

08 a 11 de Outubro de 2018
Instituto Federal Fluminense
Búzios - RJ

ROTEIRIZAÇÃO DO SINK MÓVEL EM RSSF MULTI-HOP: ALGORITMO GENÉTICO PARA SOLUÇÃO DO TSPN

Larissa Maria Santiago Correia^{1,2} - larissa.mscorreia@gmail.com

Alexandre Celestino Leite Almeida^{1,3} - celestino@ufsj.edu.br

Pedro Mitsuo Shiroma^{1,4} - pshiroma@ufsj.edu.br

¹Universidade Federal de São João Del Rei, Campus Alto Paraopeba - Ouro Branco, MG, Brasil

²Graduanda em Engenharia de Telecomunicações

³DEFIM - Departamento de Estatística, Física e Matemática

⁴DTECH - Departamento de Tecnologia e Engenharia Civil, Computação e Humanidades

Resumo. *Em uma rede de sensores sem fio de múltiplos saltos, a escolha do melhor trajeto para um sink móvel realizar a coleta de dados é de crucial importância, pois minimiza o tempo gasto no percurso, disponibilizando mais tempo para a coleta de dados de fato. Neste caso, os pontos da borda da região de cobertura contém os melhores pontos de parada do sink. Uma vez que todas as posições sobre os perímetros dos clusters são possíveis pontos de parada para o sink móvel durante sua rota, encontrar o melhor percurso a ser realizado se resume a resolver o Problema do Caixeiro Viajante com Vizinhaça (TSPN). Este trabalho propõe, como método de resolução para o problema de escolha da melhor rota de um sink móvel em uma rede de sensores sem fio com múltiplos saltos, um algoritmo genético que busca minimizar a distância percorrida pelo sink na busca pelo melhor trajeto a ser realizado.*

Palavras-Chave: *TSPN, Algoritmo Genético, Caixeiro Viajante, Caixeiro Viajante com Vizinhaça, Redes de Sensores Sem Fio*

1. INTRODUÇÃO

Uma rede de sensores sem fio (RSSF) é composta por diversos nós sensores, com um raio de cobertura, espalhados em uma determinada área, que coletam informações sobre certa condição. Neste trabalho são analisadas redes de sensores sem fio com múltiplos saltos (RSSF *multi-hop*), em que os nós podem trocar dados entre si ou com um nó móvel coletor (*sink* móvel, responsável pela coleta de dados). Assim, alguns nós sensores podem, primeiramente, enviar seus dados à nós mais próximos dele. Estes nós, então, enviam o conteúdo recebido diretamente para o *sink* móvel.

Os nós mais próximos entre si tendem a criar *clusters* (agrupamento de nós). Desta forma, levando em consideração que cada nó sensor presente na RSSF possui uma região de cobertura, a borda da região de um *cluster* é determinada a partir da união das regiões de cobertura dos

nós mais externos pertencentes à ele. Assim, o *sink* móvel precisa parar em apenas um ponto da borda do cluster para a recepção dos dados, para que pelo menos um nó possa conseguir enviar os dados (seus e os recebidos) para o *sink*.

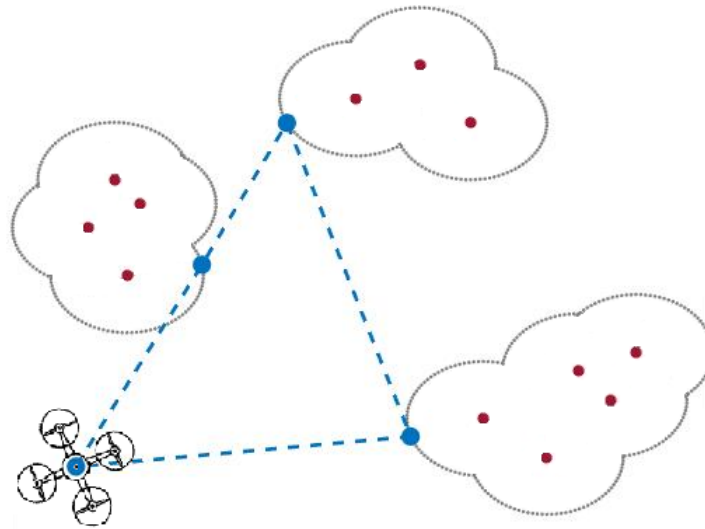


Figura 1- Exemplo de rota realizada por um *sink* móvel, sobre as bordas de *clusters* formadas em uma RSSF *multi-hop* devido a união das regiões de cobertura de cada nó individual.

A Fig. 1 mostra um exemplo de RSSF de múltiplos saltos e ilustra uma possível rota a ser realizada pelo *sink* móvel posicionado em p_0 , em que os pontos de parada da trajetória são pontos sobre as curvas formadas pela união das áreas de cobertura de cada nó do *cluster*.

A coleta de dados em uma RSSF *multi-hop*, quando o interesse é roteirizar o *sink* apenas otimizando o comprimento da rota do mesmo, é uma aplicação bastante estudada na forma do Problema do Caixeiro Viajante com Vizinhança (TSPN - Traveling Salesman Problem with Neighborhoods). Vários trabalhos apresentam soluções para a resolução da otimização da coleta de dados de redes através de *sinks* móveis, utilizando distintas perspectivas do TSPN, como em Yuan et al. (2007), Anuar et al. (2017), Liu et al. (2013), He et al. (2013) e Wu, Liu (2014). O TSPN é um problema derivado do Problema do Caixeiro Viajante (TSP - Traveling Salesman Problem).

O Problema do Caixeiro Viajante (TSP) tem sido investigado há mais de 50 anos (Lin, 1965). Nele, um viajante, ao sair de determinada origem, precisa passar por uma série de cidades e retornar ao ponto de partida. O problema é definido como encontrar o melhor caminho a ser percorrido pelo viajante, que usualmente é o menor caminho. Ao longo dos anos, foram encontradas diversas aplicações para o TSP, em várias áreas, como raio-X cristalográfico, roteamento de veículos como um problema de m -caixeiros, etapas da fabricação de placas de circuito eletrônico, entre outros (Conte, 2002).

No Problema do Caixeiro Viajante com Vizinhança (TSPN), o viajante não precisa, necessariamente, visitar a cidade, mas apenas passar em algum ponto de sua vizinhança. Deste modo, o problema de coleta de dados em redes de sensores sem fio de múltiplos saltos pode ser abordado como TSPN.

Em relação a complexidade computacional para a resolução do Problema do Caixeiro Viajante e do Problema do Caixeiro Viajante com Vizinhança, o TSP é NP-completo (Reinelt,

1994) e o TSPN é um problema mais difícil, sendo NP-difícil (Gudmundsson, Levcopoulos, 1999), já que o problema precisa determinar não somente a rota, como também o ponto da vizinhança que o viajante irá passar.

Para a resolução destes problemas, uma gama de algoritmos de otimização com heurísticas comuns são aplicadas, como otimização por enxames de partículas, por colônia de formigas, por colônias de abelhas, *simulated annealing* e algoritmos genéticos (Reinelt, 1994).

Neste trabalho, um algoritmo genético (AG) é proposto para a solução do problema. Atualmente, a maior parte da literatura apresenta soluções que envolvem apenas circunferências como região limite de certa área. Neste trabalho, o algoritmo genético é válido para curvas quaisquer. O algoritmo genético, em conjunto com uma abordagem simples de resolução para o TSP, são aplicados às curvas, de forma a determinar o caminho que produz a distância aproximadamente mínima a ser percorrida por um *sink* móvel de posição inicial p_0 .

2. FORMULAÇÃO DO MÉTODO PROPOSTO

É bastante aplicado em estudos a aproximação das bordas dos *clusters* por curvas conhecidas e de fácil parametrização, como circunferências, elipses, cardioides, etc. Caso não sejam curvas unicamente definidas, pode-se defini-las a partir da interseção das curvas de bordo das coberturas de todos os nós dos clusters. A partir desta suposição, é factível encontrar a melhor rota para um *sink* móvel resolvendo o Problema do Caixeiro Viajante com Vizinhança (TSPN) sobre estas curvas parametrizadas.

Os cenários estudados consistem de diversas regiões que simulam *clusters*, cujos perímetros são definidos por conhecidas curvas paramétricas no plano.

2.1 Algoritmo Genético

O funcionamento do algoritmo genético utilizado é ilustrado no Algoritmo 1, seguindo o padrão da maioria dos encontrados na literatura. No mesmo, *tampop* é o tamanho da população, *xu* é valor máximo que as componentes dos indivíduos podem assumir e *xl* é o valor mínimo. A função *escolhe_melhores_individuos* retorna os melhores indivíduos da população. As variáveis *p_C*, *p_M* e *max_avaliacoes* são a probabilidade de ocorrer o cruzamento, a probabilidade de ocorrer mutação e o máximo número de avaliações, respectivamente.

A alteração feita no algoritmo genético é a definição do indivíduo (ou cepa), como a seguir.

Definição do indivíduo (Cepa). A cepa é representada por (t_1, t_2, \dots, t_n) , que está associada a um conjunto de pontos $P_1 = r_1(t_1), P_2 = r_2(t_2), \dots, P_n = r_n(t_n)$, que são pontos respectivamente das curvas distintas C_i de parametrização $r_i(t)$, $i \in (1, 2, \dots, n)$.

As funções utilizadas a cada iteração do algoritmo genético são explanadas a seguir, segundo Takahashi (2007).

Função Objetivo. Neste trabalho, o objetivo é minimizar a distância percorrida pelo *sink* móvel ao visitar as curvas. Dado um indivíduo (t_1, \dots, t_n) , e seus pontos de parada respectivos $(R_1(t_1), \dots, R_n(t_n))$, a função objetivo retorna o valor da distância percorrida no caminho encontrado pelo TSP para os pontos de parada dados (incluindo a origem como ponto inicial e final).

Algoritmo 1: ALGORITMO GENÉTICO

Entrada: $tampop, xu, xl, p_C, p_M, max_avaliacoes$

Saída: *Resultado*

1 **início**

2 $Populacao \leftarrow geraPopulacaoInicial(tampop, xu, xl)$

3 $avaliacoes \leftarrow 0$

4 **Enquanto** ($avaliacoes \leq max_avaliacoes$)

5 $melhores \leftarrow escolhe_melhores_individuos(Populacao)$

6 $Populacao \leftarrow cruzamento(Populacao, p_C)$

7 $Populacao \leftarrow mutacao(Populacao, p_M)$

8 $Populacao \leftarrow selecao(Populacao)$

9 $Populacao \leftarrow elitizacao(Populacao, melhores)$

10 **fim Enquanto**

11 $Resultado \leftarrow melhor_individuo(Populacao)$

12 **fim**

13 **retorna** *Resultado*

Função Ajuste. Também conhecida como função *fitness*, essa função é responsável por avaliar e, através de recursos matemáticos aplicados aos resultados provenientes da função objetivo, determinar quem são os melhores indivíduos da população analisada. A função ajuste utilizada neste trabalho é dada por:

$$FT = \alpha J + \beta \quad (1)$$

sendo J o vetor de avaliações da função objetivo para os N indivíduos da população. Os valores de α e β são determinados considerando $\bar{J} = média(J)$, $J_M = max(J)$, $J_m = min(J)$, $v = \frac{(\gamma J_m - J_M)}{(\gamma - 1)}$, $\gamma = 1, 8$ e:

- Para $J_m \geq v$:

$$\alpha = \bar{J} \frac{(\gamma - 1)}{(J_M - \bar{J})} \quad (2)$$

$$\beta = \bar{J} \frac{(J_M - \gamma \bar{J})}{J_M - \bar{J}} \quad (3)$$

- Para $J_m < v$:

$$\alpha = \frac{\bar{J}}{(J_M - J_m)} \quad (4)$$

$$\beta = -\frac{\bar{J} J_m}{(J_M - J_m)} \quad (5)$$

Cruzamento. Nesta função, a população é dividida em duas metades. Para cada par formado, verifica-se se vai ou não ocorrer cruzamento, com probabilidade de ocorrência de 50%. Caso vá ocorrer cruzamento, dois novos indivíduos são gerados da seguinte forma:

$$X_N = \alpha X_a + (1 - \alpha) X_b, \quad -0.1 \leq \alpha \leq 1.1 \quad (6)$$

onde α é escolhido aleatoriamente, seguindo uma distribuição uniforme, no intervalo: $-0,1 < \alpha < 1,1$.

Mutação. Cada indivíduo pode sofrer mutação, com probabilidade igual a 0,05. Neste caso, será somado ao indivíduo um vetor V cujas componentes são dadas por V_i com distribuição normal $N(0, \delta_i)$, onde δ é calculado $\delta = 0.05B_i$, e B_i é o tamanho do intervalo de busca na dimensão i .

Avaliação. Cada indivíduo é avaliado na função objetivo.

Seleção. É realizada uma seleção de N indivíduos dentre os N indivíduos existentes, sendo que cada indivíduo pode ser selecionado mais de uma vez. A probabilidade de um indivíduo ser selecionado a cada vez é igual ao valor da fração de sua função de ajuste em relação à soma das funções de ajuste de todos os indivíduos.

Elitização. Caso os melhores indivíduos não tenham sido selecionados para a nova população, eles são nela introduzidos, com a exclusão de elementos quaisquer, escolhidos aleatoriamente.

O Algoritmo 1 ilustra a aplicação da maioria das funções explanadas. As funções objetivo e ajuste não são ilustradas no Algoritmo 1, pois as mesmas são aplicadas dentro das funções mostradas.

2.2 TSP

O uso do TSP é feito para achar a melhor rota, ou seja, a ordem de visita aos pontos que o *sink* móvel deve seguir, uma vez que as coordenadas que devem ser visitadas durante o percurso é definida.

Quando um cenário com no máximo oito curvas é considerado, ou seja, o *sink* móvel deve passar por oito pontos e retornar a origem, a análise de todas combinações de rotas possíveis é computacionalmente aceitável para a resolução do TSP. Para um maior número de curvas, algoritmos de otimização devem ser utilizados, para que o custo computacional seja reduzido.

2.3 Resolução do TSPN

O método proposto consiste em aplicar o TSP, junto a parametrizações, como função objetivo do algoritmo genético. Nesse caso, a população do algoritmo genético é composta de indivíduos de dimensão n (n = número de curvas), com cada componente da cepa assumindo um valor dentro do intervalo $t_i = [0, 1]$. Respeitando este intervalo, a parametrização das curvas é respeitada.

Quando cada indivíduo é avaliado através da função objetivo, o mesmo é transformado em coordenadas do plano cartesiano, através de equações de parametrização adequadas ao tipo de curva em análise e, as coordenadas resultantes são utilizadas para calcular o melhor resultado do TSP.

3. RESULTADOS

Nesta seção, foram criados alguns cenários para a análise do método proposto. Os centros das curvas paramétricas foram gerados aleatoriamente seguindo uma distribuição uniforme em cada coordenada. O tamanho da população adotada para o algoritmo genético foi de 50 indivíduos.

Foram analisados os seguintes cenários: área com oito circunferências de mesmo raio, área com sete cardióides de diferentes inclinações e raios e, por fim, área com três elipses, três cardióides e uma circunferência, todos de raios e inclinações diferentes.

Para o primeiro cenário descrito, os algoritmos de comparação foram executados nove vezes. Para os demais cenários, vinte execuções foram realizadas. Os resultados obtidos pela média das distâncias percorridas em cada execução é mostrado na Tabela 1.

O algoritmo CSS (He et al., 2013), usado na comparação dos resultados do primeiro cenário, adota um modelo de comunicação de disco unitário, em que todos os dados de uma RSSF são coletados pelo *sink* móvel, desde que o trajeto do mesmo intercepte os discos de todos os nós. Este modelo utiliza como base RSSFs *single-hop* assim como a maioria dos trabalhos presentes na literatura.

Em uma rede de único salto, para que o *sink* móvel recolha os dados de todos os nós, ele deve estar posicionado de tal forma que as informações sejam transmitidas através de comunicação direta, ou seja, apenas um salto, entre o próprio nó e o *sink*, não havendo a possibilidade dos dados serem enviados para outro nó da rede antes de chegar ao *sink*.

A comparação foi realizada utilizando o algoritmo CSS, apesar do mesmo ser *single-hop*, pois não foram encontrados trabalhos que utilizassem RSSFs *multi-hop* junto a abordagem do TSPN.

Outra comparação realizada foi com o modelo TSP, que considera os centros das circunferências como os pontos de parada durante o percurso do *sink* móvel.

A Fig. 2 ilustra a diferença dos percursos em uma das execuções realizadas para o primeiro cenário.

O ponto de origem, p_0 , é ilustrado pelo "X", em cinza, nas figuras, de onde todas as linhas que representam os percursos saem e chegam.

Visivelmente, a solução encontrada pelo TSP não é boa. A obrigação de tornar os centros das áreas pontos de parada do percurso de um *sink* móvel aumenta significativamente a distância percorrida, o que é comprovado pelos resultados mostrados na Tabela 1.

Tabela 1- Resultados provenientes dos diferentes métodos de análise para o cenário 1 (8 circunferências), cenário 2 (7 cardióides) e cenário 3 (3 elipses, 3 cardióides e 1 circunferência). O método de análise CSS é considerado somente no cenário 1, pois é aplicável somente a situações de espectro circular.

Cenário	Distância média (m) Genético proposto	Distância média (m) TSP	Distância média (m) CSS (He et al., 2013)
1	928,9218	1.185,4677	962,7434
2	1.017,5702	1.208,8169	–
3	980,1072	1.208,8169	–

O método CSS apresenta um quantidade de pontos de parada durante a rota reduzida em

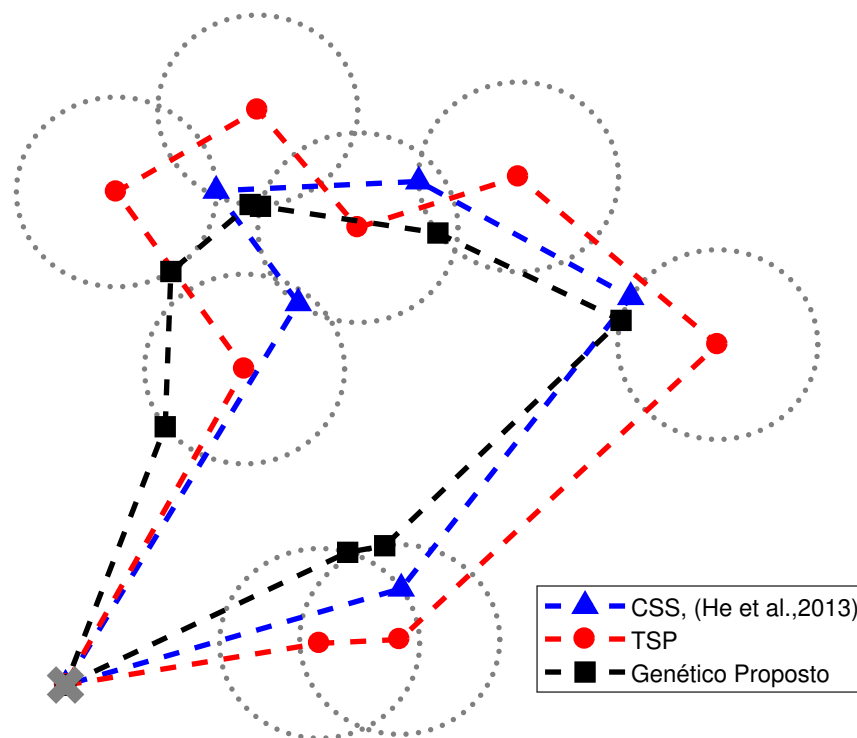


Figura 2- Cenário 1 - Trajetórias encontradas pelos métodos de análise: Genético Proposto (rota em preto, $d = 985,54\text{m}$), TSP (rota em vermelho, $d = 1.288,79\text{m}$) e CSS (He et al., 2013) (rota em azul, $d = 1.074,30\text{m}$).

relação ao método proposto neste trabalho, pois considera que os pontos de parada podem estar dentro das regiões delimitadas pelas curvas, enquanto o método proposto considera possíveis pontos de parada apenas na borda da curva. Apesar desse fato, a melhor rota para esses pontos acarreta uma maior distância percorrida para o método CSS quando comparado ao método proposto.

Este trabalho, além de fornecer bons resultados para espectros circulares, principal foco da literatura atual, oferece, também, a análise de outras curvas. Os demais cenários propostos ilustram esse fato. O método CSS não é utilizado, pois sua aplicação se restringe à curvas que simulam discos.

A Fig. 3 mostra o resultado da execução do método proposto para o segundo cenário citado. Afim de comparação, o TSP foi novamente aplicado às execuções. Mais uma vez, os resultados do método proposto se mostram melhores frente aos fornecidos pelo TSP, como mostrado pela Tabela 1 e pela Fig. 3.

Da mesma forma que realizado para os cenários anteriores, a Fig. 4 mostra a execução do método proposto para o terceiro cenário apresentado. Novamente, os resultados encontrados para o método proposto são melhores que os encontrados para o TSP, como apresentado na Tabela 1 e na Fig. 4.

Na Tabela 1, os valores de distâncias média percorridas para o método do TSP, no segundo e terceiro cenários, são iguais, apesar de os cenários serem diferentes. Isso aconteceu, pois mesmo




Figura 3- Cenário 2 - Trajetórias encontradas pelos métodos de análise: Genético Proposto (rota em preto, $d = 988,79\text{m}$) e TSP (rota em vermelho, $d = 1.284,26\text{ m}$).

com curvas diferentes, a quantidade de centros e as posições dos mesmos foram mantidos de um cenário para outro.

4. CONCLUSÕES

O presente trabalho propõe um método para determinar a rota de um *sink* móvel para coleta de dados de uma RSSF. O método propõe a aproximação das bordas dos *clusters* por curvas paramétricas facilitando o encontro da melhor posição sobre o perímetro de cada agrupamento de nós sensores. A metodologia proposta soluciona o problema TSPN mesmo nas situações onde a vizinhança é complexa, ou seja, o contorno pode apresentar regiões côncavas, não suaves ou até apresentar interseção com regiões vizinhas. A única restrição imposta é que ela seja parametrizável por partes. Desta forma o algoritmo proposto é genérico, ao contrário dos trabalhos frequentemente encontrados na literatura, que apresentam a resolução de tal problema apenas para *clusters* com espectro circular.

A utilização do algoritmo evolucionário dinamiza o processo, de modo que as melhores combinações possíveis de posições sobre as regiões limites dos *clusters* são testadas através do TSP em uma mesma geração do algoritmo genético.

Analisando os dados da Tabela 1 verifica-se que, mesmo no caso circular, a abordagem proposta é superior ao TSPN tradicional proposto por He et al. (2013). Além disso, é possível concluir que algoritmos com base na resolução do TSPN (Problema do Caixeiro Viajante com




Figura 4- Cenário 3 - Trajetórias encontradas pelos métodos de análise: Genético Proposto (rota em preto, $d = 974,35\text{m}$) e TSP (rota em vermelho, $d = 1.240,34\text{m}$).

Vizinhança) fornecem resultados melhores frente aos que resolvem o TSP (Problema do Caixeiro Viajante). Este fato acontece devido à rota fornecida pelo TSP ser sempre maior que a fornecida pelo TSPN, uma vez que para o primeiro problema, o *sink* móvel necessita visitar o centro do *cluster*, o que não ocorre para o segundo problema.

Embora o trabalho atual tenha focado no cenário de coleta de dados em RSSF o algoritmo proposto pode ser aplicado em diversas outras aplicações, como por exemplo o sequenciamento de tarefas em robôs (Alatartsev et al. (2013)).

Uma limitação presente na solução refere-se à escalabilidade do mesmo em relação ao número de *clusters*. Devido ao aumento do tamanho do cromossomo, é possível que para números mais elevados de *clusters* o algoritmo genético apresente problemas de convergência, causados pela alto custo computacional necessário para calcular a função objetivo de cada indivíduo.

Concluindo, garantir que os pontos encontrados pelo método proposto são ótimos é impossível, porém ele se mostra eficiente em fornecer bons resultados, tornando a resposta próxima à mínima, uma vez que resolve o Problema do Caixeiro Viajante com Vizinhança em conjunto à aproximação do perímetro dos *clusters* por curvas paramétricas.

Agradecimentos

Os autores agradecem à FAPEMIG (Projeto 16179 e do termo APQ-01366-16) e ao CNPq pelo apoio financeiro.

REFERÊNCIAS

- Alatartsev Sergey, Mersheeva Vera, Augustine Marcus, Ortmeier Frank.* On Optimizing a Sequence of Robotic Tasks // Proceedings of the International Conference on Intelligent Robots and Systems (IROS). 2013.
- Annuar Noralifah, Bergmann Neil, Jurdak Raja, Kusy Branislav.* Mobile Data Collection from Sensor Networks with Range-Dependent Data Rates. 10 2017. 53–60.
- Conte Nelson.* O problema do caixairo viajante, teoria e aplicações. 2002.
- Gudmundsson Joachim, Levcopoulos Christos.* A Fast Approximation Algorithm for TSP with Neighborhoods and Red-blue Separation // Proceedings of the 5th Annual International Conference on Computing and Combinatorics. Berlin, Heidelberg: Springer-Verlag, 1999. 473–482. (COCOON'99).
- He L., Pan J., Xu J.* A Progressive Approach to Reducing Data Collection Latency in Wireless Sensor Networks with Mobile Elements // IEEE Transactions on Mobile Computing. July 2013. 12, 7. 1308–1320.
- Lin S.* Computer solutions of the traveling salesman problem // The Bell System Technical Journal. Dec 1965. 44, 10. 2245–2269.
- Liu Jing-Sin, Wu Shao-You, Chiu Ko-Ming.* Path planning of a data mule in wireless sensor network using an improved implementation of clustering-based genetic algorithm. 04 2013. 30–37.
- Reinelt Gerhard.* The Traveling Salesman: Computational Solutions for TSP Applications. Berlin, Heidelberg: Springer-Verlag, 1994.
- Takahashi R. H. C.* Otimização Escalar e Vetorial - Volume 1: Conceitos Preliminares. 2007.
- Wu Shao-You, Liu Jing-Sin.* Evolutionary path planning of a data mule in wireless sensor network by using shortcuts. 07 2014. 2708–2715.
- Yuan B., Orłowska M., Sadiq S.* On the Optimal Robot Routing Problem in Wireless Sensor Networks // IEEE Transactions on Knowledge and Data Engineering. Sept 2007. 19, 9. 1252–1261.

ROUTING MOBILE SINK IN MULTI-HOP WSN: A TSPN SOLUTION BY GENETIC ALGORITHM

Abstract. *In a multi-hop wireless sensor network, choosing the best route for a mobile sink to perform data collection is of crucial importance as it minimizes the time spent on the route, providing more time for actually collecting data. In this case, the edge points of the coverage region contain the best points of the sink stop. Since all positions on the perimeters of the clusters are possible stopping points for the mobile sink during its route, finding the best route to be undertaken is simply to solve the Traveling Salesman Problem with Neighborhood (TSPN). This work proposes, as a resolution method for the problem of choosing the best route from a mobile sink in a wireless multi-hop sensor network, a genetic algorithm which seeks to minimize the distance traveled by the sink in the search for the best route to be performed.*

Keywords: *TSPN, Genetic Algorithm, Traveling Salesman Problem, Traveling Salesman Problem with Neighborhood, Wireless sensor network*