LI Simpósio Brasileiro de Pesquisa Operacional
Limeira–SP, 02 a 06 de setembro de 2019

Uma abordagem multiobjetivo para resolver o problema de cobertura e redução de RSUs em Redes Veiculares

Thiago Da Silva Correia
Programa de Pós-Graduação de Modelagem Matemática e Computacional
Centro Federal de Educação Tecnológica de Minas Gerais
Belo Horizonte – MG – Brazil
info.thiagosilva@gmail.com

João F. M. Sarubbi
Departamente de Computação
Centro Federal de Educação Tecnológica de Minas Gerais
Belo Horizonte – MG – Brazil
joaosarubbi@gmail.com

Flávio V. C. Martins
Departamente de Computação
Centro Federal de Educação Tecnológica de Minas Gerais
Belo Horizonte – MG – Brazil
flaviocruzeiro@cefetmg.br

RESUMO

Neste trabalho, propomos um algoritmo evolucionário multiobjetivo baseado no método NSGA-II para resolver a alocação de Unidades Rodoviárias (RSUs) em uma Rede Veicular. Nossos objetivos consistem simultaneamente maximizar a área coberta e minimizar o número de RSUs utilizados. O algoritmo proposto neste trabalho utiliza operadores geométricos projetados especificamente para esse tipo de problema a fim de obter melhores resultados. O algoritmo proposto neste trabalho foi comparado ao da literatura atingindo melhores resultados em todos os casos testados.

PALAVRAS CHAVE. Algoritmos Genéticos, NSGA-II, Redes Veiculares.

ABSTRACT

In this work, we propose a multiobjective evolutionary algorithm based on the NSGA-II method for solving the Deployment of Roadside Units (RSUs) in a Vehicular Network. Our goal is at the same time maximize the covered area (minimize the uncovered area) and also to minimize the number of RSUs used. Our algorithm uses geometric operators specifically designed for this problem in addition to a local search for better results. We compared our results in a simulated area. Our results surpassed all the results of the work that was used as the basis for this experiment.

KEYWORDS. Genetic Algorithm, NSGA-II, Vehicular Networks.

https://proceedings.science/p/106913?lang=pt-br

1. Introdução

Os sistemas de comunicação entre veículos constituem as chamadas redes veiculares (VANETs), e o estudo dessas redes tem recebido significativa atenção nos últimos anos [Cunha et al., 2016]. Uma rede veicular pode fornecer acesso móvel aos veículos com maior desempenho e baixo custo [Ott e Kutscher, 2004]. Essas redes diferem de outras redes sem fio, principalmente devido às características de seus nós que são formados por caminhões, carros e ônibus. Esses nós possuem uma alta mobilidade e são limitados apenas pela topologia das rodovias.

As VANETs são projetadas para auxiliar motoristas e passageiros durante suas viagens com o objetivo de reduzir acidentes e gerenciar o tráfego nas principais cidades. Além disso, existem várias outras aplicações, tais como: (i) aplicações de segurança que visam alertar o motorista sobre a possibilidade de colisões com outro veículo ou com algum obstáculo à frente [Zaldivar et al., 2011]; (ii) disponibilidade de vagas de estacionamentos [Panayappan et al., 2007]; (iii) tráfego de veículos em tempo real [Qureshi et al., 2017], dentre outras.

Existem três tipos de conexões nas redes veiculares: (i) Veículo-to-Veículo (V2V), onde as conexões são estabelecidas diretamente entre dois veículos; (ii) Veículo-to-Infraestrutura (V2I), onde as conexões são estabelecidas entre os veículos e as Unidades Rodoviárias (do inglês, *Roadside Units* RSU) e, (iii) as redes híbridas, que misturam os dois tipos de conexões mencionadas [Blum et al., 2004].

Embora as redes com conexão V2V não necessitem de uma infraestrutura para operar, o que as torna mais baratas, sua desvantagem mais significativa é que, em ambientes com um pequeno número de nós - veículos - elas podem se tornar altamente ineficientes. Por outro lado, as redes V2I ficam mais caras devido à necessidade de instalar as unidades de comunicação. Estudos mostram que este tipo de rede pode aumentar significativamente a eficiência da rede veicular [Wu et al., 2012; Reis et al., 2011]. Portanto, tem-se um impasse entre reduzir os custos de implantação das RSUs e garantir a eficiência deste tipo de rede. Neste caso, torna-se necessário conhecer a localização estratégica onde as RSUs devem ser alocadas de modo que se tenha a maior eficiência utilizando o menor número de RSUs.

Este trabalho busca encontrar um conjunto de soluções eficientes, em redes veiculares V2I, que atendam a cobertura desejada com a menor quantidade de RSUs possíveis. Para realizar essa tarefa implementamos um algoritmo genético multiobjetivo baseado no NSGA-II (*Non-dominated Sorting Genetic Algorithm II*) [Deb et al., 2002]. O algoritmo tem como diferencial o uso de um operador de Cruzamento Geométrico, para explorar melhor o espaço de busca das soluções. Os resultados atingidos com a abordagem proposta superaram em todos os casos os resultados apresentados por [Kumrai et al., 2014].

Este artigo está dividido da seguinte forma: Seção 2 detalhará alguns trabalhos relacionados; a Seção 3 definirá formalmente o problema. A Seção 4 descreverá o algoritmo apresentado neste artigo. A Seção 5 mostra os parâmetros usados durante a simulação e discutirá os resutlados obtidos neste trabalho. Por fim, a Seção 6 tratará dos trabalhos futuros.

2. Trabalhos Relacionados

Pesquisadores têm estudado a alocação das RSUs em redes veiculares através de vários pontos de vista. O trabalho de [Rebai et al., 2012] apresenta um novo modelo de programação linear para resolver o problema de alocação das RSUs nas VANETs. O custo total da rede e a manutenção da conectividade entre veículos e RSUs são considerados durante a implantação. Em [Cavalcante et al., 2012] um algoritmo genético é apresentado para resolver o problema de cobertura máxima da área por parte das RSUs com limite de tempo de conexão. O trabalho de [Kumrai et al.,

https://proceedings.science/p/106913?lang=pt-br

2014] utiliza um algoritmo genético multiobjetivo para resolver o problema de alocação de RSUs utilizando o menor número de RSUs.

Modelos probabilísticos são usados para avaliar as localizações de cada RSU, pois eles têm um conhecimento prévio das rotas de cada veículo [Xie et al., 2013]. O trabalho de [Liu et al., 2013] utiliza cadeias de Markov homogêneas de tempo contínuo como estratégia para alocar as RSUs tendo como objetivo a transferência de arquivos. O trabalho de [Zheng et al., 2010] utiliza a probabilidade de contato. Essa métrica mede a fração de tempo que o veículo se conecta à infraestrutura, enquanto [Lee e Kim, 2010] propõem uma heurística que aloca as RSUs visando uma melhoria na conectividade entre veículos, reduzindo desconexões.

Existem algumas métricas para garantir a qualidade na distribuição de RSUs. A *Delta-Deployment* – $\Delta_{\rho_2}^{\rho_1}$ – garante que $\rho_2\%$ dos veículos tenham uma conexão com uma duração de pelo menos ρ_1 unidades de tempo [da Silva e Meira, 2015]. [Martins et al., 2017] propuseram uma abordagem multiobjetivo para resolver o problema de alocação das RSUs com o objetivo de minimizar o número de RSUs e maximizar o número de veículos aplicando a métrica $\Delta_{\rho_2}^{\rho_1}$. Outra métrica, o *Gamma-Deployment*, avalia a qualidade das unidades de comunicação e qualifica a consistência do número de contatos entre os veículos e as RSUs, com foco no tempo entre os contatos. Nessa métrica cada veículo não pode permanecer um tempo superior a τ segundos sem estar conectado a uma RSU, sendo esse pertencente à solução [Silva et al., 2016; Pereira et al., 2017].

O trabalho proposto difere dos demais porque possui um foco na cobertura da área pelas RSUs e na redução dos números de RSU implantados em uma abordagem multiobjetivo, que em um primeiro momento, independe do tráfego de veículos na área de interesse. Além disso, foi implementado um operador geométrico a fim de aumentar as soluções encontradas.

3. Caracterização do Problema

Para a primeira etapa deste trabalho tem-se o seguinte problema. Dada uma área de interesse, que pode ser discretizada em células iguais de tamanho X, formando um conjunto C de células, onde cada célula $c \in C$ pode ou não ser coberta pelas RSUs. Cada RSU tem um raio de cobertura r e pode ser posicionada em qualquer uma das células $c \in C$ da área. Uma célula c é considerada coberta se, e somente se, uma RSU estiver a uma distância de r da célula c. O problema multiobjetivo de cobertura de área e redução do número de RSUs pode ser definido como encontrar um conjunto de soluções eficientes S que atendam simultaneamente aos seguintes objetivos: 1) maximizar a área coberta e 2) minimizar o número de RSUs. Claramente, os objetivos são conflitantes, então cada solução $U \in S$ pode priorizar um objetivo em detrimento do outro, não tendo uma única solução ótima para o problema. Cada solução $U \in S$ é constituída por células do conjunto C onde serão alocadas as RSUs. Uma célula $c \in C$ é coberta por uma RSU alocada na célula $u \in U$ quando estiver parcial ou totalmente dentro do raio de ação r da RSU. Seja $F \subset C$ o conjunto de células através do qual há rodovias. Uma RSU pode ser implantada em qualquer uma das células em C, no entanto, para efeitos de cálculo de cobertura, serão contabilizadas apenas as células pertencentes ao conjunto F.

Nesta primeira etapa considerou-se dois objetivos durante a otimização. A primeira função objetivo chamada F_{cob} calcula as células por onde passam as rodovias e são cobertas pelas RSUs sendo que cada célula é contabilizada apenas uma vez. Uma célula é dita coberta por uma RSUs quando está totalmente ou parcialmente na área de atuação do dispositivo de comunicação. A segunda função objetivo chamada F_{num} calcula o número de RSUs que foram alocadas, e essa função deve ser minimizada. Dada uma solução U a área coberta é calculada da seguinte forma:

$$F_{cob} = \sum_{f \in F} g(f) \tag{1}$$

$$g(f) = \begin{cases} 1 & \text{se} \quad \exists u \in U \quad | \quad d_{(f,u)} \leq r \\ 0 & \text{caso contrário} \end{cases}$$

Onde $d_{(f,u)}$ é a distância euclidiana entre a RSU alocada na célula u e a célula f por onde passam as rodovias. Portanto, a função $g(f)$ assume valor 1 quando existe uma RSU, dentre as que foram alocadas na solução U, que cubra a célula f.

O algoritmo proposto está preparado para minimizar as funções objetivo, e para que ambos os objetivos sejam minimizados, a área descoberta é calculada na equação 2 na qual $TamRodovias$ é o número de células pelas quais a rodovia passa.

$$F_{descob} = TamRodovias - F_{cob} \tag{2}$$

O segundo objetivo é calculado da seguinte maneira:

$$F_{num} = |U| \tag{3}$$

Na segunda etapa deste trabalho se fez necessário simular o fluxo de veículos pela rede veicular. Para realizar tal tarefa foi calculado para cada veículo que transitará pela rede todo o seu trajeto assim como o tempo que ele permanecerá em cada célula. O tempo, em segundos, de permanência em cada célula segue uma distribuição uniforme no intervalo $(8, 12)$. Foi escolhido o intervalo $(8, 12)$ considerando uma velocidade média de $40km/h$ no qual o veículo irá percorrer aproximadamente $100m$. Considere V o conjunto de todos os veículos, $G_v \subset F$ o conjunto de células que descreve o percurso do veículo $v \in V$ e $Z_{v,g}$ o tempo que o veículo $v \in V$ permaneceu na célula $g \in G_v$. Seja $TotalPacotes$ o número total de pacotes enviados pelos veículos no período de tempo t de modo que cada veículo envia 1 pacote por segundo.

Na segunda etapa não foi considerado o número de RSUs alocadas e sim a função $F_{taxaSucesso}$ que consiste em calcular a taxa de pacotes recebidos por todas RSUs de uma solução. Dada uma solução U a taxa de pacotes entregues é calculada da seguinte maneira:

$$F_{taxaSucesso} = \frac{PacotesEntegues}{TotalPacotes} \tag{4}$$

$$PacotesEntegues = \sum_{u \in U} \sum_{g \in G_v} h(g,u) \times Z_{v,g} \quad \forall u \in U$$

$$h(g,u) = \begin{cases} 1 & \text{se} \quad d_{(g,u)} \leq r \\ 0 & \text{caso contrário} \end{cases}$$

4. Algoritmo Proposto

Nesta Seção é apresentada a estratégia proposta para a solução do problema de alocação das RSUs baseada no algoritmo multiobjetivo NSGA-II Deb et al. [2002]. O que difere o NSGA-II aqui utilizado do padrão são os operadores de cruzamento geométrico e de mutação que exploram propriedades do problema em questão.

O NSGA-II é um Algoritmo Genético(AG) e se enquadra na classe dos algoritmo evolutivos. Essa classe de algoritmos envolve uma determinada população que em sucessivas iterações (gerações), examina, de maneira inteligente, o espaço de soluções. Uma população consiste em vários indivíduos que, por sua vez, representam uma possível solução para o problema. Para realizar uma busca no espaço de soluções de uma maneira inteligente, um AG utiliza três operadores: (i)

https://proceedings.science/p/106913?lang=pt-br

operador de Seleção, responsável por selecionar os indivíduos para a próxima geração; (ii) operador de Cruzamento, responsável por gerar novos indivíduos (soluções); (iii) o operador de Mutação, responsável por manter a diversidade da população modificando parte da solução atual.

4.1. Indivíduos

No algoritmo proposto, cada célula recebe um identificador inteiro positivo e um indivíduo consiste em uma lista de inteiros. Esta lista indica em quais células as RSUs serão instaladas. A Tabela 1 exemplifica a representação de um indivíduo em que as RSUs serão alocadas nas células 4, 8, 15, 16, 23 e 42.

Tabela 1: EXEMPLO DE INDIVÍDUO

Indivíduo	4	8	15	16	23	42

4.2. Operador Mutação

O operador de mutação implementado pode agir de três formas: (i) substituição de uma RSU, (ii) remoção de uma RSU, (iii) inserção de uma RSU. A Tabela 2 exemplifica o caso de quando a célula onde está instalada uma RSU é substituída por outra.

Tabela 2: EXEMPLO DE MUTAÇÃO

Indivíduo Original	4	8	15	16	23	42
Indivíduo Modificado	4	98	15	16	23	42

4.3. Operador Cruzamento

Operadores geométricos foram apresentados por [Moraglio e Poli, 2005] como suporte geral para o desenvolvimento de algoritmos evolutivos. Utilizando uma definição de distância adequada é possível definir o conceito de mutação geométrica.

Um cruzamento geométrico pode ser implementado como uma sequência de mutações geométricas, que é realizada de tal forma que as soluções descendentes estão presentes no menor caminho (usando uma definição de distância adequada) que conecta os dois pais. Segundo [Martins, 2012] este tipo de tratamento pode ser usado como uma base para a elaboração de poderosos algoritmos evolutivos para diversos problemas.

Para este trabalho foi escolhido o operador geométrico chamado Cruzamento Real-Polarizado (CRP) que foi originalmente proposto para variáveis reais por [Takahashi et al., 2003]. [Martins et al., 2014] estenderam a definição para variáveis inteiras e essa definição será utilizada neste trabalho. Dados os vetores $\overrightarrow{A}$ e $\overrightarrow{B}$ representando dois pais, as soluções obtidas são geradas no segmento $\overrightarrow{A'B'}$ como podemos ver na Figura 1.

$$\overrightarrow{A'} = \overrightarrow{A} - 0.1 \cdot \overrightarrow{AB}$$
$$\overrightarrow{B'} = \overrightarrow{B} + 0.1 \cdot \overrightarrow{AB}$$
$$\overrightarrow{A'B'} = \overrightarrow{B'} - \overrightarrow{A'}$$

Para realizar a extrapolação do segmento AB, é necessário estabelecer a noção de distância entre duas soluções. Neste trabalho, a distância de Hamming [Hamming, 1950] foi escolhida por se encaixar muito bem na modelagem proposta neste trabalho. Inicialmente, a distância de Hamming foi definida entre duas *strings* de mesmo comprimento e consiste no número de posições nas

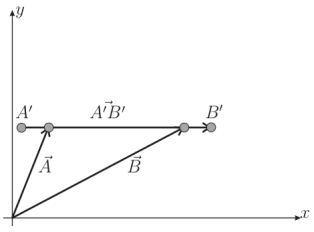


Figura 1: Exemplo de uma Extrapolação [Martins et al., 2014].

quais elas se diferem. Esse conceito foi aplicado na modelagem deste trabalho seguindo a seguinte definição: A distância, $dist(A, B)$, entre a solução A e B é definida como o número mínimo de RSUs que devem ser inseridas ou removidas em A de modo que A se torne igual à solução B.

Para realizar uma extrapolação de 1 movimento, por exemplo, em relação ao indivíduo A é criado um indivíduo A' onde a distância $dist(A, A') = 1$ e, para isso, basta inserir ou remover uma RSU de A. Um vetor Y_A é criado de forma que cada célula desse vetor contenha 0 se A' e B' forem iguais para o mesmo índice ou 1 caso contrário. Uma vez tendo Y_A, um inteiro p é sorteado seguindo uma distribuição quadrática com $0 \leq p < dist(A', B')$ e p posições diferentes de zero são escolhidas e são transformadas em posições nulas. Como p segue uma distribuição quadrática, tem-se uma polarização da geração de novos indivíduos favorecendo o pai de melhor valor da função objetivo. De um modo análogo, um vetor Y_B é criado, porém o inteiro p sorteado segue uma distribuição normal.

Portanto, no Cruzamento Real-Polarizado, o primeiro filho será gerado a partir do vetor Y_A, de modo que ele herdará do Pai A todas as posições nulas e do Pai B todas as posições não nulas. O segundo Filho será gerado de forma análoga usando o vetor Y_B. Para ilustrar o CRP, será utilizado um indivíduo modelado de forma diferente por razões didáticas. Neste exemplo, o indivíduo é representado por uma lista de 0's ou 1's, onde 0 significa que nenhuma RSU foi instalada naquela célula e 1 significa que há uma RSU instalada nessa célula. Tabela 3 mostra um exemplo de como o CRP é calculado.

Tabela 3: EXEMPLO DE CRUZAMENTO

A	1	0	1	1	0	1
B	0	0	0	1	1	0
A'	1	1	1	1	0	1
B'	0	0	0	1	0	1
Y	1	0	1	0	1	1
Y_A	0	0	1	0	0	0
Y_B	0	0	1	0	1	1
Filho 1	1	0	0	1	0	1
Filho 2	1	0	0	1	1	0

Para mostrar a eficiência do operador CRP, ele foi comparado ao operador de Cruzamento Uniforme. Os resultados são mostrados na Figura 2. Os pontos branco correspondem ao operador de Cruzamento Uniforme. Neste operador, cada gene do pai é escolhido seguindo uma distribuição uniforme como na segunda parte do CRP. Nele, observa-se que o operador CRP pode implantar um número menor de RSUs e diminuir a área descoberta, o que justifica a escolha do operador de

cruzamento.

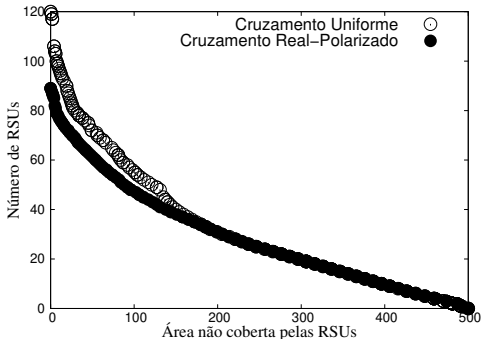


Figura 2: Efeito do Operador Cruzamento na População. Os círculos em preto representam as soluções obtidas quando pelo operador de Cruzamento Real-Polarizado. Os círculos em branco descrevem as soluções obtidas utilizando o operador de Cruzamento Uniforme.

4.4. Operador Seleção

O algoritmo apresentado neste trabalho por ser baseado no NSGA-II [Deb et al., 2002] utiliza o conceito de dominância e evolui uma população de tamanho fixo N. Considerando um problema de minimização, uma solução z^* domina a solução z se para $f_k(z^*) < f_k(z)$ para todas as funções objetivo f_k. Durante a execução do algoritmo, os indivíduos foram classificados como pertencentes a uma categoria denominada como frente. A primeira frente contém todas as soluções não dominadas e é chamada de Conjunto Pareto. A segunda frente contém as soluções não dominadas, não considerando as soluções da frente 1. Para calcular a terceira frente, excluí-se as soluções das frentes 1 e 2 e assim por diante, até que todos os indivíduos estejam em alguma frente. Assim, o número de frentes pode variar de acordo com a população [Deb et al., 2002].

A seleção dos indivíduos para a próxima geração, no NSGA-II, é realizada selecionando os indivíduos das fronteiras até atingir o tamanho N. Caso o número de indivíduos da fronteira ultrapasse o tamanho N da população os indivíduos com a maior Distância de Aglomeração (do inglês *Crowding Distance*) são escolhidos. Uma solução tem uma maior Distância de Aglomeração quando está mais distante dos dois indivíduos subsequentes pertencentes à mesma fronteira.

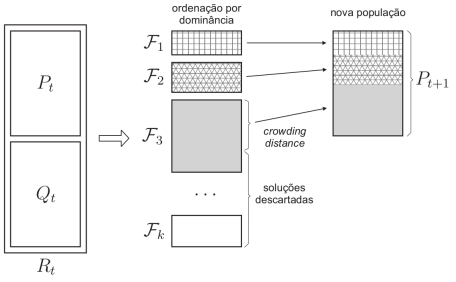


Figura 3: Processo de Seleção no NSGA-II [Martins, 2012]

A Figura 3 exemplifica o processo de seleção. O parâmetro P_t representa a população da qual os pais serão escolhidos e Q_t a população após aplicar os operadores de mutação, cruzamento e seleção em P_t na geração t.

O algoritmo 1 mostra uma visão geral do funcionamento do algoritmo apresentado neste artigo. O parâmetro $numgeracoes$ é um inteiro positivo que representa quantas gerações que a população será submetida.

Algoritmo 1: Alocação de RSUs

```
Input: Grid da área de interesse
Result: Conjunto S
Inicializa a População e Avalia os Indivíduos;
while n < numgeracoes do
    Classifica a População;
    Mutação e Cruzamento Real-Polarizado;
    Avaliação dos Indivíduos e Seleção;
    n = n + 1
end
```

5. Análise da Simulação

Nesta Seção será mostrado como as configurações da simulação foram realizadas e também a comparação dos resultados obtidos neste trabalho com os resultados de [Kumrai et al., 2014].

Para efeitos de comparação todos os parâmetros utilizados foram iguais aos de [Kumrai et al., 2014]. O raio de comunicação r da RSU foi definido em $250m$ e, no máximo, 100 RSUs podem ser alocadas na área de interesse. A área de interesse consiste em $5km \times 5km$ divididos em células de $100m \times 100m$. Utilizamos uma população com 100 indivíduos, uma taxa de cruzamento de $0,9$, uma taxa de mutação de $0,3$ e 15000 gerações.

5.1. Resultados

A Figura 4 mostra os resultados das soluções obtidas pelo algoritmo proposto e o algoritmo sugerido por [Kumrai et al., 2014]. O eixo x representa a área não coberta pelas RSUs e o eixo y representa o número de RSUs alocadas. Os círculos em branco foram obtidos aplicando o método proposto por [Kumrai et al., 2014], onde eles utilizaram o JMetal [Durillo e Nebro, 2011]. Os círculos em preto constituem o Pareto otimizado encontrado pelo algoritmo proposto. A Figura 4 mostra as soluções obtidas neste trabalho atingem uma maior cobertura utilizando um número menor de RSUs quando comparadas às soluções de [Kumrai et al., 2014].

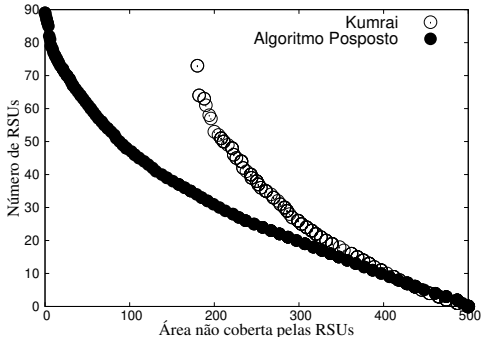


Figura 4: Comparação de Resultados. Os círculos em branco foram obtidos aplicando o método proposto por [Kumrai et al., 2014] nas configurações padrões do JMetal. Os círculos pretos constituem o Pareto otimizado encontrado pelo algoritmo apresentado neste trabalho.

https://proceedings.science/p/106913?lang=pt-br

Para comparar os resultados empregou-se a métrica denominada Hipervolume, que é comumente usada em problemas multiobjetivo [Zhang e Hansen, 2009; Deb, 2001]. Nesta métrica, as soluções de Pareto são usadas e o Hipervolume da região coberta entre os pontos das soluções e um ponto de referência W é calculado. Uma maneira simples de determinar esse ponto é utilizar os piores valores das funções objetivo, considerando todas as soluções a serem comparadas. De acordo com [Deb, 2001], um alto valor de Hipervolume significa que o método teve uma boa distribuição entre as soluções e uma boa convergência. A Figura 5 mostra um exemplo do Hipervolume no caso de duas funções objetivo f_1 e f_2. Neste caso o Hipervolume consiste em calcular a área do polígono da frente de Pareto tendo como referência o ponto W.

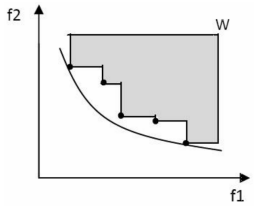
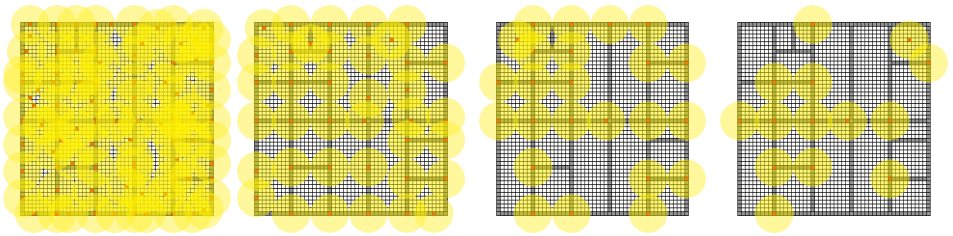


Figura 5: Exemplo de um Hipervolume para o caso de duas funções objetivos [AZUMA, 2011].

A solução encontrada pelo algoritmo proposto neste trabalho possui um Hipervolume igual a 85879, já a solução obtida por [Kumrai et al., 2014] possui um Hipervolume igual a 68181, sendo assim, a solução encontrado pelo algoritmo proposto é considerada uma solução melhor.

5.2. Exemplos de Soluções

Nesta Seção, serão apresentadas 4 soluções presentes no último conjunto de Pareto encontrado pelo algoritmo proposto neste trabalho.



(a) Solução com 100% da rodovia é coberta pelas RSUs.

(b) Solução com pelo menos 70% da rodovia é coberta pelas RSUs.

(c) Solução com pelo menos 50% da rodovia é coberta pelas RSUs.

(d) Solução com pelo menos 30% da rodovia é coberta pelas RSUs

Figura 6: As células em vermelho correspondem às posições onde as RSUs serão implantados e os círculos amarelos correspondem à área de cobertura das RSUs.

As Figuras 6(a), 6(b), 6(c) e 6(d), representam uma área discretizada em 50×50 células e os pontos cinzentos correspondem às rodovias, os vermelhos são as posições encontradas pelo algoritmo para alocar as RSUs e os círculos amarelos correspondem à área de cobertura das RSUs. Cada círculo amarelo representa a área de cobertura das RSUs.

A figura 6(a) mostra uma solução em que 100% das rodovias são cobertas por 89 RSUs. Observou-se que, para atingir 100% de cobertura, algumas RSUs foram implantadas fora da região correspondente às rodovias. Na Figura 6(b), tem-se uma solução que cobre pelo menos 70% das rodovias da área. Nesta solução, um menor número de RSUs é observado fora das células através

das quais passam as rodovias. As soluções mostradas na Figura 6(c) e 6(d) possuem pelo menos 50% e 30% de área coberta pela RSUs respectivamente. Analisando estes números, é evidente um comportamento do algoritmo de sempre tentar implantar as RSUs nas interseções das rodovias. Tal ação está de acordo com o que os autores esperavam, uma vez que as interseções tendem a ter mais rodovias próximas. Mesmo em soluções com menos RSUs instaladas, esse comportamento é preservado.

A Figura 7 mostra os resultados obtidos na segunda parte deste trabalho que consistem em analisar a taxa de pacotes recebidos pelas RSUs alocadas. No eixo x tem-se a área não coberta pelas RSUs e no eixo y a fração dos pacotes enviados pelos veículos que foram recebidos pelas RSUs. Observa-se que durante a simulação dos fluxos de veículos quase 100% dos pacotes enviados por todos os veículos são recebidos pelas RSUs alocadas. Não foram realizados testes variando o números de veículos por não afetar

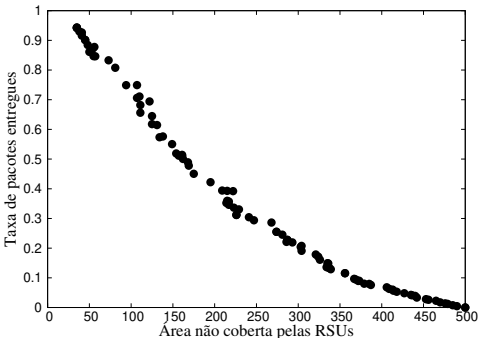


Figura 7: Resultados obtidos pelo algoritmo proposto quando se considera os pacotes entregues e a área não coberta pelas RSUs

6. Conclusão

Este trabalho trata o problema de alocação de unidades de comunicação em redes veiculares. Apresentado o problema, são indicadas duas abordagens para soluciona-lo. O problema consiste em dada uma área de interesse escolher posições nas quais as RSUs serão alocadas de modo que os veículos tenham a maior conectividade possível.

Ambas as abordagens utilizam um algoritmo multiobjetivos baseado no NSGA-II para buscar em quais posições da área de interesse serão alocadas as RSUs, procurando a melhor cobertura possível utilizando o menor número de RSUs. Uma inovação na implementação desse algoritmo foi o uso de operadores geométricos aplicados a redes veiculares. Os resultados ao aplicar esses operadores se mostraram melhores ao explorar o espaço de busca das soluções quando comparados com o trabalho de [Kumrai et al., 2014]. Foi mostrado que a heurística implementada, quando aplicada a primeira parte deste trabalho, supera todos os resultados obtidos por [Kumrai et al., 2014].

As soluções alcançadas na segunda parte deste trabalho onde se considera a taxa de pacotes entregues se mostraram eficientes, uma vez que, nas soluções com maiores coberturas, mais de 90% dos pacotes gerados pelos veículos foram recebidos pelas RSUs. Como trabalhos futuros, é possível adicionar ao modelo um gerenciamento de energia para cada RSU instalada, testar cenários mais realistas e implementar métodos de Busca Local.

Agradecimentos

Agradecimentos à CAPES, à FAPEMIG, ao CNPq e ao CEFETMG pela estrutura e apoio tecnológico e financeiro.

https://proceedings.science/p/106913?lang=pt-br

Referências

AZUMA, R. M. (2011). *Otimização multiobjetivo em problema de estoque e roteamento gerenciados pelo fornecedor. 2011. 121 f.* PhD thesis, Dissertação (Mestrado em Engenharia de Computação)-Programa de Pós-Graduação .

Blum, J. J., Eskandarian, A., e Hoffman, L. J. (2004). Challenges of intervehicle ad hoc networks. *IEEE transactions on intelligent transportation systems*, 5(4):347–351.

Cavalcante, E. S., Aquino, A. L., Pappa, G. L., e Loureiro, A. A. (2012). Roadside unit deployment for information dissemination in a vanet: An evolutionary approach. In *Proceedings of the 14th annual conference companion on Genetic and evolutionary computation*, p. 27–34. ACM.

Cunha, F., Villas, L., Boukerche, A., Maia, G., Viana, A., Mini, R. A., e Loureiro, A. A. (2016). Data communication in vanets: Protocols, applications and challenges. *Ad Hoc Networks*, 44: 90–103.

da Silva, C. M. e Meira, W. (2015). Evaluating the performance of heterogeneous vehicular networks. In *2015 IEEE 82nd Vehicular Technology Conference (VTC2015-Fall)*, p. 1–5. IEEE.

Deb, K. (2001). Multi-objective optimization using evolutionary algorithms wiley. *Chichester, UK*.

Deb, K., Pratap, A., Agarwal, S., e Meyarivan, T. (2002). A fast and elitist multiobjective genetic algorithm: Nsga-ii. *IEEE transactions on evolutionary computation*, 6(2):182–197.

Durillo, J. J. e Nebro, A. J. (2011). jmetal: A java framework for multi-objective optimization. *Advances in Engineering Software*, 42(10):760–771.

Hamming, R. W. (1950). Error detecting and error correcting codes. *Bell System technical journal*, 29(2):147–160.

Kumrai, T., Ota, K., Dong, M., e Champrasert, P. (2014). Rsu placement optimization in vehicular participatory sensing networks. In *2014 IEEE Conference on Computer Communications Workshops (INFOCOM WKSHPS)*, p. 207–208. IEEE.

Lee, J. e Kim, C. M. (2010). A roadside unit placement scheme for vehicular telematics networks. In *Advances in computer science and information technology*, p. 196–202. Springer.

Liu, Y., Niu, J., Ma, J., e Wang, W. (2013). File downloading oriented roadside units deployment for vehicular networks. *Journal of Systems Architecture*, 59(10):938–946.

Martins, F. V., Carrano, E. G., Wanner, E. F., Takahashi, R. H., Mateus, G. R., e Nakamura, F. G. (2014). On a vector space representation in genetic algorithms for sensor scheduling in wireless sensor networks. *Evolutionary computation*, 22(3):361–403.

Martins, F. V. C. (2012). Operadores geométricos para otimizacao dinâmica com aplicacao ao problema de cobertura e conectividade em redes de sensores sem fio nao-hierárquicas. 190 f.

Martins, F. V. C., Sarubbi, J. F., e Wanner, E. F. (2017). A multiobjective strategy to allocate roadside units in a vehicular network with guaranteed levels of service. In *International Conference on Evolutionary Multi-Criterion Optimization*, p. 120–134. Springer.

https://proceedings.science/p/106913?lang=pt-br

Moraglio, A. e Poli, R. (2005). Topological crossover for the permutation representation. In *Proceedings of the 7th annual workshop on Genetic and evolutionary computation*, p. 332–338. ACM.

Ott, J. e Kutscher, D. (2004). Drive-thru internet: Ieee 802.11 b for"automobile"users. In *IEEE INFOCOM 2004*, volume 1. IEEE.

Panayappan, R., Trivedi, J. M., Studer, A., e Perrig, A. (2007). Vanet-based approach for parking space availability. In *Proceedings of the fourth ACM international workshop on Vehicular ad hoc networks*, p. 75–76. ACM.

Pereira, L. A., Sarubbi, J. F., Pitangui, C. G., e Silva, C. M. (2017). Planejando a infraestrutura de comunicação para a distribuição de mídias em tempo real para véıculos. In *Anais do XXXV Simpósio Brasileiro de Redes de Computadores e Sistemas Distribuídos*. SBC.

Qureshi, K. N., Bashir, F., e Abdullah, A. H. (2017). Real time traffic density aware road based forwarding method for vehicular ad hoc networks. In *2017 10th IFIP Wireless and Mobile Networking Conference (WMNC)*, p. 1–6. IEEE.

Rebai, M., Khoukhi, L., Snoussi, H., e Hnaien, F. (2012). Optimal placement in hybrid vanets-sensors networks. In *2012 Wireless Advanced (WiAd)*, p. 54–57. IEEE.

Reis, A. B., Sargento, S., e Tonguz, O. K. (2011). On the performance of sparse vehicular networks with road side units. In *2011 IEEE 73rd Vehicular Technology Conference (VTC Spring)*, p. 1–5. IEEE.

Silva, C. M., Guidoni, D. L., Souza, F. S., Pitangui, C. G., Sarubbi, J. F., e Pitsillides, A. (2016). Gamma deployment: Designing the communication infrastructure in vehicular networks assuring guarantees on the v2i inter-contact time. In *2016 IEEE 13th International Conference on Mobile Ad Hoc and Sensor Systems (MASS)*, p. 263–271. IEEE.

Takahashi, R. H., Vasconcelos, J., Ramírez, J. A., e Krahenbuhl, L. (2003). A multiobjective methodology for evaluating genetic operators. *IEEE Transactions on Magnetics*, 39(3):1321–1324.

Wu, Y., Zhu, Y., e Li, B. (2012). Infrastructure-assisted routing in vehicular networks. In *2012 Proceedings IEEE INFOCOM*, p. 1485–1493. IEEE.

Xie, B., Xia, G., Chen, Y., e Xu, M. (2013). Roadside infrastructure placement for information dissemination in urban its based on a probabilistic model. In *IFIP International Conference on Network and Parallel Computing*, p. 322–331. Springer.

Zaldivar, J., Calafate, C. T., Cano, J. C., e Manzoni, P. (2011). Providing accident detection in vehicular networks through obd-ii devices and android-based smartphones. In *2011 IEEE 36th Conference on Local Computer Networks*, p. 813–819. IEEE.

Zhang, W. e Hansen, K. M. (2009). An evaluation of the nsga-ii and mocell genetic algorithms for self-management planning in a pervasive service middleware. In *2009 14th IEEE International Conference on Engineering of Complex Computer Systems*, p. 192–201. IEEE.

Zheng, Z., Lu, Z., Sinha, P., e Kumar, S. (2010). Maximizing the contact opportunity for vehicular internet access. In *2010 Proceedings IEEE INFOCOM*, p. 1–9. IEEE.

https://proceedings.science/p/106913?lang=pt-br