CENTRO FEDERAL DE EDUCAÇÃO TECNOLÓGICA DE MINAS GERAIS
PROGRAMA DE PÓS-GRADUAÇÃO EM MODELAGEM MATEMÁTICA E COMPUTACIONAL

HEURÍSTICA PARA IMPLANTAÇÃO DE UNIDADES DE COMUNICAÇÃO EM REDES VEICULARES

THIAGO DA SILVA CORREIA

Orientador: Flávio Vinícius Cruzeiro Martins
Centro Federal de Educação Tecnológica de Minas Gerais

Coorientador: João Fernando Machry Sarubbi
Centro Federal de Educação Tecnológica de Minas Gerais

BELO HORIZONTE
FEVEREIRO DE 2019

THIAGO DA SILVA CORREIA

HEURÍSTICA PARA IMPLANTAÇÃO DE UNIDADES DE COMUNICAÇÃO EM REDES VEICULARES

Dissertação apresentada ao Programa de Pós-graduação em Modelagem Matemática e Computacional do Centro Federal de Educação Tecnológica de Minas Gerais, como requisito parcial para a obtenção do título de Mestre em Modelagem Matemática e Computacional.

Área de concentração: Modelagem Matemática e Computacional

Linha de pesquisa: Sistemas Inteligentes

Orientador: Flávio Vinícius Cruzeiro Martins
Centro Federal de Educação Tecnológica de Minas Gerais

Coorientador: João Fernando Machry Sarubbi
Centro Federal de Educação Tecnológica de Minas Gerais

CENTRO FEDERAL DE EDUCAÇÃO TECNOLÓGICA DE MINAS GERAIS
PROGRAMA DE PÓS-GRADUAÇÃO EM MODELAGEM MATEMÁTICA E COMPUTACIONAL
BELO HORIZONTE
FEVEREIRO DE 2019

Agradecimentos

A Deus que esteve ao meu lado e me deu força, ânimo e crença para não desistir e continuar lutando por este meu sonho e objetivo de vida. A Ele eu devo minha gratidão.

À minha mãe, Andreia, por todo carinho, amor e dedicação que sempre me proporcionou. Ao meu pai, Marco Antônio, que me ensinou importantes valores de vida. Agradeço também aos meus avós Air e Maria das Graças por todo amor e apoio. A minha namorada Fabíola, por todo carinho, atenção e incentivos incondicionais.

Um agradecimentos a todos os bons professores que tive no CEFET-MG, em especial os professores Flávio Cruzeiro e João Sarubbi. Em seus papéis de orientadores, tiveram bastante paciência e me guiaram sempre pelo caminhos certos.

Agradeço a CAPES, FAPEMIG e ao CEFET-MG por todo o auxílio estrutural e financeiro.

Resumo

O estudo de redes veiculares (VANETs, *Vehicular Ad Hoc Networks*) tem recebido uma importante atenção nos últimos anos devido a incorporação de diversas tecnologias nos veículos automotores. Neste trabalho iremos resolver o problema de alocação das unidades de comunicação (RSUs, do inglês *Roadside Units*). Para realizar tal tarefa iremos utilizar um algoritmo evolucionário multiobjetivo baseado no método NSGA-II tendo como objetivos maximizar a área coberta pelas RSUs utilizando o menor número de RSUs possível. Para alcançar esses objetivos, duas abordagens serão aplicada. A primeira abordagem considera a área coberta pelas RSUs e o número de RSUs utilizadas. Já na segunda abordagem é levado em consideração a taxa de pacotes recebidos pelas RSUs. O algoritmo proposto neste trabalho utiliza operadores geométricos projetados especificamente para esse tipo de problema e uma busca local foi implementada para obter melhores resultados. Além disso o algoritmo proposto foi comparado ao da literatura atingindo melhores resultados em todos os casos testados.

Palavras-chave: Redes Veiculares. Algoritmo Genético. Otimização MultiObjetivo. NSGA-II.

Abstract

The study of vehicle networks (VANETs - Vehicular Ad Hoc Networks) has received important attention in recent years due to the incorporation of several technologies in motor vehicles. In this paper, we will solve the problem of allocation of communication units (RSUs). To accomplish this task we will use an evolutionary multiobjective algorithm based on the NSGA-II method, aiming to maximize the area covered by the RSUs using the least number of RSUs possible. To achieve these goals, two approaches will be applied. The first approach considers the area covered by the RSUs and the number of RSUs used. In the second approach, the packet rate received by RSUs is taken into account. The algorithm proposed in this work uses geometric operators designed specifically for this type of problem and a local search was implemented for better results. In addition, the proposed algorithm was compared to that of the literature achieving better results in all cases tested.

Keywords: Genetic Algorithm, NSGA-II, Vehicular Networks, multiobjective optimization.

Lista de Figuras

Figura 1 – Exemplo de Rede Veicular. 2
Figura 2 – Exemplo de alocação e estado de ativação das RSUs. 4
Figura 3 – Exemplo de dominância para o caso de duas funções objetivos. 12
Figura 4 – Representação da malha viária em células 15
Figura 5 – Exemplo do Cruzamento Real-Polarizado 19
Figura 6 – Função de distribuição quadrática 19
Figura 7 – Conceito do Cálculo realizado pelo Operador de Diversidade 23
Figura 8 – Operador Seleção 24
Figura 9 – Exemplo de um Hipervolume para o caso de duas funções objetivos. . . 25
Figura 10 – Divisão da área de interesse 26
Figura 11 – Exemplo do percurso dos veículos. 27
Figura 12 – Influência da taxa de mutação na convergência do algoritmo. 29
Figura 13 – Influência da busca bocal no algoritmo 29
Figura 14 – Efeito do Operador Cruzamento na População. Os círculos em preto representam as soluções obtidas quando pelo operador de Cruzamento Uniforme. Os círculos em branco descrevem as soluções obtidas utilizando o operador de Cruzamento Real-Polarizado. 30
Figura 15 – Comparação dos métodos proposto neste trabalho com o trabalho de Kumrai et al. (2014) 31
Figura 16 – Solução com 100% das rodovias é coberta pelas RSUs. 32
Figura 17 – Solução com pelo menos 70% das rodovias é coberta pelas RSUs. . . . 32
Figura 18 – Solução com pelo menos 50% das rodovias é coberta pelas RSUs. . . . 32
Figura 19 – Solução com pelo menos 30% das rodovias é coberta pelas RSUs. . . . 33
Figura 20 – Comparação dos resultados obtido pelo algoritmo exato e pelo algoritmo genético. 34
Figura 21 – Resultados obtidos pelo algoritmo proposto quando se considera os pacotes entregues e a área não coberta pelas RSUs 35
Figura 22 – Distribuição dos pontos de partida dos veículos pelas rodovias 35
Figura 23 – Células por onde os veículos transitaram. 36

Lista de Tabelas

Tabela 1 – Principais tipos de Representação 9
Tabela 2 – Exemplos de indivíduos 18
Tabela 3 – Exemplo de uma Mutação 18
Tabela 4 – Exemplo de um Cruzamento 20

Lista de Algoritmos

Algoritmo 1 – Estrutura Genérica de um Algoritmo Genético 10

Algoritmo 2 – Fast Non-Dominated Sorting 22

Algoritmo 3 – Crowding Distance 23

Lista de Abreviaturas e Siglas

AGs	Algoritmos Genéticos
CRP	Cruzamento Real-Polarizado
NSGA-II	*Non-dominated Sorting Genetic Algorithm II*
RSUs	*Roadside Units*
VANET	*Vehicular Ad Hoc Networks*
V2I	Vehicle-to-Infrastructure
V2V	*Vehicle-to-Vehicle*

Sumário

1 – Introdução **1**
1.1 Objetivo 4

2 – Trabalhos Relacionados **5**

3 – Fundamentação Teórica **8**
3.1 Algoritmos Genéticos 8
3.2 Otimização Multiobjetivo 11
3.3 NSGA-II 13

4 – Metodologia **14**
4.1 Construção do Modelo 14
4.1.1 Caracterização do Problema 14
4.1.2 Modelo Matemático 17
4.2 Algoritmo Proposto 17
4.2.1 Implementação do NSGA-II 20
4.2.2 Busca Local 24
4.2.3 Hipervolume 25
4.3 Coleta e tratamento de dados 25
4.3.1 Simulação do Tráfego na rede 25

5 – Resultados **28**
5.1 Parâmetros do Algoritmo 28
5.2 Influência dos operadores genéticos e da Busca Local 28
5.3 Área coberta e pacotes de dados gerados 30

6 – Conclusão **37**
6.1 Trabalhos Futuros 37

Referências **38**

Capítulo 1

Introdução

Devido ao crescimento das cidades e ao aumento do tráfego de veículos, as pessoas passam mais tempo em seus meios de transporte. De acordo com Phillips (2001) a média de tempo gasto por um europeu dentro de um veículo em 1 ano é de 274 horas, e esse valor aumenta para 541 horas, quando se considera um americano. Com a modernização da internet móvel e o surgimento de diversos aplicativos as pessoas querem estar a todo momento conectadas a tudo e a todos.

Os sistemas de comunicação entre veículos constituem as chamadas redes veiculares (VANETs, do inglês *Vehicular Ad Hoc Networks*) e o estudo dessas redes têm recebido uma importante atenção nesses últimos anos(EZE; ZHANG; LIU, 2014). A principal razão são os veículos automotores que vêm incorporando diversas tecnologias que melhoram a experiência de dirigir. Um exemplo dessas tecnologias são os sensores capazes de detectar e alertar ao condutor sobre a presença de pedestres e de outros veículos. No entanto, essas tecnologias são limitadas à interação entre condutor e veículo, sendo a integração desses sensores por meio de um sistema de comunicação que possibilite o compartilhamento de informações desses diversos veículos um passo muito importante.

Redes veiculares podem fornecer um acesso móvel aos veículos com alta performance e a um baixo custo (OTT; KUTSCHER, 2004). Tais redes vêm desempenhando um importante papel sob a ótica de Sistemas Inteligentes de Transportes, sendo responsável por uma comunicação eficiente para controle de tráfego, segurança veicular e aplicações de entretenimento (AISSAOUI et al., 2014; ALVES et al., 2009; ZEADALLY et al., 2012).

As redes veiculares se diferenciam das demais redes sem fio principalmente pelas características de seus nodos que são formados por caminhões, carros, ônibus, pessoas e etc. Esses nodos, apresentam uma mobilidade elevada e limitada apenas pela topologia das estradas.

As *VANETs* são redes móveis onde são estabelecidas conexões intra-veículos V2V(*Vehicle-*

to-Vehicle), ou entre veículos e as infraestruturas denominadas *Roadside Units* (RSUs) que recebe o nome de V2I (*Vehicle-to-Infrastructure*) e, por fim, conexões híbridas que mesclam os dois tipos de conexões (BLUM; ESKANDARIAN; HOFFMAN, 2004). A figura 1 ilustra esses tipos de redes.

Figura 1 – Exemplo de Rede Veicular.

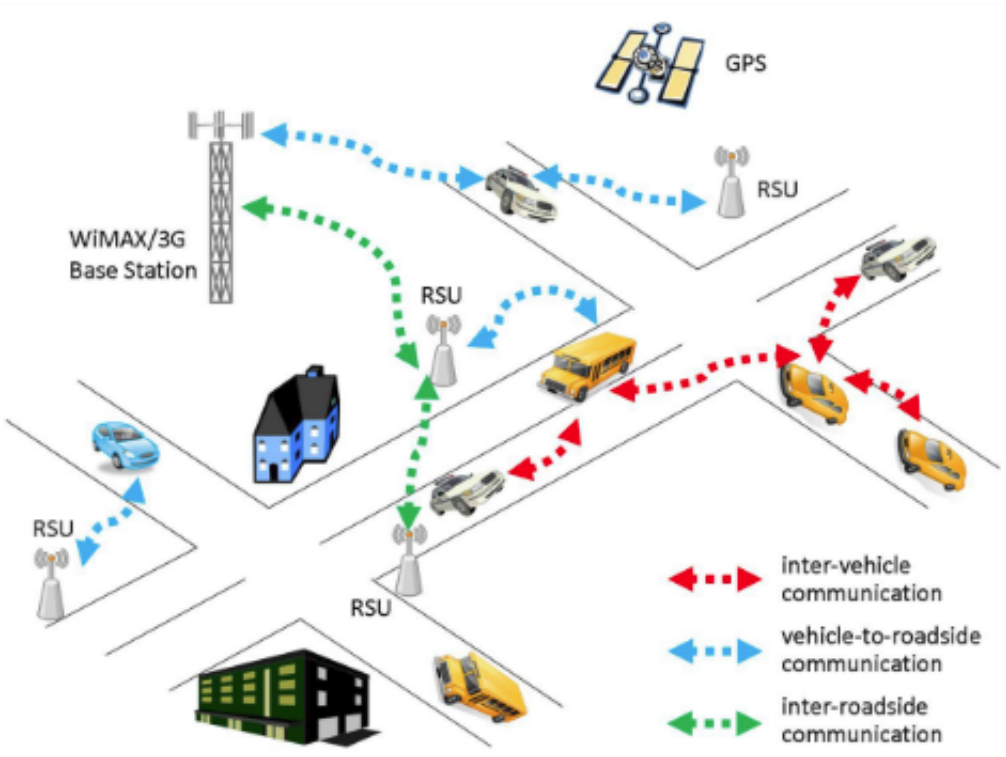

Fonte: (SARUBBI et al., 2017)

Nas redes V2V os veículos se conectam diretamente uns com os outros não havendo qualquer tipo de infraestrutura. Nas redes V2I, por sua vez, a conexão é realizada entre as RSUs e os veículos e por isso se faz necessária a instalação das RSUs nas estradas. Já a rede híbrida os dois tipos de conexões são possíveis.

Embora as redes V2V não necessitem de uma infraestrutura para funcionar, o que as tornam mais baratas, sua maior desvantagem é que em ambientes com um número reduzido de nós –veículos – podem se tornar altamente ineficientes. Já as redes V2I se tornam mais caras devido a necessidade de instalar as unidades de comunicação, no entanto, estudos mostram que esse tipo de rede pode aumentar de forma significativa a eficiência da rede veicular (REIS; SARGENTO; TONGUZ, 2011; WU; ZHU; LI, 2012). Portanto, temos um impasse entre reduzir os custos da instalação das RSUs e garantir a eficiência da rede

veicular distribuindo as RSUs. Nesse caso, torna-se necessário saber o local estratégico onde as RSUs devem ser instaladas diminuindo assim os custos e aumentando a eficiência da rede veicular.

Diante disso, resolver o problema de alocação de RSUs consiste em resolver o problema de localização de facilidades. Originalmente proposto por Weber (1909), o problema de localização de facilidade baseava-se em posicionar a facilidade no plano de modo a minimizar a soma de todas as distâncias entre a facilidade e os pontos de demanda. A localização de facilidades é um aspecto importante no planejamento estratégicos da iniciativa pública ou privada. Localizar uma facilidade envolve tomar decisões de localização, por exemplo, de hospitais, escolas, armazéns e centro de distribuições. Uma facilidade, no problema de alocação de RSUs, é representada por uma RSU enquanto a demanda a ser atendida é representada pela área de interesse coberta pelas RSUs.

Alguns estudos, sobre alocação de RSUs, têm como foco a minimização do custo de instalação das RSUs, tendo como restrição a área da área de interesse a ser coberta. Rebai et al. (2012) propuseram um novo modelo de programação linear para resolver o problema de alocação de RSUs em VANETs. O custo total da rede e a manutenção da conectividade entre os veículos e as RSUs são considerados durante a alocação. Em outro trabalho, um algoritmo genético é apresentado para resolver o problema de máxima cobertura da área de interesse por partes das RSUs com limite de tempo de conexão (CAVALCANTE et al., 2012).De todos os trabalhos pesquisados, apenas o de Ota et al. (2017) considera o consumo de energia das RSUs alocadas na solução do problema, porém não é especificado para qual período de tempo.Os autores simularam o consumo de energia da rede com todas as RSUs ligadas e posteriormente otimizaram o consumo de energia considerando a mesma janela de tempo.

A disposição espacial de veículos segue uma distribuição não uniforme e pode variar no tempo dependendo do dia, hora e localização sendo possível obter uma aproximação da distribuição de carros nas regiões de interesse a partir de uma coleta de dados durante um certo período (WU et al., 2012; KHABAZIAN; ALI, 2007). Para analisar esse cenário foi realizada uma simulação envolvendo veículos onde cada um dos veículos emite 1 pacote de dados por segundo e foi contabilizado a porcentagem de dados recebidos pelas RSUs.

A Figura 2 exemplifica um dos possíveis cenários que a alocação e gerenciamento das RSUs podem apresentar. Cada RSUs possui um estado de ativação, s, e uma posição, (x, y), que são representadas pela tupla (s, x, y).

Figura 2 – Exemplo de alocação e estado de ativação das RSUs.

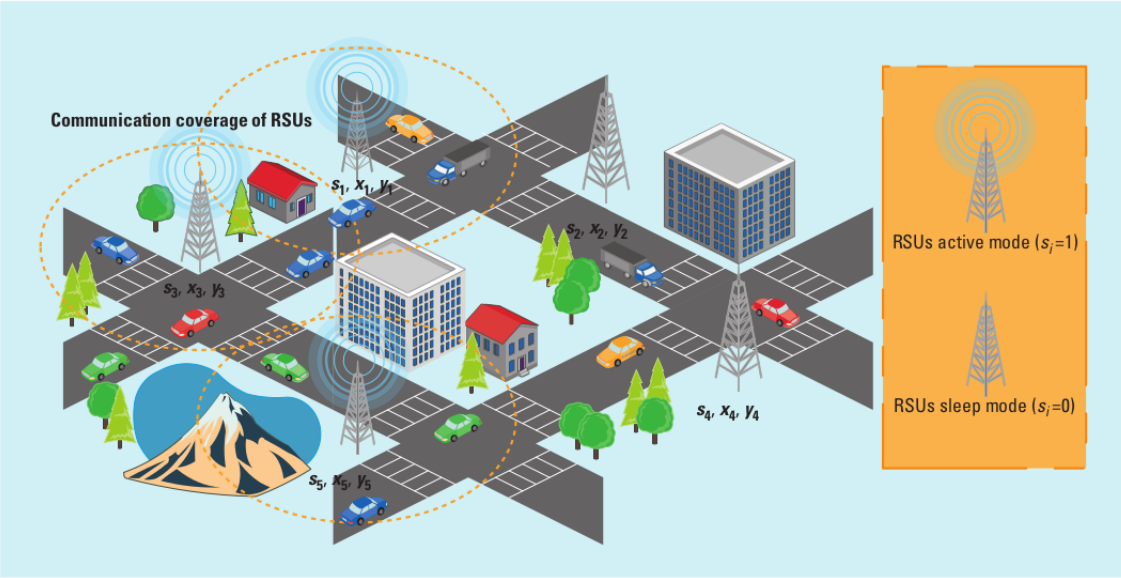

Fonte: (OTA et al., 2017)

Este trabalho busca, em um primeiro momento, encontrar um conjunto de soluções eficientes, em redes veiculares V2I, que atendam a cobertura desejada com a menor quantidade de RSUs possíveis. Em um segundo momento este trabalho visa encontrar um conjunto de soluções eficientes que atendam a cobertura desejada de modo que o fluxo de informação na rede seja o maior possível. Para realizar essa tarefa foi implementado um algoritmo genético multiobjetivo baseado no NSGA-II (*Non-dominated Sorting Genetic Algorithm II*) (DEB et al., 2002). O algoritmo 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).

1.1 Objetivo

Este trabalho está dividindo em duas etapas. A primeira etapa tem como objetivo elaborar uma heurística para alocar unidades de comunicação em uma região de interesse utilizando o menor número de unidade de comunicação possível. A segunda etapa consiste em alocar as unidades de comunicação considerando a transmissão de dados pela rede veicular. Para cumprir esses objetivos será adotada uma abordagem multiobjetivo que, em um primeiro momento, tem como objetivo minimizar o número de RSUs alocadas e maximizar a área de cobertura das RSUs e, em um segundo momento, tem como objetivo maximizar o número de pacotes recebidos pelas RSUs e maximizar a área de cobertura das unidades de comunicação.

Capítulo 2

Trabalhos Relacionados

Na literatura existem diversas estratégias para alocação de RSUs em redes veiculares. Zheng et al. (2010) utiliza a probabilidade de contato. Essa métrica mensura a fração de tempo da conexão entre o veículo com a infraestrutura, ao passo que Lee e Kim (2010) propuseram uma heurística que aloca as RSUs com o objetivo de melhorar a conectividade entre os veículos reduzindo as desconexões.

Xie et al. (2013) abordam como estratégia para alocação das RSUs o conhecimento prévio das rotas dos veículos. Com base no históricos do fluxo de carros, os autores utilizam um modelo probabilístico para inferir as localizações de cada RSUs. Chi et al. (2013) propuseram distribuir as unidades de comunicação da forma tão equilibradamente quanto possível. Liu et al. (2013) utilizam cadeia de Markov homogênea de tempo contínuo como estratégia de alocação de RSUs para transferência de arquivo em redes veiculares. Além de instalar as RSUs em locais estáticos o trabalho de Kim et al. (2017) considera aloca-las em veículos de transporte público e ou de propriedade do governo local da cidade.

Sob a ótica da geometria Aslam, Amjad e Zou (2012) usam Programação Inteira Binária para o problema de alocação das infraestrutura. Já Cheng et al. (2013) propuseram uma heurística para resolver o prolema da máxima cobertura da área de interesse.

Kumrai et al. (2014) utilizam algoritmos genéticos para solucionar o problema de alocação das infraestruturas tendo como objetivo aumentar a área coberta pelas RSUs. Em Ota et al. (2017) também foi utilizado Algoritmo genéticos, porém com dois objetivos que são: maximizar a área de cobertura e diminuir o consumo de energia. O trabalho de Faraj et al. (2017) propõem uma heurística baseada no NSGA-II para resolver o problema de alocação das RSUs em redes veiculares considerando o temo de contato entre cada veículo. No trabalho de Massobrio et al. (2015) também é proposto um algoritmo genético, que utiliza dados reais da cidade Málaga na Espanha, onde é proposto um novo método para se manter a qualidade de atendimento dos veículos pelas RSUs considerando o número de

veículos, a suas velocidades e a área de interesse coberta.

Algumas métricas existem para garantir a qualidade na distribuição das antenas. Silva e Meira (2015) apresentam a Deposição $\Delta_{\rho 2}^{\rho 1}$ a qual garante que $\rho_2\%$ dos veículos tenham uma conexão com uma duração de no mínimo ρ_1 unidades de tempo. Já Silva et al. (2016) porpuseram uma métrica denominada *Deposição Gamma*, Γ_{ρ}^{τ} , para avaliar a qualidade das unidades de comunicação e qualificar a consistência do número de contatos entre os veículos e as antenas, tendo como foco o tempo entre contatos. Cada veículo não pode ficar mais que τ segundos sem estar conectado a uma RSUs caso esse veículo pertença ao um dos ρ veículos pertencentes a solução.

O trabalho de Wang et al. (2014) utiliza técnicas de clusterização como abordagem para resolver o problema de alocação das RSUs. A distribuição espacial e temporal dos veículos é utilizada para determinar quais *clusters* possuem maior influência e os elegem como locais para se alocar as RSUs.

Para manter a cobertura das área de interesse dentro dos parâmetros desejados utilizando o menor números de RSUs Cheng et al. (2014) propuseram um modelagem baseada em grafos não-direcionados e reduziram o problema de alocação das RSUs a uma versão problema da mochila restrita e aplicaram decomposição Lagrangiana como método para resolver o problema.

Sob o prisma do consumo de energia, as *redes de sensores* se destacam por possuir uma forte restrição quanto ao consumo de energia, pois depende do uso de uma bateria. Essas redes se diferem das demais redes em vários aspectos: possuem um grande número de nodos – sensores – distribuídos, possuem restrições de processamento, de energia e dispõem de mecanismos para auto-configuração e adaptação devido a problemas que podem ocorrer como perda de nodos e falhas na comunicação (RUIZ et al., 2004). Esses sensores podem ser dispostos em *clusters* (grupos) onde, pelo menos, um dos sensores deve ser capaz de perceber um evento em seu raio de atuação, processá-lo e decidir se deve ou não fazer a propagação dessa informação para os outros sensores. Nesse tipo de rede os sensores se comunicam diretamente entre si como ocorre em redes veiculares V2V (LOUREIRO et al., 2003).

Camilo et al. (2006) utiliza pequenos pacotes de dados para descobrir rotas energeticamente eficientes utilizando o algoritmo Colônia de Formigas para executar de encontrar o melhor caminho para a propagação da informação. Zhang et al. (2015) obtiveram bons resultados utilizando técnicas de aproximação linear para resolver de alocação das RSUs considerando o consumo de energia e o número de RSUs alocadas.

O trabalho proposto difere dos demais, pois seu foco consiste na cobertura da área de

interesse pelas RSUs e na redução dos números de RSU implantadas em uma abordagem multiobjetivo independentemente do tráfego de veículos na área de interesse. Além disso, foi implementado um operador geométrico e uma busca local para solucionar o problema de implantação de RSUs.

Capítulo 3

Fundamentação Teórica

Nesta seção apresentaremos o conceito de otimização, problemas multiobjetivos, assim como a descrição de Algoritmo Genéticos e do NSGA-II.

3.1 Algoritmos Genéticos

Os Algoritmos Genéticos (AGs), são métodos de busca probabilísticos inspirados pela biologia evolutiva como genética e seleção natural (HOLLAND, 1975).

A evolução biológica apresentada por C. Darwin lança mão a dois métodos: Seleção e a variabilidade genética. A seleção natural assegura que os indivíduos mais adaptados ao meio tenham maior probabilidade de sobreviver, e como consequência, a possibilidade de gerar mais filhos perpetuando assim seus genes ao longo das gerações. Um mecanismo que gera uma certa variabilidade genética assegura que os filhos sejam diferentes de seus pais (GASPAR-CUNHA; TAKAHASHI; ANTUNES, 2012). Esses processo podem ou não gerar indivíduos capazes de sobreviver ao meio ambiente.

Esses processos servem de inspiração para a construção de algoritmos que buscam a melhor solução para um determinado problema varrendo, de forma inteligente, o espaço de busca. Essa busca é realizada evoluindo a população ao longo de sucessivas iterações (gerações). Uma população é constituída por vários indivíduos que por ser vez representam uma possível solução para o problema. Cada indivíduo é composto por genes que representam as variáveis do problema (PACHECO et al., 1999).

Há duas escolhas importantes que se faz necessárias quando se decide usar um AGs para resolver o problemas:

• Definição da função *fitness*, que forneça para cada indivíduo uma media de aptidão que irá conduzir o processo de busca.
• O processo de codificação dos genes, onde a representação das variáveis do problema

define a estrutura dos genes a serem computados pelo algoritmo.

Os principais tipos de representação são:

Representação	**Problemas**
Binária	Numéricos, Inteiros
Números Reais	Numéricos
Permutação de Símbolos	Baseados em Ordem
Símbolos Repetidos	Grupamento

Fonte: (PACHECO et al., 1999)

Tabela 1 – PRINCIPAIS TIPOS DE REPRESENTAÇÃO

O processo de evolução, ilustrado no algoritmo 1, se inicia com a criação da população inicial. A partir de um processo de seleção baseado na função *fitness* de cada indivíduo, são escolhidos indivíduos para a fase de reprodução que cria novos indivíduos utilizando-se dos operadores genéticos. Portanto a *fitness* do indivíduo determina seu grau de sobrevivência,e assim, a probabilidade dos seus genes fazerem parte das próximas gerações.

Para se ter eficiência no processo de busca é fundamental a existência uma diversidade na população assim como o surgimento de novos indivíduos. Os operadores genéticos desempenham um papel importante nessa tarefa. Basicamente um AG possui três operadores genéticos: seleção, mutação e cruzamento. O operador seleção é encarregador de escolher na população os melhores indivíduos para se formar população da próxima geração. O operador cruzamento é considerado o principal responsável pelo processo busca local realizado por um AG. Pares de genitores são selecionados aleatoriamente na população e novos indivíduos são gerados a partir da troca de material genético. Portanto os descendentes são diferentes dos pais, mas possuem características genéticas de ambos. Já o operador mutação é responsável por manter a diversidade da população além de permitir que sejam introduzidos novos genes nos indivíduos. É um processo aleatório e atua trocando um gene por um outro qualquer seguindo uma taxa probabilidade. (GASPAR-CUNHA; TAKAHASHI; ANTUNES, 2012; PACHECO et al., 1999)

Ao longo das gerações a qualidade média dos indivíduos tendem a aumentar, de maneira mais acentuada no in início da execução do algoritmo, e tem tendência a diminuir com o tempo. O desaparecimento dos melhores indivíduos está atrelado ao caráter probabilístico dos operadores genéticos. Para evitar que isso aconteça é utilizada a técnica denominada de elitismo que consiste em escolher, após a avaliação da população, o melhor indivíduo

para a próxima geração. (GASPAR-CUNHA; TAKAHASHI; ANTUNES, 2012)

Algoritmo 1: ESTRUTURA GENÉRICA DE UM ALGORITMO GENÉTICO

início
- $t \leftarrow 0$
- Gerar População inicial $P(t)$
- Avaliar os indivíduos de $P(t)$
- **repita**
  - Gerar os filhos em $P'(t)$ a partir de $P(t)$
  - Operador Mutação em $P'(t)$
  - Avaliar $P'(t)$
  - Operador Seleção $P(t+1)$
  - $t \leftarrow t+1$
- **até** *Até o critério de parada*;
- Devolva o resultado da otimização

fim

Além da forma com que o problema é codificado, existem vários parâmetros do algoritmo genético que podem ser escolhidos para melhorar o seu desempenho, adaptando-o às características particulares de determinadas classes de problemas. Entre eles os mais importantes são: o tamanho da população, o número de gerações, a probabilidade de cruzamento e a probabilidade de mutação (ROJAS et al., 2002).

O tamanho da população influencia diretamente o desempenho global do algoritmo. Uma população grande demais acarreta numa grande cobertura do espaço de buscas, mas consome grandes recursos computacionais. Uma população suficientemente grande proporciona uma cobertura ideal do espaço de buscas e previne a convergência prematura. Porém, uma população muito pequena não cobre o espaço de buscar de maneira eficiente, acarretando uma queda do desempenho.

A probabilidade de ocorrer um cruzamento e como ele ocorre afeta diretamente o surgimento de novos indivíduos. Quanto maior a taxa mais rapidamente novos indivíduos serão introduzidos na população. Porém, isso pode substituir a maior parte da população, causando uma perda de variabilidade genética, podendo ocorrer perda de indivíduos de alta função *fitness*. Caso o algoritmo utilize um taxa de cruzamento baixa ele pode ser tornar lento.

Segundo Rojas et al. (2002) a probabilidade de ocorrer uma mutação influência na qualidade da solução ele mostra que valores muito baixo de taxa acarreta em uma piora da qualidade média da população.

Em problemas mono-objetivo a solução ótima é aquela que apresenta o melhor valor da

função objetivo, porém em um problema multiobjetivo se faz necessário outra abordagem pois não se tem apenas uma solução ótima, e sim um conjunto de soluções denominado Conjunto de Pareto. Cada solução pertencente a esse conjunto é não dominada por nenhuma outra solução (FONSECA; FLEMING, 1995).

O número de gerações usualmente é usado como critério de parada. Um valor pequeno causa uma limitação no espaço de busca do algoritmo já um valor grande faz necessário um tempo maior de processamento, mas fornece uma melhor solução para o problema (ROJAS et al., 2002).

3.2 Otimização Multiobjetivo

Problemas de otimização são aqueles que visam determinar os pontos extremos de uma função, sejam eles mínimo, e então os problemas serão de minimização, sejam eles máximo, problemas de maximização (STEWART, 2009). Otimização é algo extremamente comum em nosso dia a dia. Os exemplos vão desde os mais simples, como pegar um caminho mais curto para chegar no trabalho, até problemas mais complexos, como minimizar custos de uma produção em uma fábrica, determinar o melhor conjunto de rotas para uma transportadora, dentre outros. (DEB, 2012)

A otimização abrange as mais diversas áreas do conhecimento, problemas de biologia de economia/administração, de engenharia e seja qual for o problema, o primeiro passo rumo a otimização do mesmo é a modelagem matemática. A modelagem, no problema de otimização, é representado pela função objetivo, e pelo conjunto de restrições que o problema apresenta. Um modelo pode dispor de uma ou mais funções objetivos dependendo da sua natureza. É dito que o problema é mono-objetivo quando se tem interesse em apenas uma função objetivo, caso contrário é dito multiobjetivo.(HILLIER, 1967)

Um problema de otimização multiobjetivo consiste em encontrar um vetor de variáveis de decisão (solução) que satisfaça restrições e otimize as funções objetivos. Estas funções representam os critérios que, usualmente, são conflitantes. Portanto, o termo "otimizar"significa encontrar soluções com todos os valores dos objetivos que não podem ser melhorados simultaneamente.

Um exemplo de um problema com objetivos conflitantes é a tarefa de comprar um computador. Uma compra ótima é aquela que fornece o custo mínimo enquanto maximiza o desempenho do equipamento. Estes objetivos são conflitantes entre si, uma vez que existirão desde computadores com elevado custo e desempenho até aqueles com baixo custo e desempenho. Assim, nenhuma solução que tenha menor custo e performance pode ser considerada como superior a outra com maior custo e desempenho. Contudo, dentre todas as configurações de equipamentos existem algumas que são superiores a

outras, isto é, apresentam uma performance maior ou equivalente por um custo menor ou igual. Estas configurações (soluções) que superam outras são conhecidas como soluções não-dominadas, enquanto que as configurações que são superadas por pelo menos uma são conhecidas como soluções dominadas.

De acordo com Abraham et al. (2004) o conceito de Pareto-ótimo constitui o cerne da otimização multiobjetivo. Seja z um vetor solução onde cada posição desse vetor representa uma função que descreve o problema. Pela definição, um vetor z é Pareto-ótimo se não existe um outro vetor viável z^* que possa melhorar algum objetivo, sem causar uma piora em pelo menos um outro objetivo. Em outras palavras, um vetor solução z pertence ao conjunto de soluções Pareto-ótimo se não existe nenhum vetor solução z^* que domine z.

Considerando um problema de minimização a solução z domina uma solução z^* quando:

•z domina z^* se, e somente se, $z_j \leq z_j^* \ \forall j$ e $z_j < z_j^*$ para algum objetivo j;
• z e z^* são indiferentes ou possuem o mesmo grau de dominância se, e somente se, z não domina z^* e z^* não domina z.

No último caso, as soluções não podem ser classificadas como melhor que as outras, a menos que seja aplicado um método para diferencia-las.

A Figura 3 exemplifica o conceito de dominância para o caso onde o problema possui dois objetivos. As soluções A, B e C são consideradas boas soluções - embora nenhuma seja melhor que a outra em ambos os objetivos - e neste caso elas são as soluções **não-dominadas**. Já as soluções D e E são **dominadas** pelas soluções C e B respectivamente, pois para ambos os objetivos as soluções B e C são melhores que os objetivos de D e E.

Figura 3 – Exemplo de dominância para o caso de duas funções objetivos.

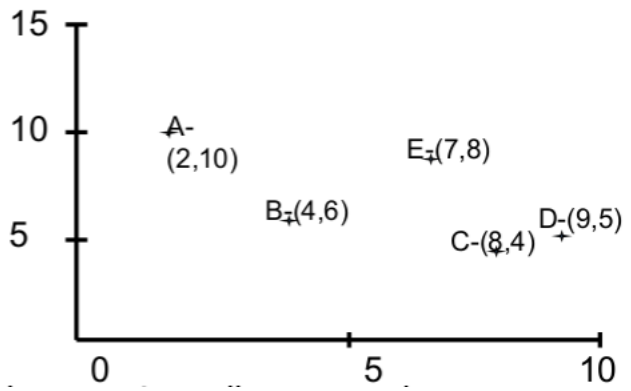

3.3 NSGA-II

O NSGA-II é um algoritmo genético multiobjetivo, proposto por (DEB et al., 2002), que evolui a população e retorna um conjunto formado pelas melhores soluções. Durante a execução do algoritmo os indivíduos serão classificados como pertencentes a uma categoria nomeada como fronteira. A primeira fronteira contém todas as soluções não-dominadas e recebe o nome Conjunto de Pareto. A segunda fronteira contem as soluções não-dominadas não considerando as soluções da fronteira 1. Para calcular a terceira fronteira se exclui as soluções da fronteira 1 e 2 e assim sucessivamente até que todos os indivíduos estejam em alguma fronteira. Assim o número de fronteiras pode variar conforme a população (DEB et al., 2002).

Através do conceito de dominância, o algoritmo associa o conceito de elitismo que classifica a população em diferentes fronteiras de qualidade ao invés de tratá-las como pertencentes a um único grupo. Isso permite ao algoritmo a privilegiar as melhores soluções.

O diferencial do NSGA-II está nos dois mecanismos importantes que o processo de seleção possui: *Fast Non-Dominated Sorting* e o *Crowding Distance*. O algoritmo *Fast Non-Dominated Sorting* utiliza o conceito de dominância para classificar cada indivíduo em sua respectiva fronteira. Dentro de uma fronteira nenhuma solução domina qualquer outra solução, portanto se faz necessário um critério para diferenciar umas soluções das outras. A técnica de distância de aglomeração (*Crowding Distance*) existe exatamente para suprimir essa necessidade. De modo geral o operador *Crowding Distance* ordena os indivíduos de acordo com a distância aos seus vizinhos na mesma fronteira. Quanto mais isolado um indivíduo é, maior a probabilidade dele ser escolhido para a próxima geração. Portanto esse operador proporciona uma diversidade da população impedindo que haja um agrupamento de soluções em um mesmo ponto.

Capítulo 4

Metodologia

Este capítulo irá descrever as técnicas utilizadas durante a estruturação e implementação do projeto, as ferramentas adotadas e suas características. Será discutido também a ferramenta que implementa o algoritmo NSGA-II, suas características, seus parâmetros de entrada.

4.1 Construção do Modelo

A construção do modelo foi dividida em duas etapas. A primeira corresponde ao entendimento do problema e a criação do modelo matemático. Já a segunda etapa consiste em implementar o algoritmo e analisar os resultados obtidos.

4.1.1 Caracterização do Problema

O primeiro problema a ser resolvido consiste em cobrir a maior área ,da região de interesse, possível utilizando o menor número de RSUs.
Esse problema é caracterizado como:
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. 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.

Essa abordagem permite que as células assumam diferentes níveis de precisão de acordo com a necessidade do problema. Perde-se precisão ao aumentar o tamanho das células, pois se restringe os possíveis locais onde as antenas podem ser alocadas. A Figura 4 é uma reprodução da cidade de Ouro Branco - MG e está dividia em célula de 20×20, 40×40 e 80×80 onde cada uma dessas divisões exemplifica os possíveis níveis de precisão.

Figura 4 – Representação da malha viária em células

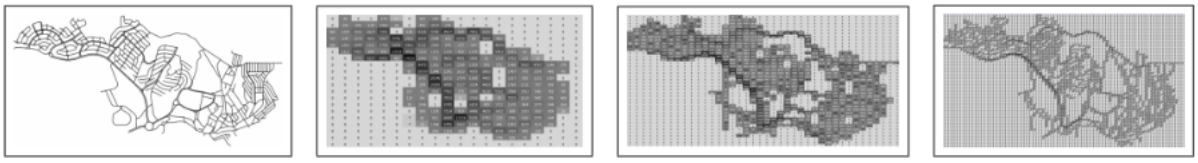

(a) Malha viária. (b) Grade 20×20. (c) Grade 40×40. (d) Grade 80×80.

Fonte: (SILVA et al., 2016)

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 segundo a Equação 1.

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

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

Onde $d_{(f,u)}$ é a distância euclidiana entre a RSU alocada na célula u e a célula f por onde passa 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 passam alguma rodovia.

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

O segundo objetivo é calculado segundo a Equação 3.

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

O segundo problema consiste em cobrir a maior área possível e maximizar o número de pacotes de dados entregues com sucesso. Nesta segunda etapa foi simulado 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 $(8, 12)$. 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.

Neste problema 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 as RSUs de uma solução. Dada uma solução U a taxa de pacotes entregues é calculada segundo a Equação 4

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

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

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

4.1.2 Modelo Matemático

Nesta Seção é apresentado os dois modelo matemáticos que serão resolvidos neste trabalho.

O modelo 5 descreve o problema tratado na primeira parte deste trabalho que consiste em minimizar a área coberta utilizando o menor número de RSU. O objetivo consiste em encontrar um subconjunto $U \subset C$ que minimize as funções F_{descob} e F_{num}.

$$\begin{array}{lll} \text{Minimize} & (F_{descob}(U), F_{num}(U)) & \\ \text{Subject to} & F_{num}(U) & \leq NumeroMaxRSUs \\ & U \subset C & \end{array} \tag{5}$$

Já o conjunto de inequações 6 modela a segunda parte deste trabalho que consiste na avaliação da taxa de sucesso de envio dos pacotes de dados. Nesta parte, o objetivo também consiste em encontrar um conjunto $U \subset C$ que, neste caso, maximize as funções F_{cob} e $F_{taxaSucesso}$.

$$\begin{array}{lll} \text{maximize} & (F_{cob}(U), F_{Fpack}(U)) & \\ \text{subject to} & ||U|| & \leq NumeroMaxRSUs \\ & U \subset C & \end{array} \tag{6}$$

4.2 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). Um grande diferencial que o NSGA-II utilizado neste trabalho apresenta quando comparado com os demais trabalho consiste na utilização dos operadores de cruzamento geométrico e de mutação que exploram propriedades do problema em questão. Além disso, foi proposto um método de busca local a fim de aumentar a eficiência do algoritmo apresentado neste trabalho.

Um primeiro passo quando se trabalha com AGs consiste em codificar as variáveis do problema. Neste trabalho cada célula da área de interesse recebeu um número inteiro que será seu identificador (gene) e a partir dessa codificação um indivíduo foi definido como um conjunto de inteiros. Cada inteiro desse conjunto corresponde a uma célula que foi eleita para receber uma RSUs. A figura abaixo ilustra como um indivíduo é constituído.

A operação de mutação modifica os indivíduos já existentes transformando-os em outros indivíduos. Obedecendo uma taxa inicialmente definida, cada indivíduo terá um gene trocado por outro, removido ou inserido. Vale ressaltar que genes repetidos não serão tolerados por

Indivíduo 1	50	1789	158	99	73	
Indivíduo 2	4	8	15	16	23	42

Tabela 2 – EXEMPLOS DE INDIVÍDUOS

prejudicar uma das funções objetivo. A tabela abaixo exemplifica uma possível mutação onde o gene na segunda posição é substituído pelo gene 98. Além desse tipo de mutação outros dois tipos foram implementados: remoção e inserção de um único gene.

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

Tabela 3 – EXEMPLO DE UMA MUTAÇÃO

Os indivíduos existentes na população irão trocar sequências, aleatoriamente escolhidas, de genes obedecendo uma taxa inicialmente estabelecida gerando novos indivíduos. Essa troca é realizada em um processo denominado de cruzamento e neste trabalho será utilizado o Cruzamento Real-Polarizado (CRP), proposto por Takahashi et al. (2003) e posteriormente o conceito foi estendido para variáveis inteiras por Martins et al. (2014). Dados os vetores $\overrightarrow{A}$ e $\overrightarrow{B}$ representando dois pais, as soluções obtidas sobre o segmento de reta $\overrightarrow{A'B'}$ são tais que:

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

O vetor $\overrightarrow{A'B'}$ é ilustrado na Figura 5. O CRP gera indivíduos no segmento de $\overrightarrow{A'}$ até $\overrightarrow{B'}$ que inclui o $\overrightarrow{AB}$ e uma certa extrapolação deste segmento. Um dos indivíduos filhos são gerados segundo uma função de distribuição quadrática, em que o melhor pai irá contribuir com uma parte maior da sua carga genética do que o segundo pai. Assim, a vizinhança do melhor pai tem maiores chances de receber o novo indivíduo. As Figuras 6 e 5 exemplificam a geração de dois filhos. A Figura 5 representa o processo denominado de extrapolação onde a vizinhança dos pais será explorar para gerar os filhos. Na Figura 6 os pontos vermelhos representam as soluções escolhidos para serem os pais e as soluções em azul representam os filhos gerados. Observa-se que os filhos estão mais próximos do pai $\overrightarrow{A}$, devido ao fato dele ser o pai mais bem avaliado.

Para realizar a extrapolação do segmento $\overrightarrow{AB}$ se faz necessário eslecer a noção de distância entre duas soluções e neste trabalho a distância de *Hamming* (HAMMING, 1950) foi escolhida, por ser bem natural no atual contexto. Inicialmente a distância de *Hamming* foi definida entre duas strings de mesmo comprimento como sendo o número de posições

Figura 5 – Exemplo do Cruzamento Real-Polarizado

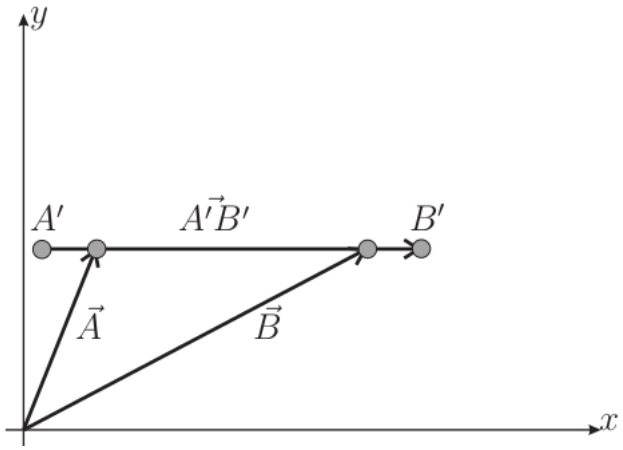

Fonte: (MARTINS, 2012)

Figura 6 – Função de distribuição quadrática

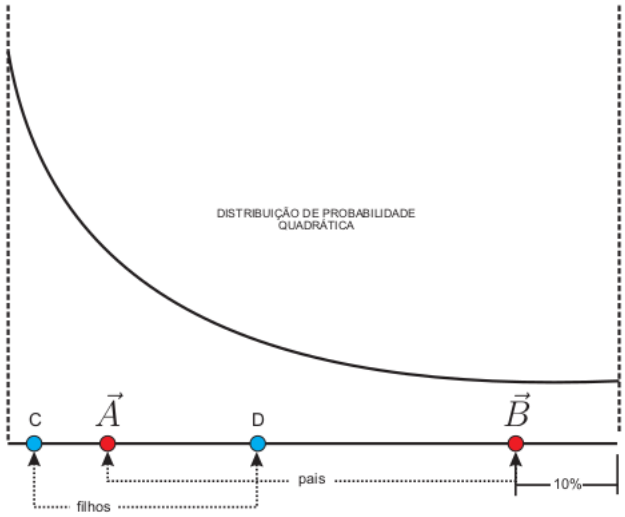

Fonte: (MARTINS, 2012)

nas quais eles se diferenciam. Esse conceito foi traduzido para a ótica de redes veiculares. Portanto a distância, $dist(A, B)$, entre a solução A e B é definida como sendo o número de RSUs que devem ser inseridas ou removidas em A para que ela se torne igual a solução B.

Então para se realizar uma extrapolação de um 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 RSUS de A. Feita a extrapolação, teremos os indivíduos A' e B', que diferem de A e B em 10% respectivamente. Um vetor W_A é criado de modo que cada célula desse vetor contém 0 se A' e B' são iguais para um mesmo índice, ou 1 caso contrário. Uma vez tendo W_A, um inteiro p é sorteado seguindo uma distribuição quadrática com $0 \leq p < dist(A', B')$ e p posições não nulas são escolhidas e são transformadas em

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
W	1	0	1	0	1	1
WA	0	0	1	0	0	0
WB	0	0	1	0	1	1
Filho 1	1	0	0	1	0	1
Filho 2	1	0	0	1	1	0

Tabela 4 – EXEMPLO DE UM CRUZAMENTO

posições nulas. De maneira análoga um vetor W_B é criado, porém o inteiro p sorteado segue uma distribuição normal.

Sendo assim o filho 1 será gerado a partir do vetor W_A de modo que ele herdará do Pai A todos as posições nulas e do Pai B todas as posições não nulas. O filho 2 será gerado de forma análoga utilizando o vetor W_B.

A Tabela 4 ilustra o funcionamento do CRP com indivíduos codificados de maneira binária para facilitar o entendimento do exemplo.

A heurística proposta neste trabalho se baseia no NSGA-II que 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.

4.2.1 Implementação do NSGA-II

A população inicial, de tamanho N, é criada de modo que se tenha indivíduos que cubram $0\%, 1\%, 2\%, ..., 99\%$ da área de interesse, garantindo assim uma população inicial diversificada.

Inicialmente a população ainda não está classificada, onde se iniciará o *Fast Non-Dominated Sorting* um processo para atribuir a cada indivíduo um grau de dominância em relação aos outros indivíduos. Isso é realizado comparando cada função *fitness* e aplicando a definição de Dominância. Em seguida os indivíduos serão organizados em suas respetivas fronteiras obedecendo seus valores de dominância, de modo que, as melhores soluções sempre são classificadas na primeira fronteira e as piores na última.

O método *Fast Non-Dominated Sorting* é dividido em duas etapas. Na primeira cada indivíduo da população é classificado quanto ao grau de dominância n_p (número de indivíduos que domina o indivíduo p).Foi definido um operador matemático $\{\prec\}$ para realizar a comparação entre dois indivíduos quaisquer obedecendo a definição de Dominância anteriormente

estabelecida. Cada indivíduo p da população é comparado com um indivíduo q utilizando o operador $\{\prec\}$. Se $p \prec q$, ou seja, se p domina q então q é inserido no conjunto S_p que contém todos as soluções dominadas por p. Para que seja possível comparar soluções dentro da mesma fronteira será aplicado um Operador de Diversidade denominado *Crowding Distance*.

Se ao termino dessa etapa, o indivíduo apresentar $n_p = 0$ representa que esse indivíduo não é dominado por ninguém da população e que tais indivíduos pertencem a fronteira 1, onde estão as melhores soluções da população corrente.

A segunda etapa corresponde em separar os demais indivíduos em diferentes fronteiras obedecendo seu grau de dominância. Para cada indivíduo p de F_i é realizado um decréscimo nos valores de n_q dos indivíduos q pertencentes a S_p a fim de tornar esse valores iguais a 0, pois ao tornar esses valores iguais a 0 significa que na próxima interação todos as soluções cujo n_p for igual a 0 estarão na nova fronteira.

O Algoritmo 2 ilustra o processo descrito acima.

Algoritmo 2: FAST NON-DOMINATED SORTING

```
início
    para Cada p ∈ P faça
        S_p = ∅
        n_p = ∅
        para cada q ∈ P faça
            se p ≺ q então
                S_p = S_p ∪ {q}
            fim
            senão se q ≺ p então
                n_p = n_p + 1
            fim
        fim
        se n_p = 0 então
            p_rank = 1
            F_1 = F_1 ∪ {p}
        fim
    fim
    i = 1
    repita
        para cada p ∈ F_i faça
            para q ∈ S_p faça
                n_q = n_q − 1
                se n_q = 0 então
                    q_rank = i + 1
                    F_{i+1} = F_{i+1} ∪ {q}
                fim
            fim
        fim
        i = i + 1
    até F_i ≠ ∅;
fim
```

Após essa classificação, o operador *Crowding Distance* é aplicado para garantir uma diversidade de soluções na população, como também ordenar indivíduos de uma mesma fronteira. Para isto, deve-se calcular o perímetro do cuboide formado pelas soluções vizinhas a i que estão localizadas na mesma frente de dominância. A Figura 7 exemplifica o cálculo do *Crowding Distance* para o indivíduo i quando se tem duas função fitness.

Figura 7 – Conceito do Cálculo realizado pelo Operador de Diversidade

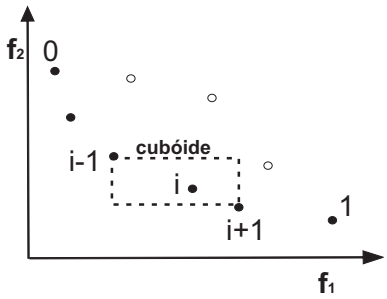

Fonte: (DEB et al., 2002)

O método se inicia ordenando um conjunto M de soluções para cada objetivo n. Os pontos extremos (soluções com o maior e menor valor de função fintes) serão sempre selecionados e por isso seus valores de *crowdist* são setados como infinito, enquanto os demais valores são inicializados com zero. Após o cálculo da *Crowding Distance* é realizado a partir do segundo indivíduo até o indivíduo localizado na posição $|M| - 1$ da seguinte maneira: O valor do *crowdist* da n-ésima solução é somado a diferença das m-ésima função *fitness* do indivíduo $n - 1$ e $n + 1$ como descrito no Algoritmo 3.

Algoritmo 3: CROWDING DISTANCE

início
  Entrada: M, um conjunto de soluções
  para $m = 1, 2, ..., N_{obj}$ **faça**
    Ordenar M por f_m
    $crowdist_1 = crowdist_{|M|} = \infty$
    para $n = 2, ..., |M| - 1$ **faça**
      $crowdist_n = crowdist_n + f_m(M_{n+1}) - f_m(M_{n-1})$
    fim
  fim
fim

Por fim 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 da população as soluções com maior *Crowding Distance* são escolhidas.

Nessa abordagem as soluções são escolhidas para constituir uma nova população. Uma solução i é escolhida sobre uma j se:

• i pertence a uma fronteira menor que j, ou seja, $rank_i < rank_j$;

• Caso ambas as soluções estejam no mesmo ranking e a solução i tenha uma *Crowding Distance* maior que j $(rank_i = rank_j$ e $crowdist_i > crowdist_j)$

Onde $rank_i$ representa a fronteira do indivíduo i.

Figura 8 – Operador Seleção

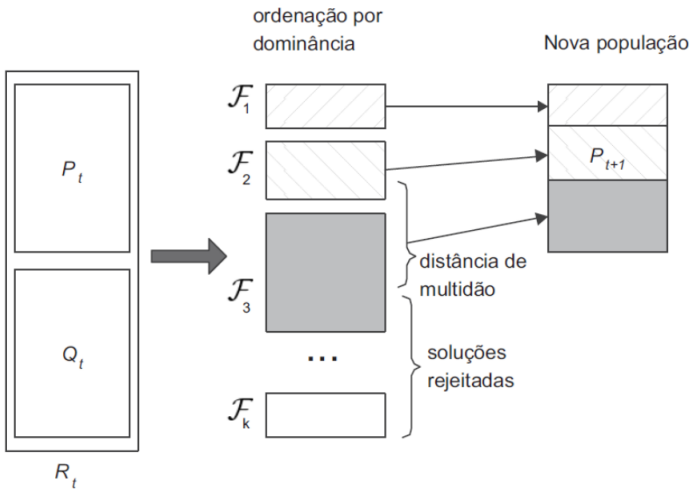

Fonte: (DEB et al., 2002)

A partir da definição acima podemos estabelecer o conceito de torneio binário que consiste em escolher dois indivíduos aleatoriamente na população, e escolher o melhor dentre esses dois indivíduos. Tal conceito é utilizado no Cruzamento para a escolhas dos pais e na Seleção da nova população.

4.2.2 Busca Local

Na tentativa de melhorar as soluções durante a execução do algoritmo dois métodos de busca local foram implementados. Um primeiro algoritmo de busca local implementado neste trabalho consiste em remover as k RSUs que menos contribuem para a cobertura da área. Neste primeiro momento, o foco é reduzir o número de RSUs. O segundo método de busca local investiga as células que mais contribuiriam para aumentar a cobertura e insere RSUs nas k melhores células. A busca local é realizada em cada indivíduo da população.

4.2.3 Hipervolume

Para efeito de comparação de resultados dos algoritmos multiobjetivos foi utilizado a métrica denominada *HyperVolume* que foi proposta por Zitzler, Deb e Thiele (2000) que consiste em calcular a área, para caso de problemas com dois objetivos, limitada pelo ponto de referência W e pelos pontos do Conjunto de Pareto.
Nesta métrica, quanto maior o valor do Hipervolume,em relação ao ponto de referência W, maior será o espalhamento das soluções do conjunto Pareto otimizado. A Figura 9 exemplifica o caso de duas funções objetivos considerando um problema de minimização. O ponto W é onde as funções objetivos $F1$ e $F2$ assumem seus piores valores enquanto os pontos E, Fe G constituem o conjunto Pareto Otimizado. O Hipervolume, que no exemplo da Figura 9 vale $8u.a$, será dado pela soma das áreas dos retângulos A, B e C com áreas iguais a $4u.a$, $3u.a$ e $1u.a$ respectivamente.

Figura 9 – Exemplo de um Hipervolume para o caso de duas funções objetivos.

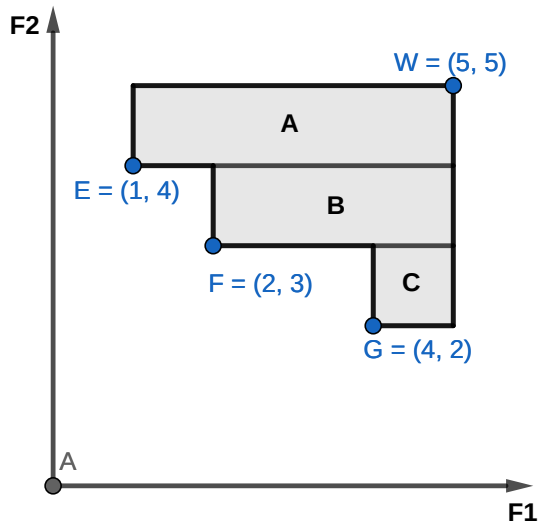

4.3 Coleta e tratamento de dados

Os dados acerca da área de interesse e das *RSUs* foram obtidos em Kumrai et al. (2014). Foi criada uma área de interesse artificial cujo tamanho é $5km \times 5km$, com $50km$ de malha viária *(TotalRoad)* dividida em 50×50 células.

4.3.1 Simulação do Tráfego na rede

Para realizar a simulação dos fluxo dos pacotes dados foi realizada um tráfego de veículos pela área de interesse. Para ta, uma célula do *grid* por onde se passa alguma rodovia é escolhida aleatoriamente como ponto de partida para o veículo e o tempo total do percurso

Figura 10 – Divisão da área de interesse

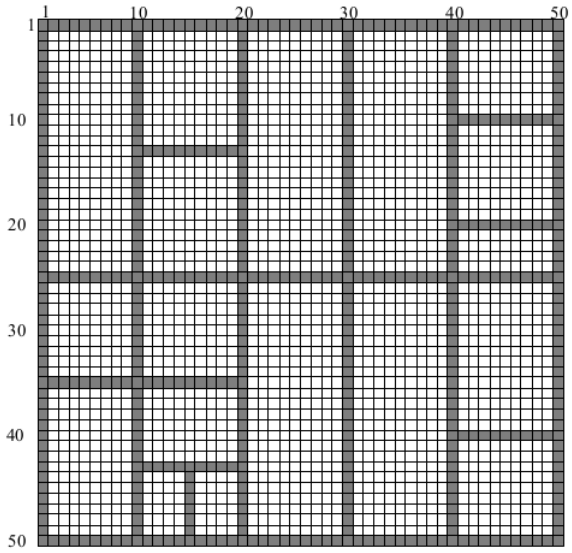

Fonte: (KUMRAI et al., 2014)

em segundos é definido. Escolhido o ponto de partida será definido todo o percurso que o veículo irá realizar e para isso uma célula, dentre as células vizinha à posição atual, é escolhida como sendo a próxima posição.
Assumindo que a velocidade média do veículo seja de $40km/h$ o tempo necessário para percorrer $100m$ – a dimensão de uma célula – seria de aproximadamente $10s$, portanto, para que se tenha um comportamento aleatório o tempo de permanência de um veículo em uma célula é escolhido de forma aleatória seguindo uma distribuição normal $(8, 12)$.

Para cada veículo é escolhida uma célula de partida e o tempo total de viagem. Tendo esses dados as próximas células são escolhidas sorteando uma das células vizinhas á posição atual, de modo que, a última célula que o veículo ocupou não possa ser escolhida. Ao mesmo tempo que a próxima célula é escolhida o tempo de permanência naquela célula também é definido aleatoriamente. O percurso se encerra quando a soma dos tempos de permanência nas células ultrapassa o tempo de viagem previamente definido.

Essa simulação é invariante ao problema que está sendo resolvido nesse trabalho podendo ser a aplicada em problemas de outra natureza.

A Figura 11 mostra o percurso de três veículos que se iniciam nas células de cor amarela e finalizam nas células de cor verde.

Figura 11 – Exemplo do percurso dos veículos.

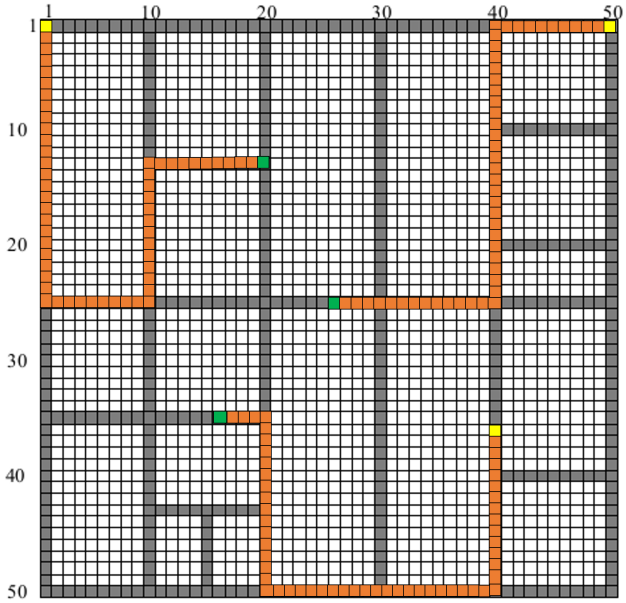

Capítulo 5

Resultados

Este capítulo irá descrever os resultados obtidos pelo algoritmo assim como quais parâmetros foram utilizados durante as simulações.

5.1 Parâmetros do Algoritmo

Os seguintes parâmetros para a execução do AG foram escolhidos após a realização de alguns testes:

- Tamanho da população - 200;
- Número máximo de RSUs - 100;
- Taxa de Mutação - 30%;
- Taxa de Cruzamento - 90%;
- Número de gerações - 5.000;
- Janela de tempo para os veículos - 3600s;
- Execução da Busca Local - A cada 50 gerações;

5.2 Influência dos operadores genéticos e da Busca Local

A Figura 12 mostra a influência da taxa de mutação na convergência do algoritmo. Observa-se que a taxa de 30% acarretou em um ganho na qualidade da solução do problema. Todas as simulações foram realizadas na mesma condições variando apenas a taxa de mutação.

A Figura 13 mostra o efeito que a Busca Local acarreta quando é aplicada durante a otimização. A Busca Local reduziu de 97 para 89 RSUs alocada considerando que 100% da área de interesse esteja coberta. O Conjunto Pareto otimizado possui um Hipervolume igual a $85879m^2$ quando se aplica a Busca Local e $85566m^2$ quando não se aplica a Busca Local.

Figura 12 – Influência da taxa de mutação na convergência do algoritmo.

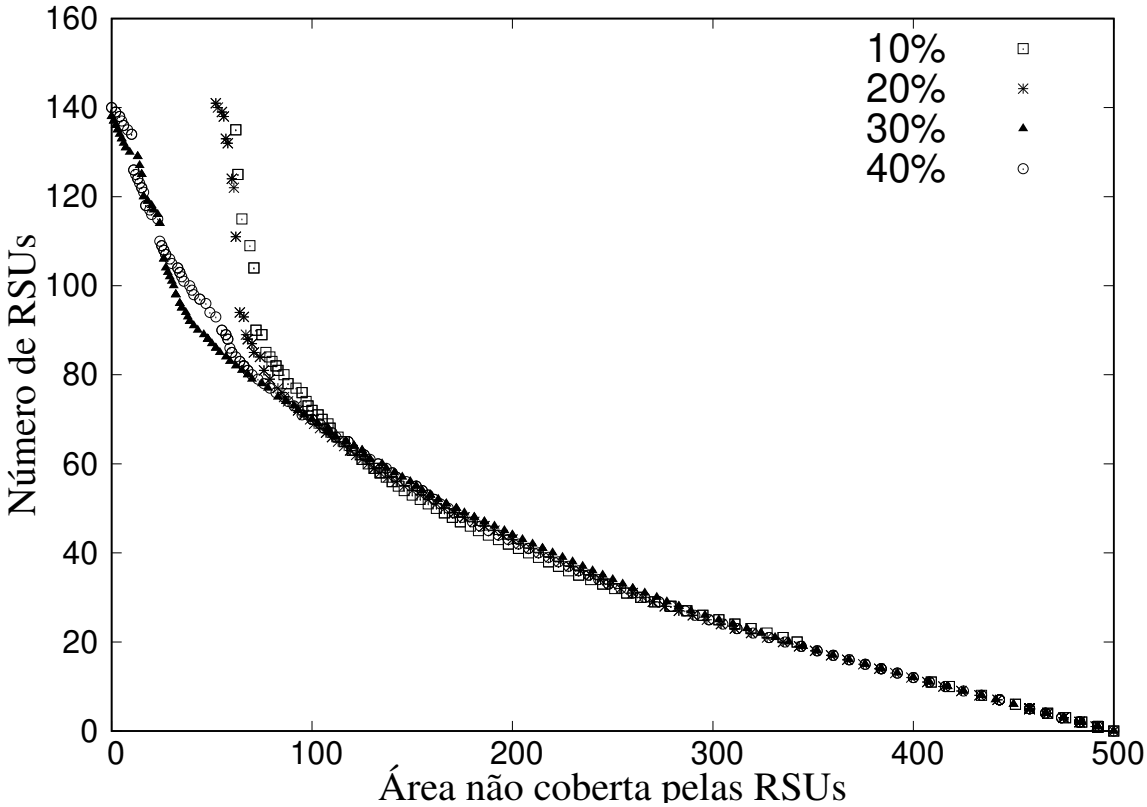

Figura 13 – Influência da busca bocal no algoritmo

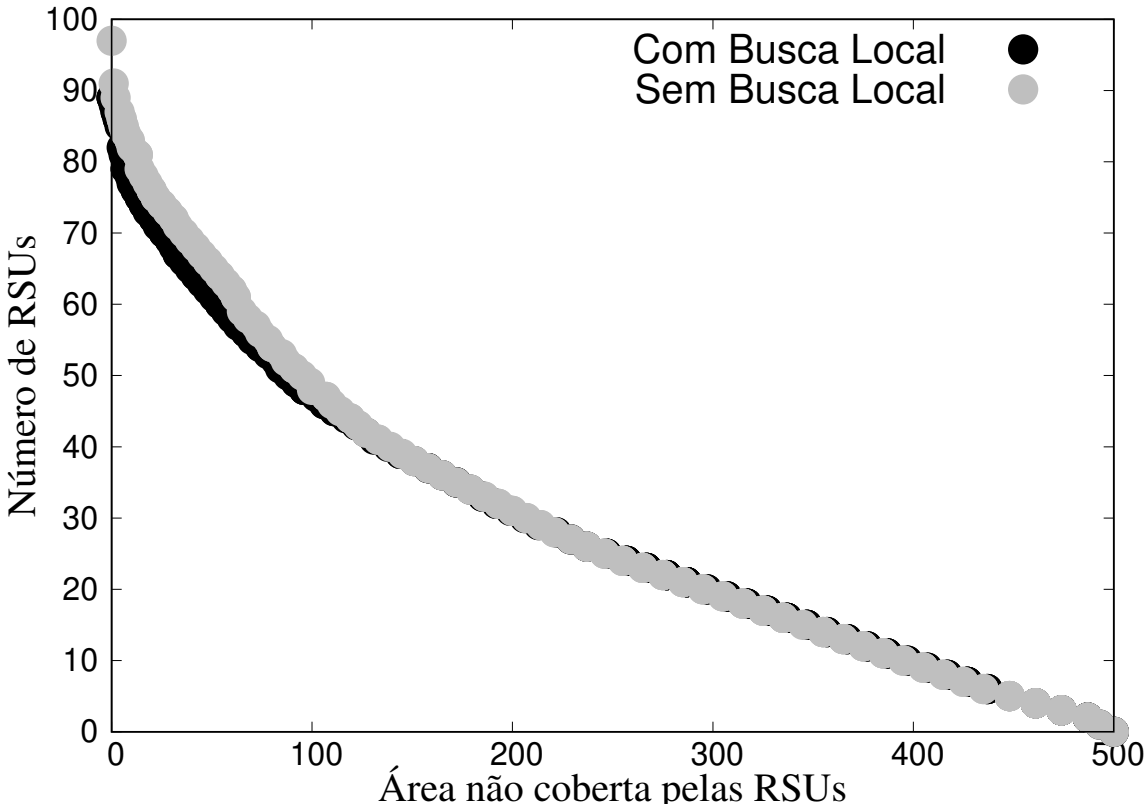

Para mostrar a influência do operador CRP, foi realizada uma comparação com o operador de Cruzamento Uniforme. Os resultados são mostrados na Figura 14. Os pontos brancos correspondem ao operador de Cruzamento Uniforme. Neste operador, cada gene do pai é escolhido seguindo uma distribuição uniforme como 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. O CRP apresentou um Hipervolume de $85879m^2$ enquanto o Cruzamento Uniforme apresentou um Hipervolume de $85303m^2$. Assim, fica claro a influência do CRP na convergência do algoritmo.

Figura 14 – Efeito do Operador Cruzamento na População. Os círculos em preto representam as soluções obtidas quando pelo operador de Cruzamento Uniforme. Os círculos em branco descrevem as soluções obtidas utilizando o operador de Cruzamento Real-Polarizado.

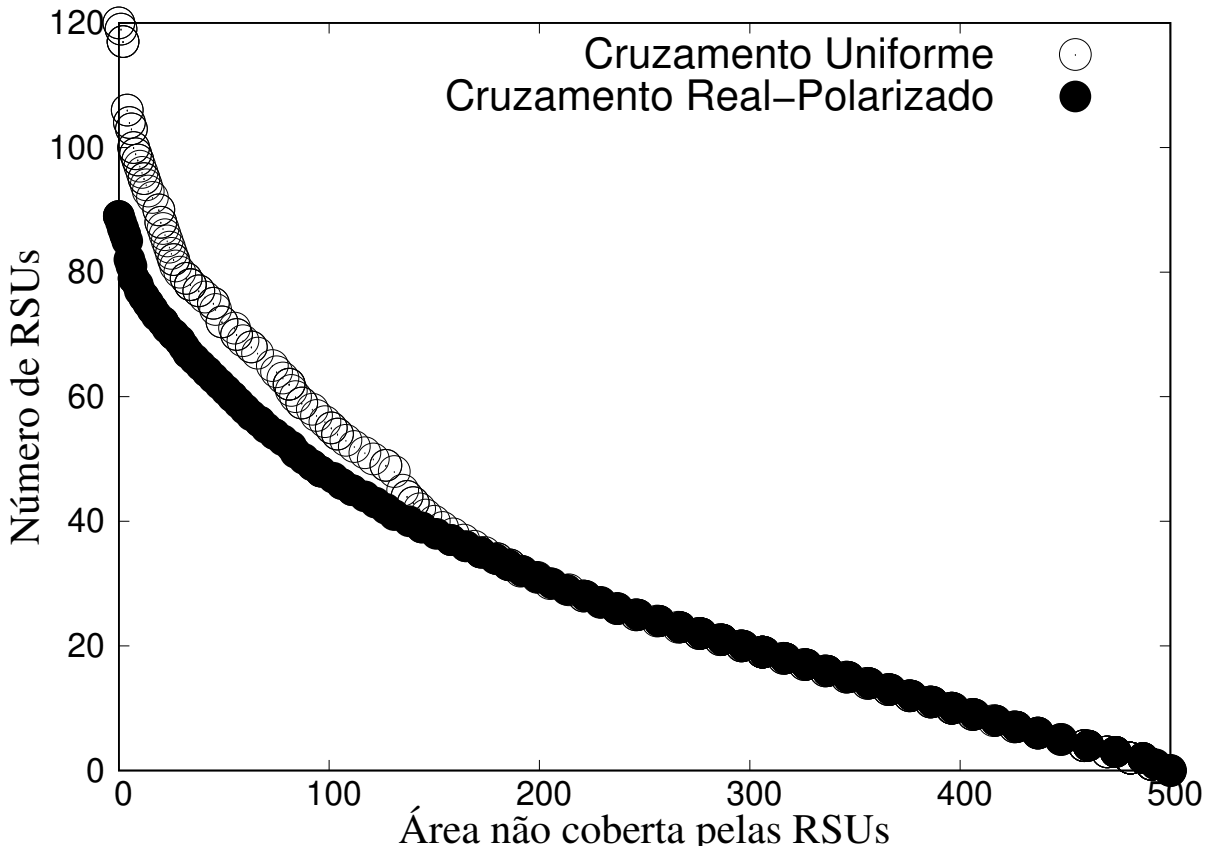

5.3 Área coberta e pacotes de dados gerados

Para a primeira parte do trabalho proposto o experimento realizado por Kumrai et al. (2014) foi reproduzido para efeitos de comparação.

A Figura 15 mostra os resultados obtidos pelo algoritmo proposto neste trabalho e pelo 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 brancos foram

obtidos aplicando o método de Kumrai et al. (2014), onde foi utilizado o *framework JMetal* (DURILLO; NEBRO, 2011). Os círculos em preto constituem o conjunto Pareto otimizado encontrado pelo algoritmo proposto neste trabalho.

Figura 15 – Comparação dos métodos proposto neste trabalho com o trabalho de Kumrai et al. (2014)

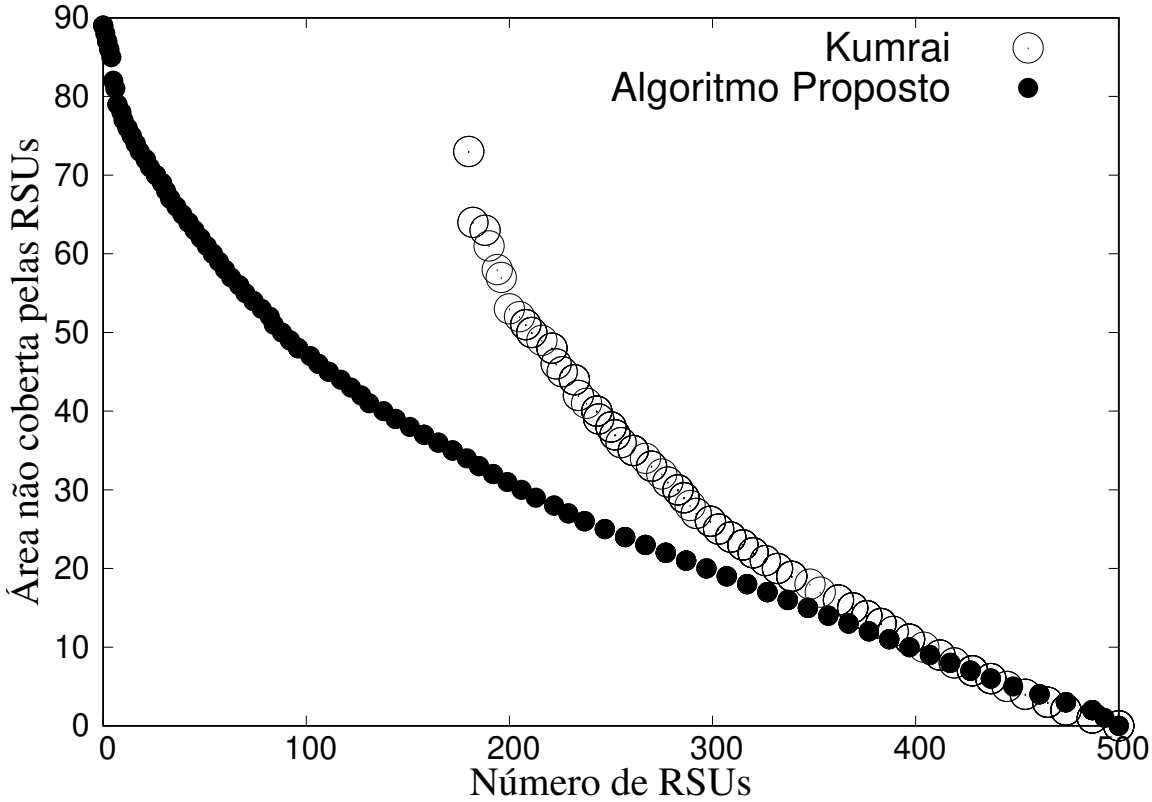

Observa-se que a soluções obtidas neste trabalho atingem uma maior cobertura utilizando um número menor de RSUs quando comparadas às soluções de Kumrai et al. (2014).

As Figuras 16, 17, 18 e 19, 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 16 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, o que era permitido contudo foge ao censo comum. Na Figura 17, 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 18 e 19 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.

Figura 16 – Solução com 100% das rodovias é coberta pelas RSUs.

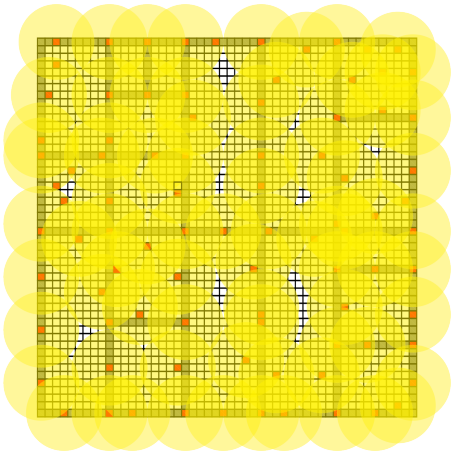

Figura 17 – Solução com pelo menos 70% das rodovias é coberta pelas RSUs.

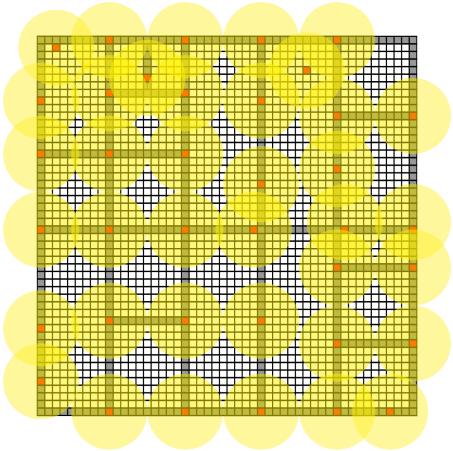

Figura 18 – Solução com pelo menos 50% das rodovias é coberta pelas RSUs.

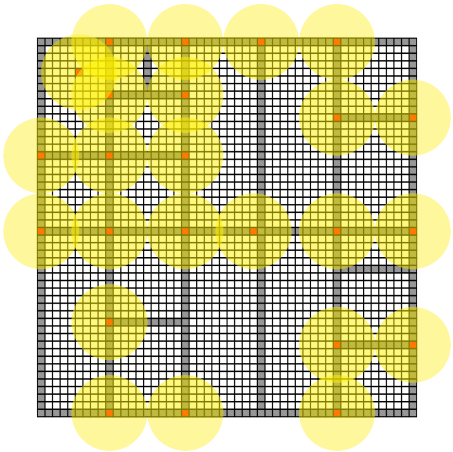

Figura 19 – Solução com pelo menos 30% das rodovias é coberta pelas RSUs.

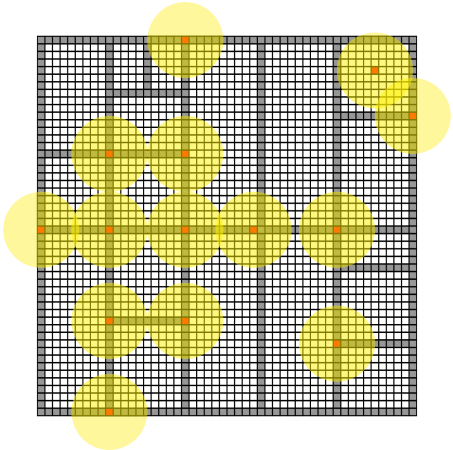

A Figura 20 compara o resultado obtido ao aplicar o algoritmo proposto neste trabalho com o algoritmo exato. Um novo mapa foi criado com 5×5 células com 5 RSUs disponíveis onde cada RSU tem um raio de cobertura igual a $50m$. No eixo x tem-se o número de RSUs utilizado e no eixo y a área não coberta pelas RSUs. A solução exata possui um Hipervolume igual a 68 enquanto a solução do algoritmo genético possui um Hipervolume igual a 65.

O algoritmo exato implementado para realizar a comparação consiste em gerar todas as combinações possíveis das localizações das RSUs e escolher a melhor solução dado o número de RSUs que se deseja alocar. Portanto, dado 1 RSU gera-se todas as soluções possíveis e a solução com maior cobertura é escolhida. Disponibilizando 2 RSUs gera-se todas as soluções e, novamente, a melhor solução é escolhida para compor o Pareto otimizado. Esse procedimento é repetido até atingir o número máximo de RSUs. Dado a complexidade exponencial do algoritmo exato se fez necessário um mapa pequeno da região de interesse.

A Figura 21 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

As Figuras 22 e 23 são um mapa de calor que mostra a distribuição dos veículos na área de interesse. A Figura 22 mostra a distribuição das posições de partida de cada veículo. Observa-se uma distribuição uniforme pela área de interesse onde quanto mais amarela a célula é mais veículos partiram daquela célula. Foram utilizados 150 veículos e não houve mais que 2 veículos partindo de uma mesma célula. Já a Figura 23 mostra a distribuição

Figura 20 – Comparação dos resultados obtido pelo algoritmo exato e pelo algoritmo genético.

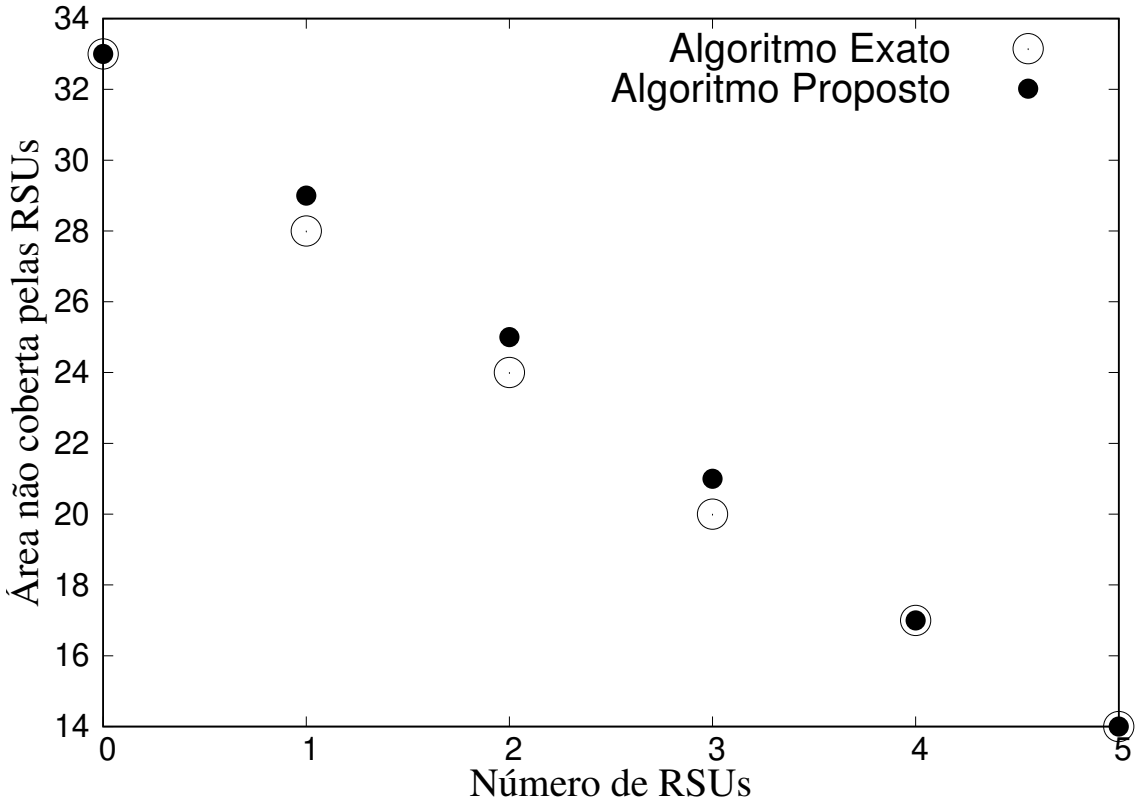

das células por onde os veículo passaram durante o tempo de simulação.

Todas as simulações foram realizadas no *cluster* do Departamento de Computação do CEFETMG com 4 máquinas *Supermicro*, 64 *threads* físicas, sem *hyperthread*, 128 GB RAM.

Figura 21 – Resultados obtidos pelo algoritmo proposto quando se considera os pacotes entregues e a área não coberta pelas RSUs

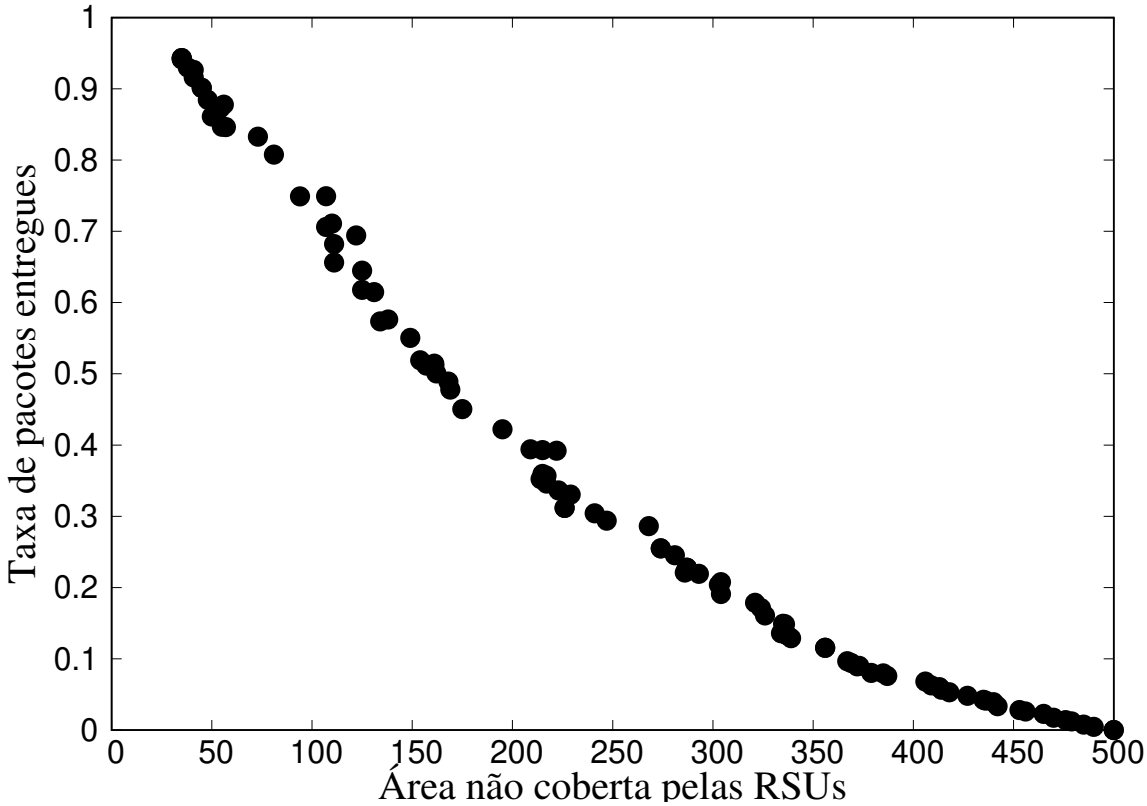

Figura 22 – Distribuição dos pontos de partida dos veículos pelas rodovias

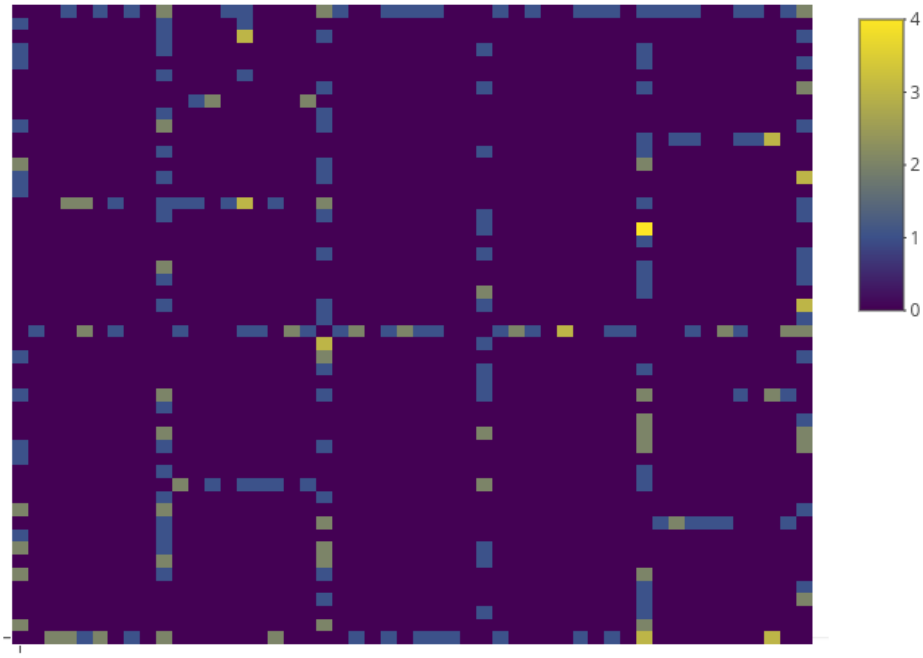

Figura 23 – Células por onde os veículos transitaram.

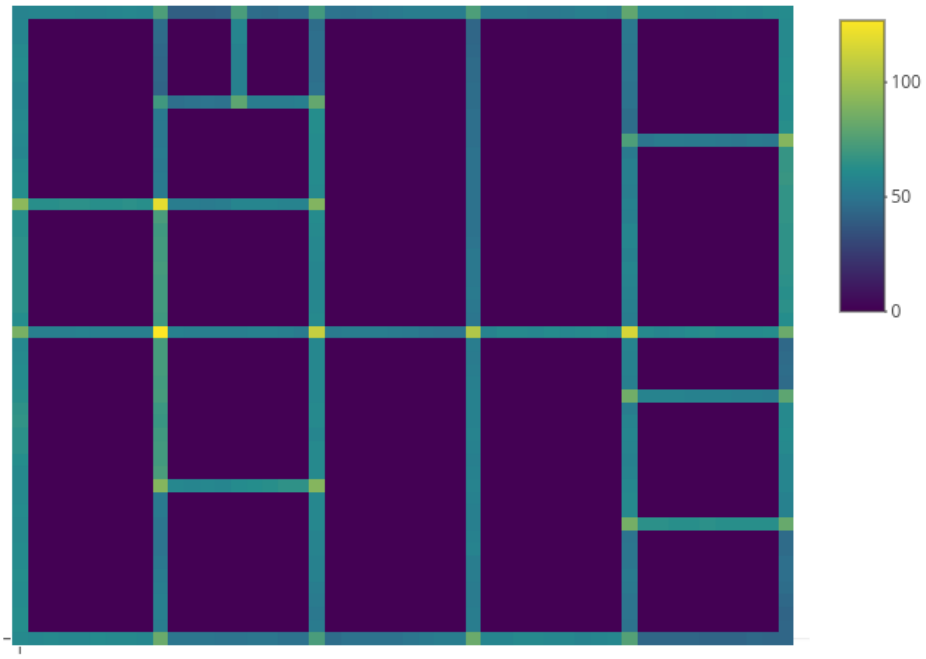

Capítulo 6

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 consistem 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.

6.1 Trabalhos Futuros

Uma proposta de trabalho futuro é considerar o consumo de energia das RSUs no problema de alocação de unidades de comunicação em redes veiculares. Neste caso uma possível função objetivo poderia ser o gasto de energia para se receber um pacote de dados. Desta maneira será possível realizar uma otimização mais condizente com a realidade. Uma outra proposta é considerar redes V2X onde a comunicação acontece com outros dispositivos da rede veicular além das RSUs e, neste caso, a área de cobertura das RSUs pode ser menor quando comparado as redes V2I.

Referências

ABRAHAM, D. J. et al. Pareto optimality in house allocation problems. In: SPRINGER. **International Symposium on Algorithms and Computation**. [S.l.], 2004. p. 3–15. Citado na página 12.

AISSAOUI, R. et al. Advanced real-time traffic monitoring system based on v2x communications. In: IEEE. **Communications (ICC), 2014 IEEE International Conference on**. [S.l.], 2014. p. 2713–2718. Citado na página 1.

ALVES, R. d. S. et al. Redes veiculares: Princıpios, aplicaçoes e desafios. **Minicursos do Simpósio Brasileiro de Redes de Computadores, SBRC**, p. 17–24, 2009. Citado na página 1.

ASLAM, B.; AMJAD, F.; ZOU, C. Optimal roadside units placement in urban areas for vehicular networks. In: IEEE. **Computers and Communications (ISCC), 2012 IEEE Symposium on**. [S.l.], 2012. p. 000423–000429. Citado na página 5.

BLUM, J. J.; ESKANDARIAN, A.; HOFFMAN, L. J. Challenges of intervehicle ad hoc networks. **IEEE transactions on intelligent transportation systems**, IEEE, v. 5, n. 4, p. 347–351, 2004. Citado na página 2.

CAMILO, T. et al. An energy-efficient ant-based routing algorithm for wireless sensor networks. In: SPRINGER. **International Workshop on Ant Colony Optimization and Swarm Intelligence**. [S.l.], 2006. p. 49–59. Citado na página 6.

CAVALCANTE, E. S. et al. Roadside unit deployment for information dissemination in a vanet: An evolutionary approach. In: ACM. **Proceedings of the 14th annual conference companion on Genetic and evolutionary computation**. [S.l.], 2012. p. 27–34. Citado na página 3.

CHENG, H. et al. A knapsack constrained steiner tree model for continuous coverage over urban vanets. In: IEEE. **2014 IEEE International Conference on Communications (ICC)**. [S.l.], 2014. p. 130–135. Citado na página 6.

CHENG, H. et al. A geometry-based coverage strategy over urban vanets. In: ACM. **Proceedings of the 10th ACM symposium on Performance evaluation of wireless ad hoc, sensor, & ubiquitous networks**. [S.l.], 2013. p. 121–128. Citado na página 5.

CHI, J. et al. Intersection-priority based optimal rsu allocation for vanet. In: IEEE. **Ubiquitous and Future Networks (ICUFN), 2013 Fifth International Conference on**. [S.l.], 2013. p. 350–355. Citado na página 5.

DEB, K. **Optimization for engineering design: Algorithms and examples**. [S.l.]: PHI Learning Pvt. Ltd., 2012. 8, 34 p. Citado na página 11.

DEB, K. et al. A fast and elitist multiobjective genetic algorithm: Nsga-ii. **IEEE transactions on evolutionary computation**, IEEE, v. 6, n. 2, p. 182–197, 2002. Citado 5 vezes nas páginas 4, 13, 17, 23 e 24.

DURILLO, J. J.; NEBRO, A. J. jmetal: A java framework for multi-objective optimization. **Advances in Engineering Software**, Elsevier, v. 42, n. 10, p. 760–771, 2011. Citado na página 31.

EZE, E. C.; ZHANG, S.; LIU, E. Vehicular ad hoc networks (vanets): Current state, challenges, potentials and way forward. In: IEEE. **Automation and Computing (ICAC), 2014 20th International Conference on**. [S.l.], 2014. p. 176–181. Citado na página 1.

FARAJ, M. F. et al. A hybrid genetic algorithm for deploying rsus in vanets based on inter-contact time. In: ACM. **Proceedings of the Genetic and Evolutionary Computation Conference Companion**. [S.l.], 2017. p. 193–194. Citado na página 5.

FONSECA, C. M.; FLEMING, P. J. An overview of evolutionary algorithms in multiobjective optimization. **Evolutionary computation**, MIT Press, v. 3, n. 1, p. 1–16, 1995. Citado na página 11.

GASPAR-CUNHA, A.; TAKAHASHI, R.; ANTUNES, C. H. **Manual de computação evolutiva e metaheurística**. [S.l.]: Imprensa da Universidade de Coimbra/Coimbra University Press, 2012. Citado 3 vezes nas páginas 8, 9 e 10.

HAMMING, R. W. Error detecting and error correcting codes. **Bell System technical journal**, Wiley Online Library, v. 29, n. 2, p. 147–160, 1950. Citado na página 18.

HILLIER, F. S. **Introduction to operations research**. 8. ed. [S.l.: s.n.], 1967. 11- 13 p. Citado na página 11.

HOLLAND, J. Adaptation in natural and artificial systems: an introductory analysis with application to biology. **Control and artificial intelligence**, University of Michigan Press, 1975. Citado na página 8.

KHABAZIAN, M.; ALI, M. M. A performance modeling of vehicular ad hoc networks (vanets). In: IEEE. **Wireless Communications and Networking Conference, 2007. WCNC 2007. IEEE**. [S.l.], 2007. p. 4177–4182. Citado na página 3.

KIM, D. et al. A new comprehensive rsu installation strategy for cost-efficient vanet deployment. **IEEE Transactions on Vehicular Technology**, IEEE, v. 66, n. 5, p. 4200–4211, 2017. Citado na página 5.

KUMRAI, T. et al. Rsu placement optimization in vehicular participatory sensing networks. In: IEEE. **Computer Communications Workshops (INFOCOM WKSHPS), 2014 IEEE Conference on**. [S.l.], 2014. p. 207–208. Citado 8 vezes nas páginas vi, 4, 5, 25, 26, 30, 31 e 37.

LEE, J.; KIM, C. M. A roadside unit placement scheme for vehicular telematics networks. In: **Advances in computer science and information technology**. [S.l.]: Springer, 2010. p. 196–202. Citado na página 5.

LIU, Y. et al. File downloading oriented roadside units deployment for vehicular networks. **Journal of Systems Architecture**, Elsevier, v. 59, n. 10, p. 938–946, 2013. Citado na página 5.

LOUREIRO, A. A. et al. Redes de sensores sem fio. In: SN. **Simpósio Brasileiro de Redes de Computadores (SBRC)**. [S.l.], 2003. p. 179–226. Citado na página 6.

MARTINS, F. V. et al. On a vector space representation in genetic algorithms for sensor scheduling in wireless sensor networks. **Evolutionary computation**, MIT Press, v. 22, n. 3, p. 361–403, 2014. Citado na página 18.

MARTINS, F. V. C. Operadores geométricos para otimizacao dinâmica com aplicacao ao problema de cobertura e conectividade em redes de sensores sem fio nao-hierárquicas. 2012. Citado na página 19.

MASSOBRIO, R. et al. Smart placement of rsu for vehicular networks using multiobjective evolutionary algorithms. In: IEEE. **2015 Latin America Congress on Computational Intelligence (LA-CCI)**. [S.l.], 2015. p. 1–6. Citado na página 5.

OTA, K. et al. Smart infrastructure design for smart cities. **IT Professional**, IEEE, v. 19, n. 5, p. 42–49, 2017. Citado 3 vezes nas páginas 3, 4 e 5.

OTT, J.; KUTSCHER, D. Drive-thru internet: Ieee 802.11 b for"automobile"users. In: IEEE. **INFOCOM 2004. Twenty-third AnnualJoint Conference of the IEEE Computer and Communications Societies**. [S.l.], 2004. v. 1. Citado na página 1.

PACHECO, M. A. C. et al. Algoritmos genéticos: princípios e aplicações. **ICA: Laboratório de Inteligência Computacional Aplicada. Departamento de Engenharia Elétrica. Pontifícia Universidade Católica do Rio de Janeiro. Fonte desconhecida**, p. 28, 1999. Citado 2 vezes nas páginas 8 e 9.

PHILLIPS, S. **Financial times: The future dashboard**. 2001. Citado na página 1.

REBAI, M. et al. Optimal placement in hybrid vanets-sensors networks. In: IEEE. **Wireless Advanced (WiAd), 2012**. [S.l.], 2012. p. 54–57. Citado na página 3.

REIS, A. B.; SARGENTO, S.; TONGUZ, O. K. On the performance of sparse vehicular networks with road side units. In: IEEE. **Vehicular Technology Conference (VTC Spring), 2011 IEEE 73rd**. [S.l.], 2011. p. 1–5. Citado na página 2.

ROJAS, I. et al. Statistical analysis of the main parameters involved in the design of a genetic algorithm. **IEEE Transactions on Systems, Man, and Cybernetics, Part C (Applications and Reviews)**, IEEE, v. 32, n. 1, p. 31–37, 2002. Citado 2 vezes nas páginas 10 e 11.

RUIZ, L. B. et al. Arquiteturas para redes de sensores sem fio. **Tutorial of the simpósio Brasileiro de Redes de Computadores e Sistemas Distribuídos(SBRC)**, 2004. Citado na página 6.

SARUBBI, J. F. et al. A grasp based heuristic for deployment roadside units in vanets. In: IEEE. **Integrated Network and Service Management (IM), 2017 IFIP/IEEE Symposium on**. [S.l.], 2017. p. 369–376. Citado na página 2.

SILVA, C. M. et al. Deposição ao gamma: Planejando a infraestrutura de comunicação ao para redes veiculares assegurando limites de tempo" entre-contatos" de veıculos com a infraestrutura. 2016. Citado na página 6.

SILVA, C. M. da; MEIRA, W. Evaluating the performance of heterogeneous vehicular networks. In: IEEE. **Vehicular Technology Conference (VTC Fall), 2015 IEEE 82nd**. [S.l.], 2015. p. 1–5. Citado na página 6.

SILVA, T. R. et al. Algoritmos baseados na metaheurística grasp para implantação de unidades de comunicação em redes veiculares garantindo qualidade de serviço. 2016. Citado na página 15.

STEWART, J. **Cálculo, vol. 1**. 6. ed. [S.l.]: Thompson, 2009. 307, 308 p. Citado na página 11.

TAKAHASHI, R. H. et al. A multiobjective methodology for evaluating genetic operators. **IEEE Transactions on Magnetics**, IEEE, v. 39, n. 3, p. 1321–1324, 2003. Citado na página 18.

WANG, C. et al. A mobility clustering-based roadside units deployment for vanet. In: IEEE. **The 16th Asia-Pacific Network Operations and Management Symposium**. [S.l.], 2014. p. 1–6. Citado na página 6.

WEBER, A. **Ueber den standort der industrien**. [S.l.: s.n.], 1909. v. 1. Citado na página 3.

WU, T.-J. et al. A cost-effective strategy for road-side unit placement in vehicular networks. **IEEE Transactions on Communications**, v. 60, n. 8, p. 2295–2303, 2012. Citado na página 3.

WU, Y.; ZHU, Y.; LI, B. Infrastructure-assisted routing in vehicular networks. In: IEEE. **INFOCOM, 2012 Proceedings IEEE**. [S.l.], 2012. p. 1485–1493. Citado na página 2.

XIE, B. et al. Roadside infrastructure placement for information dissemination in urban its based on a probabilistic model. In: SPRINGER. **IFIP International Conference on Network and Parallel Computing**. [S.l.], 2013. p. 322–331. Citado na página 5.

ZEADALLY, S. et al. Vehicular ad hoc networks (vanets): status, results, and challenges. **Telecommunication Systems**, Springer, v. 50, n. 4, p. 217–241, 2012. Citado na página 1.

ZHANG, B. et al. Energy-efficient roadside units deployment in vehicular ad hoc networks. IET, 2015. Citado na página 6.

ZHENG, Z. et al. Maximizing the contact opportunity for vehicular internet access. In: IEEE. **INFOCOM, 2010 Proceedings IEEE**. [S.l.], 2010. p. 1–9. Citado na página 5.

ZITZLER, E.; DEB, K.; THIELE, L. Comparison of multiobjective evolutionary algorithms: Empirical results. **Evolutionary computation**, MIT Press, v. 8, n. 2, p. 173–195, 2000. Citado na página 25.