de transmissões efetuadas e a quantidade de dados armazenados pela rede.

Para a construção das rotas, o *Directed Diffusion*, utiliza os seguintes elementos: dados nomeados, mensagem de interesse, gradiente e reforço. Os dados são nomeados utilizando um par (atributo, valor) e representam um evento detectado pelos nós sensores. A tarefa a ser sensoreada é difundida (*broadcasts*) periodicamente pela rede de sensores por meio de uma mensagem de interesse enviada pelo *sink node*. As mensagens de interesse podem ser originadas por um ou mais *sink nodes*, de acordo com o projeto da rede. Devido a esta característica, as mensagens de interesse quando disseminadas pela rede criam gradientes, que são estados armazenados pelos nós sensores que receberam mensagens de interesse, identificando os nós que enviam interesses. Dessa forma, os gradientes definem os nós que devem receber dados relacionados aos interesses divulgados. Por fim, tem-se o reforço, onde o *sink node* recebe mensagens de eventos ocorridos a uma baixa taxa de transmissão através dos vários caminhos disponíveis, posteriormente ele escolhe um destes caminhos e reforça a taxa de transmissão para que o evento passe a ser informado através desse caminho a uma taxa de transmissão mais alta. O *sink* realiza o reforço reenviando o interesse original para o caminho selecionado, forçando o nó fonte dos dados (nó que detectou o evento) a aumentar sua taxa de envio dos dados coletados através desse caminho.

A Figura 1 ilustra alguns aspectos do *Directed Diffusion*. A propagação do interesse é apresentada na Figura 1 (a), neste momento inicial, o *sink node* difunde pela rede uma mensagem de interesse contendo os dados nomeados (atributo, valor) dos quais ele quer receber informações. Periodicamente a mensagem de interesse é atualizada, alterando apenas a estampa de tempo do interesse, essa medida é necessária pois a rede de sensores não possui confiabilidade na transmissão dos pacotes.

Após a propagação da mensagem de interesse, os nós sensores presentes na rede associam gradientes a cada mensagem de interesse recebida, criando rotas entre o *sink* e o nó fonte dos dados, conforme apresentado na Figura 1 (b). Através do uso dos interesses e gradientes, são estabelecidos diversos caminhos entre o *sink node* e o nó fonte, contudo apenas um destes caminhos é selecionado pelo mecanismo de reforço, conforme ilustrado na Figura 1 (c).

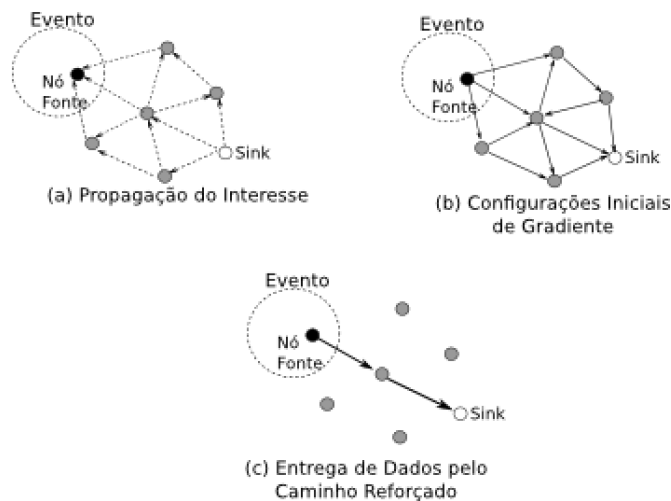


Figura 1: Construção das rotas pelo *Directed Diffusion*.

Na abordagem proposta, um nó sensor seleciona uma rota, para envio dos dados coletados, baseado em um índice, o nível *fuzzy* (FL - *Fuzzy Level*). O FL é usado para classificar cada rota que um nó possa utilizar. Rotas com maior valor de FL são consideradas preferenciais. O valor do FL é obtido por meio do modelo de inferência *fuzzy* de Mamdani, cujas entradas correspondem aos valores da energia e do número de saltos (Figura 2). Desta forma, o FL auxilia um nó sensor no processo de seleção do melhor caminho dentre as várias rotas possíveis em um dado instante de tempo, com o objetivo de aumentar o tempo de vida da rede.

### 3.2 Algoritmo para Estimação da Qualidade das Rotas

Nesta seção, apresenta-se o algoritmo implementado para estimar a qualidade de cada uma das rotas da RSSF (Figura 3). Os passos do algoritmo são:

1. *Sink nodes* geram uma lista  $V$  para armazenar os seus nós vizinhos;
2. *Sink nodes* geram uma mensagem de sinalização  $\beta^n$ ;
3. A mensagem de sinalização  $\beta^n$  é transmitida pelos *sink nodes* e propagada pela rede por meio dos nós sensores vizinhos;
4. Ao receber uma mensagem de sinalização um nó sensor  $X$  verificará os seguintes campos:

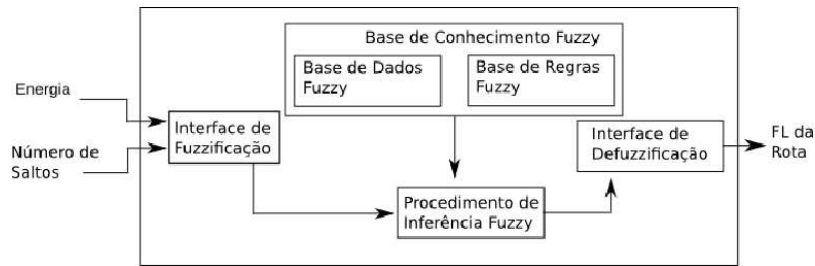


Figura 2: Sistema de inferência *fuzzy* para classificação das rotas.

- *Energia*: este campo é utilizado para armazenar o menor valor de energia encontrado no percurso até o momento;
  - *Estação\_base*: indica qual *sink node* gerou a mensagem de sinalização;
  - *Número\_saltos*: distância percorrida em saltos do *sink node* que gerou a mensagem até o nó sensor atual;
  - *Nó\_antecessor*: identifica o nó que enviou a mensagem de sinalização para o nó  $X$ ;
  - *Última\_sequência*: identifica a mensagem de sinalização. Cada vez que os *sink nodes* necessitarem reconstruir as rotas, uma nova mensagem de sinalização é gerada e o campo *Última\_sequência* será incrementado, de forma que os nós possam distinguir a mensagem atual, das mensagens de sinalização enviadas anteriormente;
5. Se o valor do campo *Nó\_antecessor* da mensagem de sinalização recebida não corresponder a nenhum dos nós vizinhos que o nó sensor  $X$  utiliza como rota atual, então ele irá desconsiderar esta mensagem descartando-a, de forma a economizar recursos do nó sensor;
  6. Nó sensor  $X$  consulta a sequência da mensagem de sinalização  $\beta^n$ ;
  7. Se o campo *Última\_sequência* for menor que a sequência atual, então trata-se da propagação de uma mensagem de sinalização recebida anteriormente e o nó sensor descarta a mensagem;
  8. Caso contrário, ou seja, a sequência atual é igual a última sequência, o nó sensor calcula o nível *fuzzy* (FL) associado a cada rota. O cálculo do FL é feito mediante a apresentação dos valores dos campos *Energia* e *Número\_saltos* ao sistema de inferência *fuzzy* de Mamdani;
  9. Nó sensor  $X$  atualiza FL;
  10. O nó  $X$  testa a sua energia em relação ao valor do campo *Energia* na mensagem de sinalização recebida. Se a energia do nó sensor  $X$  for menor que a energia contida em  $\beta^n$ , o nó sensor atualiza o campo *Energia* da mensagem de sinalização com o valor da sua energia restante. Essa atualização é feita para que o campo *Energia* efetivamente armazene o menor valor de energia encontrado até o momento;
  11. Caso a energia do nó sensor  $X$  seja maior ou igual ao valor do campo *Energia* na mensagem de sinalização recebida, o nó  $X$  simplesmente retransmite a mensagem pela rede.

Com a execução do algoritmo para classificação de rotas, o protocolo de roteamento pode utilizar o FL das rotas para escolher os caminhos para envio dos dados coletados. Portanto o protocolo de roteamento é auxiliado por estimativas da qualidade de cada rota (FL), baseando-se apenas nas informações sobre a energia e o número de saltos.

A Figura 4 ilustra uma situação de descarte de mensagem de sinalização, na qual a interligação da rede já foi estabelecida na inicialização pelo protocolo de roteamento utilizado e os nós sensores possuem múltiplas rotas. Assim, o nó sensor  $Y$  possui duas rotas de alcance ao *sink node* estabelecidas através dos nós  $X$  ( $id = 1$ ) e  $W$  ( $id = 2$ ). Quando a mensagem de sinalização  $\beta^n$  for transmitida pelo *sink node*, os nós vizinhos ao *sink node* propagam a mensagem pela rede. Deste modo, quando o nó  $Z$  receber a mensagem  $\beta^n$ , ele a repassa a todos os nós vizinhos aos quais ele tem alcance, incluindo os nós sensores que não fazem parte de sua rota, como é o caso do nó  $Y$ , que ao receber a mensagem  $\beta^n$  do nó  $Z$  a descartará imediatamente.

Neste trabalho, considera-se que cada *sink node* envia periodicamente mensagens de sinalização  $\beta^n$  pela rede, com o propósito de atualizar o FL de cada rota. Assim, haverá um melhor aproveitamento da energia dos nós sensores, pois as rotas são escolhidas a cada mensagem de sinalização transmitida. Denomina-se de janela  $\alpha$  o intervalo de tempo entre duas transmissões consecutivas de mensagens de sinalização. O valor atribuído a  $\alpha$  não pode ser muito pequeno de forma que a rede seja sobrecarregada com a constante transmissão de mensagens de sinalização e nem um valor grande o suficiente para prejudicar a escolha das rotas. Por exemplo, em um dado momento, um nó sensor, presente em uma rota, começa a perder muita energia e como o valor de  $\alpha$  é muito grande, o nó pode morrer antes que uma mensagem de sinalização possa ser transmitida para a atualização da qualidade (FL) de cada rota.

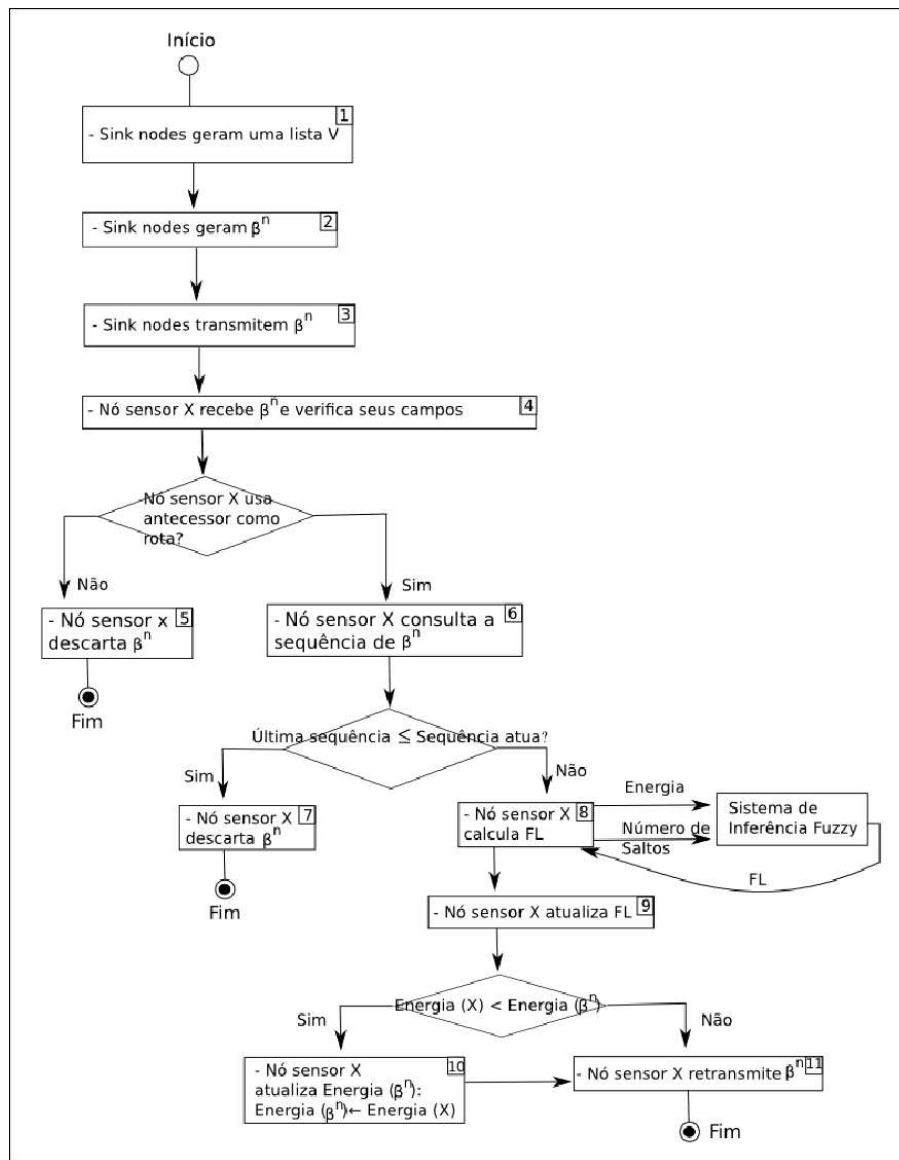


Figura 3: Algoritmo para estimação da qualidade das rotas.

### 3.3 Simulador

O simulador Sinalgo, *framework* implementado na linguagem Java, é utilizado nos experimentos para teste e validação da abordagem proposta. O Sinalgo apresenta a vantagem de permitir a simulação da operação de Redes de Sensores Sem Fio abstraindo-se as camadas mais baixas da pilha de protocolo, como física, enlace, entre outras. Portanto, pode-se focar na análise proposta, desconsiderando-se detalhes secundários para o roteamento na rede (classificação de rotas). Oferece também uma visão de transmissão de mensagens da rede, que capta bem a visão de dispositivos reais da rede. Sinalgo foi projetado, mas não é limitado para simular redes sem fio. A chave para o êxito do desenvolvimento de algoritmos de rede é um conjunto de testes abrangentes. Graças à prototipagem rápida do algoritmo em Java, pode como um primeiro ambiente de teste, antes de implantar o algoritmo para o hardware. A prototipagem em Java em vez da linguagem específica do hardware é não só muito mais rápido e mais fácil, mas também simplifica a depuração. Sinalgo oferece um amplo conjunto de condições da rede, sob o qual você pode testar seus algoritmos.

### 3.4 Aspectos da Implementação do Sistema Fuzzy Genético

Neste trabalho, empregou-se um sistema de inferência *fuzzy* de Mamdani, pois procurou-se modelar o raciocínio aproximado [46], de forma a imitar a habilidade humana de tomar decisões racionais em um ambiente com imprecisões, incertezas e ruídos. Outro modelo *fuzzy* com ampla utilização é o sistema de inferência *fuzzy* Takagi-Sugeno [47]. Este modelo foi proposto como um esforço para desenvolver uma abordagem sistemática para gerar regras de produção *fuzzy* a partir de um conjunto de dados de entrada e saída [48]. As regras *fuzzy* em um sistema de inferência *fuzzy* Takagi-Sugeno possuem variáveis linguísticas somente em seus antecedentes, e a definição dos seus consequentes, geralmente baseada no método dos mínimos quadrados, requer




Figura 4: Descarte de mensagem de sinalização

dados numéricos. Já as regras de produção em um modelo de inferência de Mamdani possuem variáveis linguísticas tanto em seus antecedentes como em seus consequentes. Portanto, a base de regras no modelo *fuzzy* de Mamdani pode ser definida exclusivamente de forma linguística, sem a necessidade de dados numéricos de entrada/saída.

O sistema de inferência *fuzzy* implementado para classificação de rotas tem duas variáveis linguísticas de entrada, a Energia e o Número de saltos, e uma variável linguística de saída, o nível *fuzzy* (FL) que mensura a qualidade de cada rota. A sintaxe das regras do sistema *fuzzy* está representada pelas seguintes declarações condicionais linguísticas:

- Regra 1: Se (*Energia é  $A_1$* ) e (*Número de saltos é  $B_1$* ), Então (*FL é  $C_1$* ), ou
- ...
- Regra  $n_r$ : Se (*Energia é  $A_p$* ) e (*Número de saltos é  $B_q$* ), Então (*FL é  $C_r$* )

onde:  $n_r$  é o número de regras;  $A_j$ ,  $B_k$  e  $C_l$  são os termos primários (valores linguísticos) associados às variáveis linguísticas Energia, Número de saltos e FL, respectivamente; p, q e r correspondem à quantidade de termos primários das variáveis linguísticas Energia, Número de saltos e FL, respectivamente.

A abordagem adotada neste trabalho propõe o uso de AGs para determinar, de forma simultânea:

- A base de dados *fuzzy*, através da especificação da quantidade de termos primários para as variáveis linguísticas e do ajuste (posicionamento) das funções de pertinência associadas a cada termo primário;
- A base de regras *fuzzy* através da combinação dos termos primários para o conjunto de regras linguísticas do sistema *fuzzy* de Mamdani.

O primeiro aspecto a ser considerado no uso de AGs para a solução de um problema é a representação cromossomal dos parâmetros do problema. Essa representação consiste em mapear a informação desses parâmetros em uma maneira viável de ser tratada pelo AG. Para a obtenção de um ajuste otimizado de um sistema de inferência *fuzzy*, deve-se codificar a base de conhecimento *fuzzy* dentro de um cromossomo de forma a considerar o relacionamento operativo entre a base de dados *fuzzy* e a base de regras *fuzzy*. Neste trabalho os cromossomos contêm informações relativas à quantidade de termos primários, às funções de pertinência dos termos primários das variáveis linguísticas, e à base de regras do sistema de inferência *fuzzy*.

A estrutura dos cromossomos para armazenar os parâmetros do sistema de inferência *fuzzy* foi dividida em três partes (Figura 5). A primeira parte codifica a quantidade de termos primários das variáveis linguísticas. Esta parte do cromossomo contém 9 genes, em que cada conjunto de 3 genes representa a quantidade de termos primários de cada uma das 3 variáveis linguísticas. A segunda parte armazena as informações da composição linguística da base de regras *fuzzy*, isto é, ela codifica os valores linguísticos do consequente associado a cada combinação das entradas das regras de produção *fuzzy*. O número máximo de termos primários de cada variável linguística foi definido como sendo igual a 5, e desta forma o número máximo de regras no sistema de inferência é igual a 25. Portanto, a segunda parte é representada por 75 genes, sendo que cada conjunto de 3 genes representa o termo primário (rótulo linguístico) associado ao consequente de cada regra de produção *fuzzy*. A terceira parte codifica os parâmetros das funções de pertinência de cada termo primário das variáveis linguísticas do sistema. As funções de pertinência utilizadas para as variáveis linguísticas são triangulares. Como as funções de pertinências têm parâmetros contínuos que necessitam de uma grande precisão, adotou-se a representação da terceira parte por meio de números reais [49], ao invés da representação binária [50] utilizada nas duas primeiras partes. Portanto, obtém-se uma representação mista (binária e real).

Entretanto, ao invés dos cromossomos armazenarem os valores  $a_i$ ,  $m_i$  e  $b_i$  para cada função de pertinência, eles armazenam os coeficientes de ajustes  $\delta_i$  e  $\eta_i$ . Cada função de pertinência  $i$  pode ser montada a partir das seguintes equações [35]:

- $a_i = (a_i + \delta_i) - \eta_i$ ;
- $m_i = (m_i + \delta_i)$ ;
- $b_i = (b_i + \delta_i) + \eta_i$ .




Figura 5: Estrutura dos Cromossomos (Indivíduos).

O coeficiente  $\delta_i$  é responsável por deslocar a função de pertinência para a direita ou esquerda. Dessa forma,  $\delta_i$  permite o deslizamento da função de pertinência em relação ao seu universo de discurso. O coeficiente  $\eta_i$  pode expandir ou encolher o suporte [51] da função da pertinência em relação ao seu universo de discurso. Assim,  $\eta_i$  pode aumentar ou reduzir a cobertura do universo de discurso pela função de pertinência (Figura 6). Como cada variável linguística possui no máximo 5 termos primários, e cada função de pertinência associada a um termo primário é representada pelos dois parâmetros  $\delta_i$  e  $\eta_i$ , são necessários no máximo 10 genes para representar as funções de pertinência de uma variável linguística do sistema de inferência *fuzzy* aplicado. Portanto, a terceira parte do cromossomo tem tamanho igual a 30. Como cada cromossomo armazena as informações sobre os parâmetros do sistema de inferência *fuzzy*, tem-se um cromossomo de 114 (9 + 75 + 30) genes. O AG implementado adotou uma população de 80 indivíduos (cromossomos). Verificou-se que 80 cromossomos garantiam o bom desempenho do algoritmo, bem como um esforço computacional aceitável.




Figura 6: Efeito dos coeficientes de ajuste na definição das funções de pertinência.

Após a definição da representação cromossomial, o projeto do AG enfoca a especificação de uma função de avaliação. Como o objetivo do sistema *fuzzy* é de ajudar o protocolo de roteamento a escolher o melhor caminho de comunicação entre os nós sensores e os *sink nodes*, este trabalho empregou como função de avaliação o tempo que leva para o primeiro nó sensor da rede morrer (isto é, o menor período de tempo necessário para o esgotamento da energia na bateria de qualquer nó sensor). Portanto, tem-se um problema de maximização, cujo objetivo está em encontrar uma base de conhecimento *fuzzy* para o sistema de inferência que ajude o protocolo de roteamento a selecionar as melhores rotas para maximizar o tempo de vida dos nós sensores e consequentemente o tempo de vida da rede.

Após o cálculo da função de avaliação para cada indivíduo da população de cromossomos, o processo de seleção escolhe um subconjunto de indivíduos da população atual, para compor uma população intermediária, de forma a aplicar os operadores genéticos. O método de seleção adotado neste trabalho foi o método do torneio [52]. Vale mencionar que o tamanho do torneio adotado foi igual a 2. Em combinação com o módulo de seleção, foi usada uma estratégia elitista, com a manutenção do melhor indivíduo de uma geração para outra.

Para fazer com que a população passe por uma evolução, deve-se aplicar os operadores genéticos. Os operadores genéticos, cruzamento e mutação, são utilizados para transformar a população por meio de sucessivas gerações, de forma a estender a busca/otimização a um resultado satisfatório. O cruzamento é o operador responsável pela recombinação genética dos pais, para permitir que a próxima geração herde as características genéticas da população atual. Neste trabalho, empregou-se o cruzamento discreto [53]. Este operador engloba os principais operadores de cruzamento para a representação binária, os quais são diretamente aplicáveis para a representação real [54]. Portanto, tem-se um operador de cruzamento compatível com a representação cromossomial adotada. O operador genético da mutação [55] é necessário para introduzir e manter a diversidade genética da população, por meio da mudança aleatória de genes (valores dos parâmetros) dentro dos cromossomos, o que fornece meios para incorporação de novas características genéticas dentro da população. Portanto, a mutação assegura a possibilidade de se chegar a qualquer ponto do espaço de busca, além de ajudar a contornar o problema de ótimos locais. Entretanto, a



| Parâmetros         |                            |                        |
|--------------------|----------------------------|------------------------|
| Sistema Fuzzy      |                            |                        |
|                    | Funções de Pertinência     | Triangular             |
|                    | Operador de Implicação     | Mínimo de Mamdani      |
|                    | Operador de Agregação      | Máximo                 |
|                    | Método de Defuzzificação   | Centro de Área         |
| Algoritmo Genético |                            |                        |
|                    | Tamanho da População       | 80                     |
|                    | Representação              | Mista (Binária e Real) |
|                    | Método de Seleção          | Torneio ( $k=2$ )      |
|                    | Operador de Crossover      | Discreto               |
|                    | Probabilidade de Crossover | 100%                   |
|                    | Operador de Mutação        | Aleatório              |
|                    | Probabilidade de Mutação   | 5%                     |
|                    | Número Máximo de Gerações  | 100                    |

Tabela 1: Valores para os principais parâmetros do Sistema *Fuzzy*-Genético implementado.

mutação é aplicada de forma menos frequente que o cruzamento, com o intuito de preservar o relacionamento exploração-aproveitamento [56]. Neste trabalho, empregou-se a mutação aleatória [57].

Vários critérios podem ser aplicados para finalizar a execução de um AG. Neste trabalho, adotou-se o limite máximo de gerações (iterações). Esse critério consiste em parar a execução do algoritmo caso o número máximo de iterações ( $t_{max}$ ) seja excedido. Ressalta-se que esse critério foi implementado porque em simulações computacionais prévias, após um certo número de gerações, o AG já apresentava uma possível convergência, mesmo variando-se os valores das probabilidades de cruzamento e mutação. O limite máximo de gerações adotado foi de 100.

Após o ajuste dos parâmetros da base de conhecimento *fuzzy*, o sistema de inferência obtido pode ser colocado em operação para a estimação da qualidade das rotas na RSSF. A inferência de cada regra do sistema de inferência *fuzzy* obtido consiste na avaliação do antecedente, seguida da aplicação do operador de implicação para determinar o conjunto *fuzzy* do consequente. A agregação consiste em combinar (agregar), os conjuntos *fuzzy* dos consequentes obtidos pela inferência de cada regra. O procedimento de defuzzificação obtém o valor numérico do FL, ou seja, um índice quantitativo que indica a qualidade da rota. Desta forma, o sistema de inferência *fuzzy* é responsável por estimar a qualidade das rotas baseado em dois critérios: energia e número de saltos. A estimação da qualidade das rotas, por meio do FL, auxilia o protocolo de roteamento na tomada de decisão para selecionar o melhor caminho dentre os vários possíveis para o envio de dados em uma RSSF. Importante mencionar que rotas com maior valor de FL são consideradas preferenciais.

A Tabela 1 resume os valores dos parâmetros utilizados na implementação do Sistema *Fuzzy*-Genético:

#### 4 Aplicações e Discussões

Os resultados da aplicação da abordagem proposta baseada em Sistemas *Fuzzy*-Genéticos são apresentados baseados em duas métricas. As métricas são:

- Tempo de morte do primeiro nó: expressa o tempo de morte do primeiro nó na rede. Esta métrica permite analisar por quanto tempo todos os nós sensores permanecem vivos;
- Tempo de vida da rede: registra por quanto tempo a rede permanece viva, isto é, até quando a rede poderá manter ativas as comunicações necessárias, mesmo com a morte de alguns nós sensores;

Os cenários simulados são:

- Cenário 1: o simulador utiliza o protocolo de roteamento *Directed Diffusion* em sua forma tradicional, sem uso de sistemas de inferência *fuzzy*. Paralelamente, a simulação aplica balanceamento de carga de forma a distribuir uniformemente a carga

de trabalho (os pacotes transmitidos) entre as várias rotas existentes. Adicionalmente, para este cenário, considerou-se um rodízio de rotas de forma que todas as rotas sejam utilizadas. Com isso, pretende-se auxiliar o protocolo *Directed Diffusion* para minimizar o consumo de energia das rotas, uma vez que evita-se o consumo exaustivo de uma determinada rota em detrimento das outras. Essas considerações adicionais foram inseridas para melhorar a operação do *Directed Diffusion* quando utilizado sem suporte dos sistemas de inferência *fuzzy*;

- Cenário 2: o simulador aplica sistema de inferência *fuzzy* de Mamdani para estimar a qualidade das rotas baseado na energia e no número de saltos, de forma a auxiliar o protocolo de roteamento *Directed Diffusion*. Contudo, a concepção do sistema de inferência *fuzzy* é feita de maneira empírica, em que a definição da base de conhecimento *fuzzy* é feita baseada em vários testes com configurações diferentes (tentativa e erro);
- Cenário 3: como no cenário 2, consideramos a aplicação de um sistema de inferência *fuzzy* de Mamdani para auxiliar o protocolo de roteamento *Directed Diffusion*. Entretanto, neste cenário, a base de conhecimento do sistema de inferência *fuzzy* é ajustada automaticamente por meio de Algoritmos Genéticos.

A seguir descrevemos o modelo utilizado para estimar o consumo de energia de cada nó sensor da rede.

Utilizamos um modelo de energia baseado nos dados definidos em [58] e [59]. Consideramos a taxa de transmissão do nó de  $0,26\mu s/bit$ , sendo a corrente elétrica que flui pelo nó ao receber um pacote de  $7,0mA$  e ao transmitir de  $21,5mA$ . Assim, definiu-se o seguinte modelo [59]:

- $Q_{Transmissao} = 3 * 21,5mA * (0,26 * 10^{-6}s/bit * 288bits) = 0,48375mJ/mensagem$
- $Q_{Recepcao} = 3 * 7,0mA * (0,26 * 10^{-6}s/bit * 288bits) = 0,1575mJ/mensagem$
- $Q_{ouvir} = 3 * 7,0mA * (0,26 * 10^{-6}s/bit * 16bits) = 0,00875mJ/mensagem$

Onde Energia Dissipada (Q) = Voltagem x Corrente Elétrica X Tempo, sendo Tempo = Taxa de Transmissão X Tamanho da Mensagem. Neste trabalho, não tratamos o consumo de energia relacionado ao processamento da mensagem, deixando o mesmo para trabalhos futuros.

#### 4.1 Características da Rede

As principais características da rede são:

1. Topologia: a rede simulada é fixa e composta por apenas dois tipos de nós: *sink nodes* e nós sensores. Os nós sensores possuem características similares, caracterizando uma rede plana, na qual cada nó da rede possui um identificador único e um alcance de rádio fixo;
2. Quantidade de nós: a rede de sensores é composta por 100 nós sensores distribuídos uniformemente. O número de *sink nodes* variou de 1 a 7, de forma a ilustrar a influência do número de *sink nodes* no tempo de vida dos nós sensores e da rede.

#### 4.2 Resultados

Apesar da abordagem proposta ser direcionada a ambientes com múltiplos *sink nodes*, inicialmente apresenta-se o comportamento da RSSF por meio das simulações computacionais com os 3 cenários descritos considerando-se apenas um único *sink node*. Estes experimentos foram realizados com o propósito de verificar a viabilidade e eficiência da aplicação de um Sistema *Fuzzy-Genético* em um ambiente com um único *sink* (mono-*sink*). O comportamento das RSSFs também foi avaliado em cada cenário para verificar a qualidade da classificação das rotas em ambientes multi-*sink*. Adicionalmente, as simulações com ambientes mono-*sink* e multi-*sink* permitem verificar a relevância da quantidade de *sink nodes* no ambiente monitorado e a influência deles no tempo de vida da rede.

Para a primeira métrica de avaliação, tempo de morte do primeiro nó, a Tabela 2 e a Figura 7 ilustram os resultados obtidos para todos os 3 cenários simulados. O cenário 2 apresenta uma melhora em relação ao cenário 1, o que mostra a relevância do sistema de inferência *fuzzy* para a estimação da qualidade das rotas da RSSF. Portanto, o protocolo de roteamento *Directed Diffusion* pode escolher os melhores caminhos para envio de dados, baseado em um modelo de inferência *fuzzy* que utiliza apenas valores da energia e do número de saltos. Deve ser ressaltado que o ajuste da base de conhecimento *fuzzy* para o Cenário 2 foi obtido de forma manual através de várias simulações. Adicionalmente, pode-se perceber que o tempo de morte do primeiro nó apresenta um comportamento crescente entre os cenários, alcançando o maior valor para o cenário 3. Isso implica que a utilização de um Sistema *Fuzzy-Genético* maximiza o tempo de vida dos nós sensores presentes na RSSF, quando comparado aos outros cenários. Assim, para o cenário 3, o *Directed Diffusion* pode fazer uso de uma base de conhecimento altamente sintonizada para a estimação da qualidade das rotas na RSSF. Pode-se observar também que maiores tempo de vida são obtidos quando mais *sink nodes* são inseridos na RSSF. Esse fato se deve ao aumento do número de rotas possíveis que cada nó sensor pode utilizar para a transmissão de dados pela rede.

| Tempo de Morte do Primeiro Nó [segundos] |           |           |           |
|--|-----------|-----------|-----------|
| Número de <i>Sink Nodes</i>              | Cenário 1 | Cenário 2 | Cenário 3 |
| 1  | 14144     | 18254     | 19468     |
| 2  | 18334     | 20674     | 26656     |
| 3  | 19114     | 22388     | 27926     |
| 4  | 20441     | 23811     | 28329     |
| 5  | 21387     | 24381     | 29443     |
| 6  | 22441     | 25193     | 30277     |
| 7  | 23101     | 26771     | 31893     |

Tabela 2: Tempo de Morte do Primeiro Nó da RSSF.

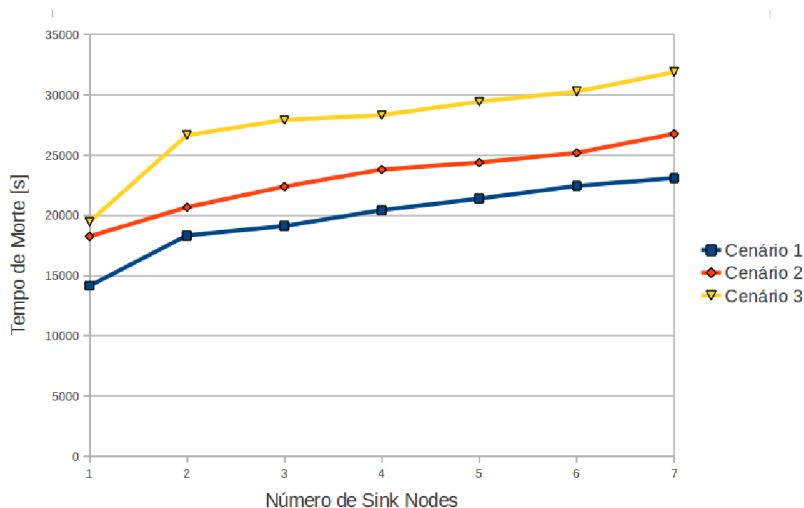


Figura 7: Tempo de morte do primeiro nó.

Para a outra métrica de avaliação, tempo de vida da rede, a Tabela 3 e a Figura 8 ilustram os resultados obtidos para todos os 3 cenários simulados. Esta métrica refere-se ao tempo em que a comunicação da rede é interrompida devido a morte de alguns nós sensores que compõem as rotas do transmissor.

Novamente, pode-se observar um melhor comportamento para o cenário 3. Esse fato representa que o uso de um sistema de inferência *fuzzy* para auxiliar o protocolo de roteamento foi responsável por maximizar o tempo de vida da rede. O *Directed Diffusion*, ao utilizar uma base de conhecimento *fuzzy* ajustada pela aplicação de Algoritmos Genéticos, é capaz de selecionar as melhores rotas para envio de dados coletados. Entretanto, deve-se notar que para uma RSSF com mais de 2 *sink nodes*, o cenário 1 teve um comportamento melhor quando comparado ao cenário 2. Por mais que o tempo de morte do primeiro nó sensor pelo cenário 1 seja menor que o tempo para o cenário 2, o tempo de vida da rede para o cenário 1 é superior ao tempo de vida para o cenário 2. Ou seja, a aplicação isolada do *Directed Diffusion* obteve um maior tempo de vida da rede quando comparado à aplicação de um sistema de inferência *fuzzy* ajustado de forma não-automática. Portanto, o sistema de inferência *fuzzy* obtido pelo ajuste manual não foi capaz de superar a aplicação do protocolo de roteamento operando isoladamente. Isso é consequência de um ajuste “pobre” (não-otimizado) na base de conhecimento *fuzzy* do sistema de inferência de Mamdani. Portanto, esse resultado valida o uso de um AG para otimizar os parâmetros do sistema de inferência *fuzzy*. Da mesma forma que para a primeira métrica, o tempo de vida da rede cresce com o número de *sink nodes*.

## 5. Conclusões

Este trabalho propõe uma abordagem baseada em Sistemas *Fuzzy*-Genéticos aplicada à Rede de Sensores Sem Fio com múltiplos *sink nodes*. O Sistema *Fuzzy*-Genético trabalha em conjunto com o protocolo de roteamento *Directed Diffusion* de forma a auxiliar um nó sensor no processo de seleção do melhor caminho dentre as várias rotas possíveis em um determinado instante. Baseado na energia e no número de saltos, um sistema de inferência *fuzzy* de Mamdani é usado para estimar a qualidade das rotas. Com isso, o protocolo de roteamento *Directed Diffusion* pode determinar o *sink node* mais adequado para o envio de dados com o objetivo de aumentar o tempo de vida da rede.

O projeto de um sistema de inferência *fuzzy* pode ser caracterizado como um problema de busca/otimização em um espaço de busca de alta dimensionalidade (multidimensional), muito grande, não diferenciável, complexo, ruidoso, multimodal e “enganoso” (*deceptive*). Estas características motivaram os autores a aplicar AGs para o projeto (ajuste) do sistema de inferência *fuzzy*

| Tempo de Vida da Rede [segundos] |           |           |           |
|----------------------------------|-----------|-----------|-----------|
| Número de <i>Sink Nodes</i>      | Cenário 1 | Cenário 2 | Cenário 3 |
| 1                                | 21518     | 23314     | 31586     |
| 2                                | 31136     | 32816     | 43284     |
| 3                                | 37918     | 34992     | 45991     |
| 4                                | 38291     | 35200     | 46871     |
| 5                                | 39331     | 36484     | 47281     |
| 6                                | 40192     | 37291     | 48332     |
| 7                                | 41871     | 38211     | 49273     |

Tabela 3: Tempo de Vida da Rede.

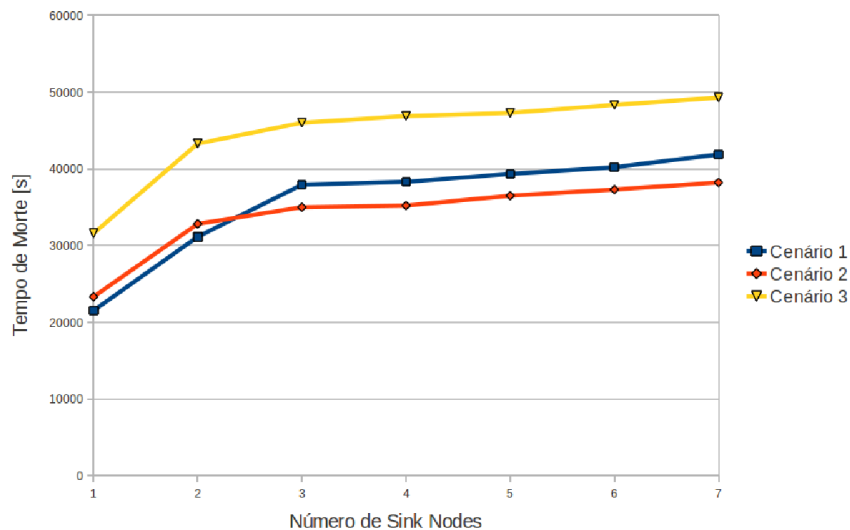


Figura 8: Tempo de vida da rede.

de Mamdani, visto que AGs se sobrepõem a muitas das limitações encontradas nos métodos de busca/otimização tradicionais.

A estimação da qualidade das várias rotas da RSSF por meio de Sistema *Fuzzy*-Genético foi simulada computacionalmente para demonstrar a viabilidade da abordagem implementada. O simulador Sinalgo foi utilizado para realizar as simulações computacionais para os 3 cenários considerando as mesmas características da rede. Para todos os cenários, notou-se que o tempo de morte do primeiro nó sensor e o tempo de vida da rede melhoraram significativamente com o aumento do número de *sink nodes* na RSSF. Os resultados obtidos pelo Cenário 3 (uso de Sistema *Fuzzy*-Genético) apresentam uma rede de sensores com maior tempo de vida para todos os nós sensores (maior tempo necessário para a morte do primeiro nó sensor) e maior tempo de vida para a RSSF. Assim por meio do uso de AGs foi possível derivar uma base de conhecimento *fuzzy* (base de dados *fuzzy* + base de conhecimento *fuzzy*) que auxilia o protocolo de roteamento a definir as melhores rotas possíveis para o envio de dados baseado apenas na energia e no número de saltos. Com a seleção das melhores rotas, a rede terá um maior tempo de vida e poderá manter ativas as comunicações necessárias por muito mais tempo. Entretanto, conforme verificado pelos resultados concernentes ao tempo de vida da rede, observou-se que a aplicação de um sistema de inferência *fuzzy* ajustado manualmente (cenário 2) através de várias tentativas realizadas (tentativa e erro) não foi capaz de superar o tempo de vida da rede obtido pela aplicação isolada do protocolo *Directed Diffusion*. Portanto, realmente faz-se necessário o emprego de uma técnica automática de ajuste para os parâmetros de projeto do sistema de inferência *fuzzy*, de forma a maximizar o tempo de vida da RSSF.

Como os sistemas de inferência *fuzzy* são potencialmente capazes de expressar e manipular informações qualitativas, os especialistas de domínio podem mapear a sua experiência e o seu processo de tomada de decisões, de forma linguística (qualitativa). Portanto, ao optar-se por um sistema de inferência *fuzzy* de Mamdani para a classificação de rotas em uma RSSF com múltiplos *sink nodes*, obtém-se uma estratégia de ação/controlar que pode ser monitorada e interpretada do ponto de vista linguístico. Desta forma, a estratégia de ação/controlar do sistema de inferência *fuzzy* de Mamdani pode ser considerada tão fundamentada e consistente quanto a estratégia dos especialistas de domínio.

Como trabalhos futuros, pretendemos analisar o comportamento da seleção de rotas em ambientes mais complexos, bem como incorporar novas variáveis linguísticas para a inferência *fuzzy*. Adicionalmente, pretendemos aplicar otimização por enxame de partículas (PSO - *Particle Swarm Optimization*) em substituição ao Algoritmo Genético para o ajuste da base de conhecimento *fuzzy*.

## Referências

- [1] H. Karl and A. Willig. *Protocols and Architectures for Wireless Sensor Networks*. John Wiley & Sons, 2005.
- [2] A. Boukerche and A. Martirosyan. “An energy efficient and low latency multiple events’ propagation protocol for wireless sensor networks with multiple sinks”. In *PE-WASUN '07: Proceedings of the 4th ACM workshop on Performance evaluation of wireless ad hoc, sensor, and ubiquitous networks*, pp. 82–86, New York, NY, USA, 2007. ACM.
- [3] E. H. Mamdani. “Application of Fuzzy Algorithms for Control of Simple Dynamic Plant”. *Proceedings of IEE Control and Science*, vol. 121, no. 12, pp. 1585–1588, 1974.
- [4] D. E. Goldberg. *Genetic Algorithms in Search, Optimization and Machine Learning*. Addison-Wesley Longman Publishing Co., Inc. Boston, MA, USA, 1989.
- [5] O. Cordón, F. Herrera and P. Villar. “Generating the Knowledge Base of a Fuzzy Rule-Based System by the Genetic Learning of the Data Base”. *IEEE Transactions on Fuzzy Systems*, vol. 9, no. 4, pp. 667–674, 2001.
- [6] F. Hoffmann. “Evolutionary Algorithms for Fuzzy Control System Design”. *Proceedings of the IEEE*, vol. 89, no. 9, pp. 1318–1333, 2001.
- [7] L. Zadeh. “Outline of a New Approach to the Analysis of Complex Systems and Decision Processes”. *IEEE Transactions on Systems, Man, and Cybernetics*, vol. 3, no. 1, pp. 28–44, 1973.
- [8] L. A. Zadeh. “The Concept of a Linguistic Variable and its Application to Approximate Reasoning -I”. *Information Sciences*, vol. 8, no. 3, pp. 199–249, 1975.
- [9] L. Zadeh. “Soft Computing and Fuzzy Logic”. *IEEE software*, vol. 11, no. 6, pp. 48–56, 1994.
- [10] W. Pedrycz and F. Gomide. *An Introduction to Fuzzy Sets*. MIT Press Cambridge, MA, 1998.
- [11] E. Tsang, D. Yeung, J. Lee, D. Huang and X. Wang. “Refinement of Generated Fuzzy Production Rules by using a Fuzzy Neural Network”. *IEEE Transactions on Systems, Man, and Cybernetics, Part B: Cybernetics*, vol. 34, no. 1, pp. 409–418, 2004.
- [12] D. S. Yeung and E. C. C. Tsang. “Weighted Fuzzy Production Rules”. *Fuzzy Sets and Systems*, vol. 88, no. 3, pp. 299–313, 1997.
- [13] O. Cordón, F. Herrera and P. Villar. “Analysis and Guidelines to Obtain a Good Uniform Fuzzy Partition Granularity for Fuzzy Rule-Based Systems Using Simulated Annealing\*”. *International Journal of Approximate Reasoning*, vol. 25, no. 3, pp. 187–215, 2000.
- [14] P. Bonissone, P. Khedkar and Y. Chen. “Genetic Algorithms for Automated Tuning of Fuzzy Controllers: A Transportation Application”. In *Proceedings of the 1996 5th IEEE International Conference on Fuzzy Systems*, volume 1, pp. 674–680. Citeseer, 1996.
- [15] L. Zheng. “A Practical Guide to Tune of Proportional and Integral (PI) Like Fuzzy Controllers”. In *IEEE International Conference on Fuzzy Systems*, pp. 633–640. IEEE, 1992.
- [16] A. Homaifar and E. McCormick. “Simultaneous Design of Membership Functions and Rule Sets for Fuzzy Controllers using Genetic Algorithms”. *IEEE Transactions on Fuzzy Systems*, vol. 3, no. 2, pp. 129–139, 1995.
- [17] Y. Shi, R. Eberhart and Y. Chen. “Implementation of Evolutionary Fuzzy Systems”. *IEEE Transactions on Fuzzy Systems*, vol. 7, no. 2, pp. 109–119, 1999.
- [18] F. Herrera. “Genetic Fuzzy Systems: Taxonomy, Current Research Trends and Prospects”. *Evolutionary Intelligence*, vol. 1, no. 1, pp. 27–46, 2008.
- [19] R. L. Haupt and S. E. Haupt. *Practical Genetic Algorithms*. Wiley New York, 1998.
- [20] L. Radziszewski and M. Kekez. “Application of a Genetic-Fuzzy System to Diesel Engine Pressure Modeling”. *The International Journal of Advanced Manufacturing Technology*, vol. 46, no. 1, pp. 1–9, 2010.
- [21] M. Dubey. “Design of Genetic Algorithm Based Fuzzy Logic Power System Stabilizers in Multimachine Power System”. In *Joint International Conference on Power System Technology and IEEE Power India Conference, 2008. POWERCON 2008*, pp. 1–6, 2008.
- [22] R. A. L. Rabelo, F. A. S. Borges, R. A. S. Fernandes, A. A. F. M. Carneiro and R. T. V. Braga. *An Application of Genetic Fuzzy Systems to the Operation Planning of Hydrothermal Systems*, pp. 69 – 88. INTECH, 2011.

- [23] C. Pena-Reyes and M. Sipper. “A Fuzzy-Genetic Approach to Breast Cancer Diagnosis”. *Artificial Intelligence in Medicine*, vol. 17, no. 2, pp. 131–155, 1999.
- [24] O. Cordón and F. Herrera. “Hybridizing Genetic Algorithms with Sharing Scheme and Evolution Strategies for Designing Approximate Fuzzy Rule-Based Systems”. *Fuzzy Sets and Systems*, vol. 118, no. 2, pp. 235–255, 2001.
- [25] P. Pawar and R. Ganguli. “Genetic Fuzzy System for Damage Detection in Beams and Helicopter Rotor Blades”. *Computer Methods in Applied Mechanics and Engineering*, vol. 192, no. 16-18, pp. 2031–2057, 2003.
- [26] A. Nandi and D. Pratihar. “Design of a Genetic-Fuzzy System to Predict Surface Finish and Power Requirement in Grinding”. *Fuzzy Sets and Systems*, vol. 148, no. 3, pp. 487–504, 2004.
- [27] K. Ng and Y. Li. “Design of Sophisticated Fuzzy Logic Controllers Using Genetic Algorithms”. In *Proceedings 3rd IEEE International Conference on Fuzzy Systems, FUZZ-IEEE’94*, pp. 1708–1712. Citeseer, 1994.
- [28] K. Tang, K. Man, Z. Liu and S. Kwong. “Minimal Fuzzy Memberships and Rules using Hierarchical Genetic Algorithms”. *IEEE Transactions on Industrial Electronics*, vol. 45, no. 1, 1998.
- [29] O. Cordon, M. del Jesus and F. Herrera. “Genetic Learning of Fuzzy Rule-Based Classification Systems Cooperating with Fuzzy Reasoning Methods”. *International Journal of Intelligent Systems*, vol. 13, no. 10-11, pp. 1025–1053, 1998.
- [30] M. Setnes and H. Roubos. “GA-Fuzzy Modeling and Classification: Complexity and Performance”. *IEEE Transactions on Fuzzy Systems*, vol. 8, no. 5, pp. 509–522, 2000.
- [31] D. Pratihar, K. Deb and A. Ghosh. “Design of a Genetic-Fuzzy System for Planning Crab Gaits of a Six-Legged Robot”. *Journal of Computing and Information Technology*, vol. 7, pp. 93–101, 1999.
- [32] H. Hagrass, V. Callaghan and M. Colley. “Learning and Adaptation of an Intelligent Mobile Robot Navigator Operating in Unstructured Environment based on a Novel Online Fuzzy-Genetic System”. *Fuzzy Sets and Systems*, vol. 141, no. 1, pp. 107–160, 2004.
- [33] C. L. Karr and E. J. Gentry. “Fuzzy Control of pH Using Genetic Algorithms”. *IEEE Transactions on Fuzzy Systems*, vol. 1, no. 1, pp. 46–53, 1993.
- [34] B. Liu, C. Chen and J. Tsao. “Design of Adaptive Fuzzy Logic Controller based on Linguistic-Hedge Concepts and Genetic Algorithms”. *IEEE Transactions on Systems, Man, and Cybernetics, Part B: Cybernetics*, vol. 31, no. 1, pp. 32–53, 2001.
- [35] D. Park, A. Kandel and G. Langholz. “Genetic-based New Fuzzy Reasoning Models with Application to Fuzzy Control”. *IEEE Transactions on Systems, Man and Cybernetics*, vol. 24, no. 1, pp. 39–47, 1994.
- [36] F. Herrera, M. Lozano and J. Verdegay. “A Learning Process for Fuzzy Control Rules using Genetic Algorithms\*”. *Fuzzy Sets and Systems*, vol. 100, no. 1-3, pp. 143–158, 1998.
- [37] Y. chee Tseng, Y. chiun Wang and L. wu Yeh. “iPower: An Energy Conservation System for Intelligent Buildings by Wireless Sensor Networks”, 2009.
- [38] I. F. Akyildiz, T. Melodia and K. R. Chowdhury. “A survey on wireless multimedia sensor networks”. *Comput. Netw.*, vol. 51, no. 4, pp. 921–960, 2007.
- [39] A. Mainwaring, D. Culler, J. Polastre, R. Szewczyk and J. Anderson. “Wireless sensor networks for habitat monitoring”. In *WSNA '02: Proceedings of the 1st ACM international workshop on Wireless sensor networks and applications*, pp. 88–97, New York, NY, USA, 2002. ACM.
- [40] N. Xu. “A Survey of Sensor Network Applications”. *IEEE Communications Magazine*, vol. 40, 2002.
- [41] J. Hill, R. Szewczyk, A. Woo, S. Hollar, D. Culler and K. Pister. “System architecture directions for networked sensors”. *SIGPLAN Not.*, vol. 35, no. 11, pp. 93–104, 2000.
- [42] C. F. Garca-herndez, P. H. Ibargengoytia-gonzlez, J. Garca-herndez and J. A. Prez-daz. “Wireless Sensor Networks and Applications: a Survey”. 2007.
- [43] L. Zadeh. “Fuzzy Sets\*”. *Information and control*, vol. 8, no. 3, pp. 338–353, 1965.
- [44] L. A. Zadeh. “Fuzzy Logic = Computing with Words”. *IEEE Transactions on Fuzzy Systems*, vol. 4, no. 2, 1996.
- [45] C. Intanagonwivat, R. Govindan, D. Estrin, J. Heidemann and F. Silva. “Directed diffusion for wireless sensor networking”. *IEEE/ACM Trans. Netw.*, vol. 11, pp. 2–16, February 2003.

- [46] E. H. Mamdani. “Application of Fuzzy Logic to Approximate Reasoning Using Linguistic Synthesis”. *IEEE Transactions on Computers*, vol. 26, no. 12, pp. 1182–1191, 1977.
- [47] T. Takagi and M. Sugeno. “Fuzzy Identification of Systems and its Applications to Modeling and Control”. *IEEE Trans. Syst., Man, Cybern.*, vol. 15, pp. 116–132, 1985.
- [48] J. M. Mendel. *Uncertain Rule-Based Fuzzy Logic Systems: Introduction and New Directions*. Prentice Hall, 2001.
- [49] T. Srikanth and V. kamala. “A Real Coded Genetic Algorithm for Optimization of Cutting Parameters in Turning”. *IJCSNS International Journal of Computer Science and Network Security*, vol. 8, no. 6, pp. 189 – 193, 2008.
- [50] J. H. Holland. *Adaptation in Natural and Artificial Systems*. Ann Arbor: The University of Michigan Press, 1975.
- [51] H. J. Zimmermann. *Fuzzy Set Theory – and its Applications*. Kluwer Academic Publishers, 2001.
- [52] A. E. Eiben, R. Hinterding and Z. Michalewicz. “Parameter Control in Evolutionary Algorithms”. *IEEE Transactions on Evolutionary Computation*, vol. 3, no. 2, pp. 124–141, 1999.
- [53] F. Herrera, M. Lozano and A. M. Snchez. “Hybrid Crossover Operators for Real-coded Genetic Algorithms: an Experimental Study”. *Soft Computing-A Fusion of Foundations, Methodologies and Applications*, vol. 9, no. 4, pp. 280 – 298, 2005.
- [54] F. Herrera, M. Lozano and A. M. Snchez. “A Taxonomy for the Crossover Operator for Real-Coded Genetic Algorithms: An Experimental Study”. *International Journal of Intelligent Systems*, vol. 18, no. 3, pp. 309–338, 2003.
- [55] R. Hinterding, H. Gielewski and T. Peachey. “The Nature of Mutation in Genetic Algorithms”. In *Proceedings of the Sixth International Conference on Genetic Algorithms*, pp. 65–72. Citeseer, 1995.
- [56] F. Herrera, M. Lozano and J. Verdegay. “Tackling Real-Coded Genetic Algorithms: Operators and Tools for Behavioural Analysis”. *Artificial Intelligence Review*, vol. 12, no. 4, pp. 265–319, 1998.
- [57] Z. Michalewicz. *Genetic Algorithms + Data Structures = Evolution Programs*. Springer, 2011.
- [58] K.-M. K. T. Schmidt, D. and N. Wehn. “Energy modelling in sensor networks”. pp. 347–351, 2007.
- [59] A. P. R. da Silva, M. H. T. Martins, B. P. S. Rocha, A. A. F. Loureiro, L. B. Ruiz and H. C. Wong. “Decentralized intrusion detection in wireless sensor networks”. In *Proceedings of the 1st ACM international workshop on Quality of service & security in wireless and mobile networks, Q2SWinet '05*, pp. 16–23, New York, NY, USA, 2005. ACM.