

# Análise da Dinamicidade Espacial e Temporal das Comunidades em Redes Veiculares

Carlos A. P. de Souza<sup>1</sup>, Ademar T. Akabane<sup>2</sup>, Edmundo R. M. Madeira<sup>1</sup>

<sup>1</sup>Instituto de Computação – Universidade Estadual de Campinas (UNICAMP)  
Cidade Universitária - Brasil

<sup>2</sup>Centro Ciências Exatas, Ambientais e de Tecnologia – Pontifícia  
Universidade Católica de Campinas (PUC-Campinas), Brasil

carloso Souza@lrc.ic.unicamp.br, ademar.akabane@puc-campinas.edu.br,  
edmundo@ic.unicamp.br

**Resumo.** *A alta mobilidade dos veículos e as mudanças das condições do tráfego em relação ao tempo e ao espaço fazem com que a topologia das redes ad hoc veiculares (VANETs) seja altamente dinâmica. Assim, o desenvolvimento de aplicações/serviços em VANETs é uma tarefa desafiadora e muitas vezes requer a compreensão das características e da dinamicidade da topologia ao longo do tempo. Neste contexto, este trabalho analisa a dinamicidade da topologia das VANETs na formação de comunidades e também na sua evolução em relação ao tempo e ao espaço. Essa análise muitas vezes se faz necessária antes do desenvolvimento de qualquer serviço, além disso, ajuda a determinar se uma determinada aplicação é viável nesse tipo de rede.*

**Abstract.** *The high mobility of vehicles and the changes in traffic conditions across time and space make the topology of vehicular ad hoc networks (VANETs) highly dynamic. Thus, the development of applications/services in VANETs is a challenging task and often requires understanding the characteristics and dynamics of the topology over time. In this context, this work analyzes the dynamics of the topology of VANETs in the formation of communities and also in their evolution in time and space. This analysis is often necessary before the development of any service, and it also helps to determine if a particular application is viable in this type of network.*

## 1. Introdução

Sabe-se que a frota de veículos em circulação vem aumentando de forma significativa em todo o mundo. Segundo Ministério da Infraestrutura [Ministério da Infraestrutura 2021], em 2021, o Brasil possuía uma frota composta de 53 milhões de veículos automotores em circulação, isso corresponde à 5ª maior frota do mundo. Outro ponto que vale a pena destacar é que, cada vez mais, as indústrias automotivas vêm embarcando tecnologias computacionais em seus veículos para aumentar o conforto e a segurança dos usuários.

O poder computacional embarcado nos veículos, individualmente, pode ser insuficiente para realizar tarefas além da determinada. No entanto, em conjunto/grupo esse poder muitas vezes é significativo, podendo realizar outras tarefas [da Costa et al. 2020]. Nesse contexto, surge uma questão: como reunir os veículos para formação de grupos (ou comunidades) para explorar os recursos computacionais ociosos? Como resposta a essa questão, há um paradigma de redes *ad hoc* veiculares (VANETs) que pode ser aplicada na formação. As VANETs conquistaram grande destaque a partir do momento em que as indústrias automotivas incorporaram dispositivos de computação e comunicação

nos veículos. Essa incorporação estabeleceu possibilidades dos veículos trocarem dados de forma autônoma com outros veículos (comunicação Veículo-para-Veículo), com a infraestrutura de rede (comunicação Veículo-para-Infraestrutura), com os pedestres (comunicação Veículo-para-Pedestre), e assim por diante. Então, esse paradigma permite a troca de informações entre veículos, e entre veículos e outros dispositivos finais.

As VANETs foram amplamente exploradas em aplicações de disseminação de dados [Akabane et al. 2015] e controle de congestionamento [Akabane et al. 2020], por exemplo. Destacam-se, também, alguns trabalhos que analisaram a conectividade em VANETs [Shilin et al. 2016, Das and Misra 2018]. No entanto, os trabalhos existentes não analisaram a detecção e a evoluções das comunidades em VANETs. Vale mencionar que, por um lado, os algoritmos de detecção de comunidades foram inicialmente propostos para grafos estáticos. Por outro lado, as VANETs são constituídas por redes altamente dinâmicas (grafos dinâmicos). Logo, devido a essa dinamicidade, a formação/detecção de comunidades em VANETs não é uma tarefa fácil [Xu et al. 2014, Das and Misra 2018]. Com isso, estudos mais profundos sobre a detecção e a evolução das comunidades em VANETs podem beneficiar outros paradigmas como *Vehicular Cloud Computing* e também outras aplicações que dependem da formação de comunidades para realizar suas tarefas [Das and Misra 2018]. Assim, a compreensão das características topológicas desse tipo de rede é fundamental para o desenvolvimento de soluções eficientes que utilizam como base as VANETs.

Com base no contexto apresentado, este trabalho tem como objetivo avaliar a formação e a evolução das comunidades auto-organizadas e dinâmicas em VANETs. Nos experimentos foi utilizado um segmento de mapa real da cidade de Erlangem - Alemanha. Além disso, a solução proposta foi avaliada em relação ao tempo e ao espaço das comunidades formadas.

As contribuições desse estudo são: (i) compreensão do comportamento das comunidades geradas nas VANETs; (ii) caracterização das comunidades formadas nas VANETs; e (iii) possibilidade de utilização das comunidades em VANETs para apoiar ou propor novos protocolos ou aplicações.

O restante do documento está organizado da seguinte forma: a Seção 2 apresenta a fundamentação teórica para a compreensão deste trabalho. Na Seção 3 são apresentados os trabalhos relacionados. A proposta deste trabalho é apresentada na Seção 4, enquanto que na Seção 5 é feita a avaliação da proposta. Por fim, na Seção 6 é apresentada a conclusão além de trabalhos futuros.

## **2. Fundamentação Teórica**

Nesta seção são apresentados os conceitos necessários para a compreensão deste trabalho. Na Subseção 2.1 é descrito o conceito de comunidades e seus benefícios. Na Subseção 2.2 é apresentado o conceito de modularidade. Enquanto, na Subseção 2.3 é descrito o Método de Louvain.

### **2.1. Comunidades**

Encontrar uma definição qualitativa de comunidade é desafiadora, tendo em vista que, não há uma definição que seja universalmente aceita [Bedi and Sharma 2016]. A definição muitas vezes depende do sistema específico e/ou aplicação que se tem em mente. Em decorrência disso, supõe-se que uma comunidade deve possuir mais arestas vinculando vértices internos do que com o restante do grafo. Esta é a diretriz de referência base da maioria das definições de comunidade. Entretanto, muitas outras são compatíveis

com ela. Além disso, muitas das vezes, as comunidades são definidas por “softwares”, ou seja, são apenas o produto final do algoritmo, sem uma definição precisa a “priori” [Fortunato 2010].

Em virtude disso, as comunidade em redes sociais podem ser caracterizadas como um grupo de entidades com relações mais próximas entre si do que com outras, ou seja, é constituída por indivíduos que interagem constantemente uns com os outros [Bedi and Sharma 2016]. Já em grafo, uma comunidade, também denominada de *clusters* ou módulos, pode ser definida como um conjunto de vértices que possuem características comuns e/ou desempenham funções semelhantes [Fortunato and Hric 2016].

### 2.1.1. Benefícios da Comunidade

O benefício de participar ou se registrar em uma comunidade de rede social *on-line* provém do nível de satisfação ou satisfação de necessidades específicas do usuário. O estudo de [Hagel and Armstrong 1997] deixa evidente que os membros aproveitam essencialmente de algumas vantagens, por exemplo: (i) suporte e relacionamento social; (ii) intercâmbio de informações; (iii) benefícios econômicos; e (iv) entretenimento. Cada um deles é descrito da seguinte maneira:

- **Suporte social e relacionamentos:** As necessidades dos membros podem ser atendidas ao se conectar socialmente com outros membros da comunidade para encontrar novos amigos e pessoas afins. Além disso, o apoio social é oferecido por essas pessoas quando enfrentam problemas pessoais na vida. Por exemplo, a comunidade existente sobre doenças e doenças graves como câncer, ou pacientes cardíacos críticos, fornece uma plataforma para seus membros compartilharem seus sentimentos emocionais e esperanças em relação à doença, trocar experiências de dor com outros membros semelhantes na comunidade;
- **Intercâmbio de informações:** Uma das maiores vantagens de fazer parte de uma comunidade é facilitar as informações postadas/fornecidas pelos outros membros sobre tópicos de interesse que podem resolver muitos problemas de usuários específicos;
- **Benefícios econômicos:** As decisões do usuário tomadas através da troca de informações e experiências com outros membros existentes na comunidade, pode resultar em benefícios econômicos. Por exemplo, conseguir um acordo de compra melhor para um produto e eventualmente acabar com uma decisão de compra é muito influenciado pelos membros da comunidade;
- **Entretenimento:** Uma comunidade fornece um ambiente agradável, onde os membros podem desfrutar de papéis de personagens virtuais, jogar juntos ou apenas postar e consumir texto, fotos e vídeos para se divertir.

O estudo de [Ridings and Gefen 2017] demonstra que o motivo difere do tipo de comunidade. Além disso, a necessidade de participação dos usuários pode mudar de acordo com o objetivo da comunidade. Outros estudos determinaram que a motivação para participar de uma comunidade advém das necessidades de informação, auto-descoberta, valorização social, manutenção da conectividade interpessoal e valor de entretenimento [Ridings and Gefen 2017]. Portanto, fatores sociais, informações, entretenimento e fatores extrínsecos, como benefícios econômicos ou orientados a *status*, são considerados os benefícios mais dominantes, o que aumenta a permanência dos membros em suas respectivas comunidades [Park et al. 2009].

## 2.2. Modularidade

O problema na identificação de comunidades reside em localizar, em um determinado grafo, um agrupamentos de vértices que possuam características comuns ou desempenham funções semelhantes [Fortunato and Hric 2016]. No entanto, ao aplicar algoritmos de identificação/deteccção de comunidades a um conjunto de dados, seja este do mundo real ou sintético, as estruturas de comunidades ainda não são conhecidas [Chakraborty et al. 2017]. Portanto, é necessário que se utilize uma métrica para avaliar a qualidade das comunidades identificadas. Diversas métricas podem ser utilizadas para avaliar a qualidade das comunidades e a semelhanças de seus membros [Chakraborty et al. 2017]. Dentre as métricas que podem ser utilizadas, a modularidade, proposta por [Girvan and Newman 2002, Newman 2006] é a mais utilizada na literatura [Chaudhary and Singh 2019]. Além disso, esta métrica de qualidade também é utilizada na avaliação dos algoritmos que desempenham a tarefa de identificação de comunidades.

A modularidade é uma métrica que avalia o quão densamente estão conectados os vértices entre si, utilizando uma escala de -1 a 1. Nessa escala quanto mais próximo de 1 melhores são as estruturas das comunidades e -1 é o caso contrário. Portanto, a intenção é atribuir cada vértice do grafo a uma comunidade de tal maneira que a modularidade seja máxima. A função de modularidade é definida formalmente por [Girvan and Newman 2002, Newman 2006], veja a Equação 1.

$$Q = \frac{1}{2m} \sum_{ij} \left( A_{ij} - \frac{k_i k_j}{2m} \right) \delta(C_i, C_j) \quad (1)$$

onde  $m$  é o número de arestas do grafo. o parâmetro  $A$  denota a matriz de adjacência, onde  $A_{ij}$  é igual a 1 se houver uma aresta entre os vértices  $i$  e  $j$ , e 0 caso contrário.  $k_i$  e  $k_j$  são os graus dos vértices  $i$  e  $j$  respectivamente,  $C_i$  e  $C_j$  são as comunidades dos vértices  $i$  e  $j$  respectivamente.  $\delta$  é a função de Kronecker, onde  $\delta(C_i, C_j)$  é igual a 1 se os vértices  $i$  e  $j$  pertencem à mesma comunidade, e 0 caso contrário.

## 2.3. Método Louvain

O Método Louvain (ML) é um algoritmo heurístico que busca maximizar a modularidade de uma rede, ponderada ou não, com  $N$  vértices proposto por [Blondel et al. 2008]. Este algoritmo possui vantagens adicionais em relação a outros, por exemplo, uma menor complexidade computacional ( $O(n \log n)$ , em que  $n$  é o número total de vértices do grafo) e comunidades com maiores valores de modularidade, ou seja, mais conectados entre si. Além disso, é um método amplamente utilizado para identificar estruturas de comunidades em redes complexas estáticas devido à sua escalabilidade em grafos de grande dimensão [Chaudhary and Singh 2019].

Seu funcionamento é segmentado em duas fases que são repetidas iterativamente. Na primeira fase, cada vértice constitui uma comunidade. Em seguida, para cada vértice  $i$ , analisa-se seus  $j$  vizinhos e avalia-se o ganho de modularidade que ocorreria desvinculando  $i$  de sua comunidade e vinculando-o na comunidade de  $j$ . Ao término da avaliação, o vértice  $i$  é associado a outra comunidade se a nova modularidade for maior que a anterior, caso contrário ele permanece em sua comunidade. Esse processo é aplicado a todos os vértices até que não haja melhoria adicional. A primeira fase finaliza quando não existirem vértices que possam ser alterados a fim de maximizar a modularidade.

Na segunda fase é construída uma nova rede cujos vértices são as comunidades identificadas na primeira fase. Para realizar essa operação, os pesos das arestas entre

os novos vértices é definido somando o peso das arestas entre os vértices nas duas comunidades correspondentes. Além disso, as arestas entre vértices pertencentes a mesma comunidade levam a *auto-loops* na nova rede.

A execução das duas fases do ML denominam-se passos. Os passos ocorrem até que não sejam detectadas mudanças e a máxima modularidade seja obtida. Em virtude disso, o número de comunidades diminui a cada iteração e o maior tempo de computação é gasto na primeira execução do algoritmo.

O ganho na modularidade  $\Delta Q$ , obtida ao mover um nó isolado  $i$  para uma comunidade  $C$ , pode ser calculada por

$$\Delta Q = \left[ \frac{\sum_{\text{in}} + 2k_{i,\text{in}}}{2m} - \left( \frac{\sum_{\text{tot}} + k_i}{2m} \right)^2 \right] - \left[ \frac{\sum_{\text{in}}}{2m} - \left( \frac{\sum_{\text{tot}}}{2m} \right)^2 - \left( \frac{k_i}{2m} \right)^2 \right]$$

onde  $\sum_{\text{in}}$  é a soma dos pesos dos *links* dentro de  $C$ ,  $\sum_{\text{tot}}$  é a soma dos pesos dos *links* incidentes nos nós em  $C$ ,  $k_i$  é a soma dos pesos dos *links* incidentes no nó  $i$ ,  $k_{i,\text{in}}$ , é a soma dos pesos dos *links* do nó  $i$  aos nós em  $C$  e  $m$  é a soma dos pesos de todos os *links* na rede.

### 3. Trabalhos Relacionados

Diversos estudos propuseram a criação de algoritmos que utilizam vários indicadores para a identificação de comunidades. Utiliza-se a identificação de comunidades principalmente em redes sociais, com o intuito de agrupar pessoas que possuem os mesmos interesses. Nesta seção, são apresentadas algumas estratégias de identificação de comunidades desenvolvidas para redes sociais estáticas, rede com baixa dinamicidade e adaptadas para VANETs.

Em [Newman 2004] o autor utiliza uma nova abordagem para a identificação de comunidades. Esta nova abordagem utiliza um método aglomerativo que otimiza o ganho de modularidade para cada agregação de comunidades. Clauset *et al.* [Clauset et al. 2004] ampliaram o estudo [Newman 2004] a fim de atender grandes redes. Blondel *et al.* [Blondel et al. 2008] construíram um algoritmo heurístico aglomerativo mais eficiente para identificar a estrutura da comunidade em grandes redes com base na otimização da modularidade. Ele funciona em duas fases que são repetidas iterativamente. Na primeira fase, avalia-se o ganho de modularidade alterando a comunidade do vértice  $v_i$  para a comunidade do vértice vizinho  $v_j$ . Se houver ganho na modularidade, o vértice  $v_i$  é colocado na comunidade do vértice vizinho à qual seu ganho de modularidade é máximo, caso contrário, permanece em sua comunidade. Este processo é repetido para todos os vértices até que nenhuma melhoria adicional possa ser feita. Na segunda fase, uma nova rede é construída considerando as comunidades da primeira fase como vértices e as arestas recebem peso que são iguais à soma dos pesos das arestas entre vértices pertencentes a comunidades diferentes. Arestas que estão entre vértices pertencentes à mesma comunidade são tratadas como um auto-laço para essa comunidade na nova rede. A primeira fase é reaplicada a esta rede reduzida. Este processo é repetido até que nenhuma melhoria adicional no ganho de modularidade possa ser alcançada.

Em [Herbiet and Bouvry 2010] foi proposto um algoritmo distribuído chamado SHARC. Esse algoritmo utiliza o conhecimento local para dividir os vértices das redes *ad hoc* móveis em comunidades baseadas na semelhança de vizinhança. A semelhança de vizinhança entre dois vértices  $u$  e  $v$  é calculada como a razão entre o número de vizinhos comuns e o seu número total de vizinhos. O vértice  $u$  é atribuído à comunidade de  $v$  com a qual sua pontuação é alta. Herbiet *et al.* [Herbiet et al. 2011]

propuseram um novo algoritmo chamado SAND/SHARC (*Stability And Network Dynamics over Sharper Heuristic for Assignment of Robust Communities*) baseado no SHARC. No entanto, o SAND/SHARC utiliza um mecanismo baseado no paradigma de propagação de marcadores epidêmicos para favorecer a geração de comunidades robustas. Em [Herbiet and Bouvry 2011] os autores refinaram o algoritmo SHARC e nomearam-no de SAw-SHARC (*Stability Aware Sharper Heuristic for Assignment of Robust Communities*) para detectar comunidades em redes sociais *ad hoc* móveis dinâmicas e adicionaram a métrica de estabilidade da conexão enquanto atribuíam comunidades.

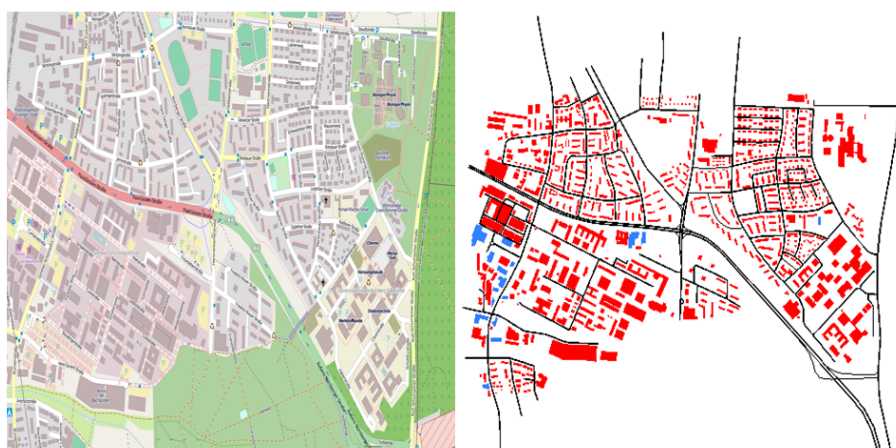
Grzybek *et al.* [Grzybek et al. 2014] estenderam o algoritmo SAw-SHARC para detectar comunidades estáveis em VANETs. Essa nova versão utiliza a duração do link e a similaridade de mobilidade como métrica de estabilidade. Além disso, faz as associações dos veículos a comunidade com base na pontuação máxima obtida. No entanto, as alterações realizadas no algoritmo SAw-SHARC para suportar as VANETs, não obtiveram bons resultados em cenários urbanos. Esses resultados podem estar relacionados com as métricas (duração do enlace e similaridade de mobilidade) utilizadas para a formação das comunidade, que em cenários altamente dinâmicos, se alteram com alta frequência. Além disso, o algoritmo SAw-SHARC foi desenvolvido para ser utilizado em redes dinâmicas com baixa mobilidade. Em razão disso, este trabalho busca adaptar o Método de Louvain, Subseção 2.3, para realizar a identificação de comunidades em VANETS, que priorize a alta densidade de *links* entre os membros, em vez da estabilidade.

#### 4. Proposta do Trabalho

A identificação de comunidades em redes não é um tema recente. Existem na literatura diversos estudos que já propuseram algoritmos para a identificação de comunidades tanto em grandes redes estáticas quanto em redes sociais dinâmicas que possuem baixa mobilidade. No entanto, a identificação de comunidades em redes altamente dinâmicas, por exemplo as VANETs, ainda possui um número reduzido de estudos. Dentre os estudos descritos na Seção 3, apenas o estudo desenvolvido por Grzybek *et al* [Grzybek et al. 2014] aborda este tema.

As comunidades podem fornecer diversos benefícios a seus participantes, como descrito na Subseção 2.1.1. Esses benefícios podem ser explorados pelas diversas aplicações desenvolvidas para VANETs, tais como, os Sistemas de Transporte Inteligentes. No entanto, antes de explorarmos os benefícios das comunidades em prol das aplicações desenvolvidas para VANETs, é necessário conhecermos as principais características das comunidades que são constituídas por este tipo de rede. Logo, neste estudo são analisadas as estruturas das comunidades identificadas nas VANETs em relação ao tempo e ao espaço ao longo das simulações. Para essa análise foi utilizado um segmento de mapa da cidade de Erlangen - Alemanha, veja a Figura 1. A simulação foi executada durante 433 segundos e contou com 500 veículos no cenário que possuíam deslocamento aleatório e com raio de comunicação de 150 metros.

Para realizar a identificação das estruturas de comunidades nas VANETs foi necessária a realização de alterações básicas no ML, descrito na Subseção 2.3, para que ele suporte grafos dinâmicos. Estas alterações foram realizadas em dois pontos: o arquivo de entrada e o número de passos. O Algoritmo 1 descreve o ML convertido para grafos dinâmicos utilizado por este estudo. Devido às VANETs serem redes altamente dinâmicas foi necessário substituir o arquivo de entrada estática do ML por um que permita representar o grafo dinâmico e todos os seus eventos. Em virtude disso, o Algoritmo 1 recebe como entrada um arquivo do tipo DGS (*Dagesh Pro Document*). Este tipo de arquivo permite armazenar dados de grafos estáticos ou dinâmicos de forma textual legível por



**Figura 1. Segmento de mapa da cidade de Erlangen/Alemanha. A figura da esquerda foi importada do OSM e a da direita representa a topologia da estrada utilizada nas simulações.**

humanos consumindo pouco espaço em disco. O fluxo de um grafo dinâmico é definido utilizando eventos como adicionar, excluir ou alterar um nó ou aresta, bem como, é possível adicionar, alterar e remover atributos no grafo, nós ou arestas. Isso permitirá analisarmos as alterações que ocorrem no grafo segundo a segundo.

Vale destacar que, antes da geração do arquivo DGS foi necessário realizar algumas etapas: (i) geração de traços veiculares de acordo com o cenário utilizado; (ii) obtenção de dados dos veículos (*Floating Car Data*) que representam as posições dos veículos (nós do grafo) a cada instante de tempo; e (iii) geração de *links* de comunicação (arestas do grafo) a cada instante de tempo.

Sobre a proposta do trabalho, foi necessária a redução no número de passos para que possamos avaliar a evolução de todas as comunidades ao longo do tempo. Tendo em vista que, o objetivo deste estudo não é propor um novo algoritmo ou aperfeiçoar o ML, mas avaliar a dinamicidade das comunidades identificadas em relação ao tempo e ao espaço.

O funcionamento do Algoritmo 1 é segmentado em duas etapas. Na primeira etapa é realizada a associação dos nós a uma comunidade inicial, caso não esteja associado a uma (linhas de 3 a 5). Em poucas palavras, na primeira etapa, cada veículo inicialmente pertence a uma comunidade de um único nó. Em seguida, nas linhas 8 a 16, é avaliado, para cada nó, o ganho de modularidade obtido ao mover o nó da comunidade que ele pertence para a comunidade de seu vizinho. Se o ganho máximo for positivo, a comunidade do nó é alterada, caso contrário permanece na comunidade em que está. Todas estas etapas são repetidas até que não haja mais instantes a serem lidos.

## 5. Avaliação da Proposta

A dinamicidade das comunidades aqui avaliadas está relacionada ao número de veículos presentes em cada instante de simulação. Nos experimentos de simulação foram analisados: (i) o número de comunidades identificadas e o número de veículos em relação ao tempo de simulação; (ii) evolução da comunidade em relação ao tempo; e (iii) quantidade de *links* presentes em cada comunidade. Após esta etapa inicial, analisamos também: o número médio de comunidades, o tamanho médio das comunidades e o número médio de *links* nas comunidades em relação ao tempo total da simulação.

---

**Algoritmo 1:** Método de Louvain convertido para grafos dinâmicos

---

**Entrada:** Arquivo DGS contendo os Vértices ( $V$ ), Arrestas ( $A$ ) e seus eventos no Tempo ( $T$ ).

**Resultado:** As comunidades detectadas e suas evoluções longo do tempo.

```
1 início
2   enquanto existir um próximo instante  $t_i \in T$  faça
3     para cada vértice  $v_i \in V$  faça
4       se  $v_i$  sem comunidade então
5         cria uma comunidade inicial para  $v_i$ ;
6       fim
7     fim
8     enquanto houver ganho de modularidade faça
9       para cada vértice  $v_i \in V$  faça
10        enquanto existir  $v_j$  vizinho de  $v_i$  faça
11          avalia o ganho de modularidade que seria obtido ao mover
12            o vértice  $v_i$  para a comunidade de  $v_j$ ;
13          fim
14          se o ganho máximo for positivo então
15             $v_i$  é movido para a comunidade do vizinho na qual o ganho
16              foi máximo;
17          senão
18             $v_i$  permanece em sua comunidade;
19          fim
20        fim
21      fim
22    fim
```

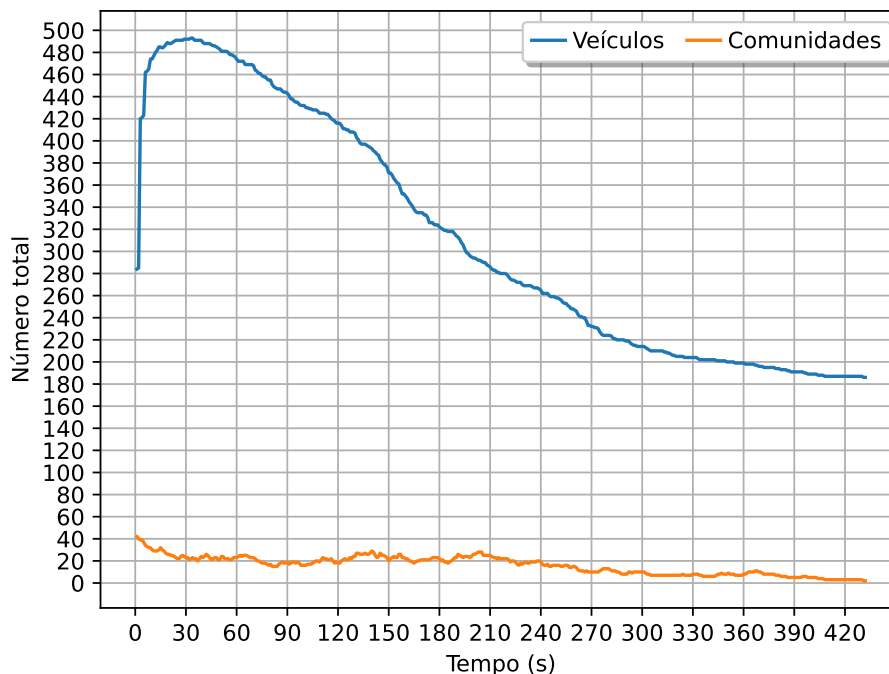
---

## 5.1. Resultados dos Experimentos

A relação entre o número de veículos e o número comunidades que ocorre ao longo tempo é demonstrada na Figura 2. Nesta figura, primeiramente pode-se observar que a variação no total de veículos é um dos fatores que tem baixa influência na formação das comunidades. O aumento no número de veículos não é determinante para que aconteça uma grande oscilação no número de comunidades, essa característica pode ser observada nas Figuras 6(a) e 6(b), uma vez que, os novos veículos podem ingressar em comunidades já existentes. Este comportamento é um reflexo dos eventos que podem ocorrer na estrutura da comunidade, por exemplo, o surgimento ou desaparecimento, a junção ou separação, aumento ou contração [Dakiche et al. 2019, Fortunato 2010]. Esta característica pode ser observada nos primeiros 35 segundos de simulação, quando o número de veículos que entram na simulação aumenta gradativamente de aproximadamente 285 para próximo de 500 veículos. Porém, o número de comunidades sofre uma redução, indo de aproximadamente 40 para 21. A redução no número de comunidades foi em decorrência de um ou mais eventos que ocorreram devido aos veículos estarem mais próximos entre si, ou seja, dentro do raio de comunicação. Em virtude disso, as comunidades que se formam podem ou não possuir um grande número de integrantes associados a elas. Por outro lado, quando mais esparsos (fora do raio de comunicação) estiverem os veículos, maior o número de comunidades com alguns participantes. Todos estes eventos estão diretamente associados aos veículos, uma vez que, a comunidade é constituída de maneira dinâmica.



Logo, um veículo, durante a sua trajetória, pode mudar de comunidade diversas vezes até atingir seu destino.

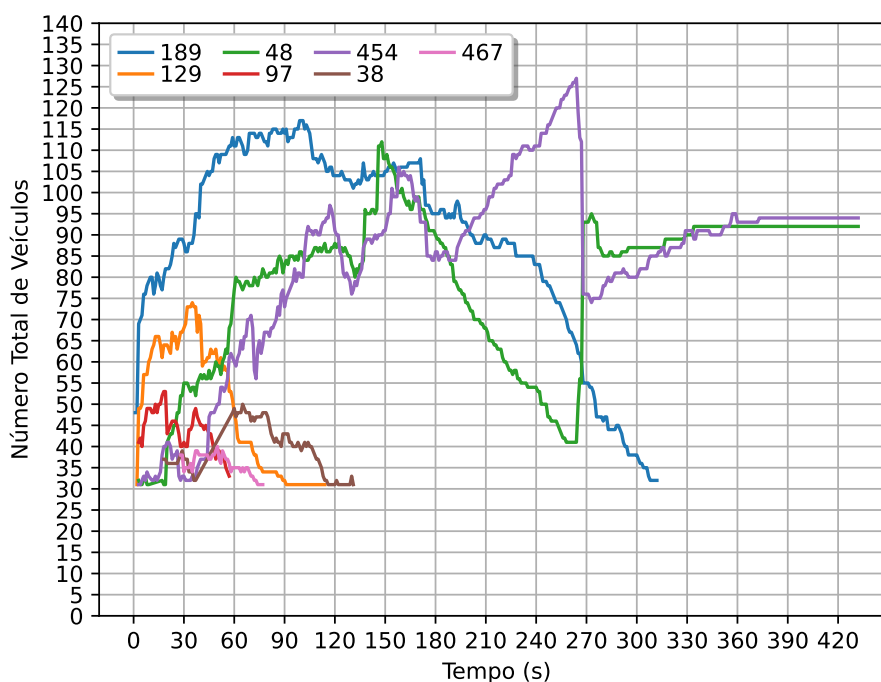


**Figura 2. Total de veículos e comunidades em relação ao tempo**

Sabe-se que, os eventos que ocorrem nas comunidades impactam diretamente em sua evolução ao longo do tempo. Para compreendermos esse impacto, foram analisadas as comunidades que possuíam 30 ou mais nós/veículos. A evolução dessas comunidades ao longo do tempo está representada na Figura 3. Ao observamos atentamente a figura, nota-se que somente 7 comunidades possuíram 30 ou mais associados. Dentre estas comunidades, destacam-se a 48, 189 e 454, pois estas foram as que, durante a sua existência, mais sofreram alterações em sua estrutura. Só nos primeiros 110 segundos de simulação, estas 3 comunidades tiveram um aumento significativo, mesmo havendo uma redução no número de veículos, como demonstrado pela Figura 2. Este comportamento mostra que os veículos estão mais concentrados em 3 locais distintos e podem representar possíveis pontos de congestionamento, como ilustrado na Figura 6(d).

Além da evolução das comunidades, também avaliamos o quanto os veículos estão conectados entre si, observando o número de *links* internos das comunidades. A Figura 4 ilustra o total de *links* presentes nas comunidades, que possuíam 30 ou mais integrantes, ao longo do tempo. Analisando a Figura 4 (total de *links*) e a Figura 3 (evolução das comunidades) em conjunto, observa-se que os gráficos possuem comportamentos semelhantes. Nas figuras podemos notar que há uma relação diretamente proporcional entre o número de veículos e o total *links*, ou seja, quanto maior o número de integrantes nas comunidades, maior o número de *links* que os conectam. Este comportamento já era esperado, uma vez que, o algoritmo utilizado para a identificação de comunidades utiliza como métrica de qualidade a modularidade (Subseção 2.2), a qual busca maximizar o número de *links* internos das comunidades.

Outra característica avaliada foi a média, tanto do número e tamanho das comunidades, quanto do número de *links*. As informações foram obtidas a partir dos dados de todas as comunidades ao longo do tempo e estão representadas na Figura 5. A



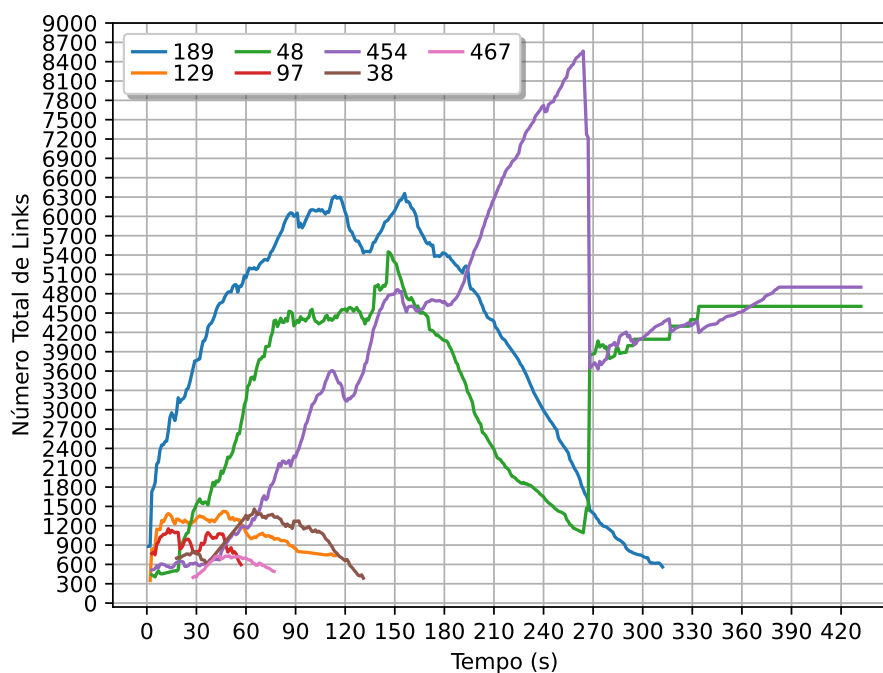
**Figura 3. Evolução das comunidades**

Figura 5(a) representa a dispersão das comunidades ao longo do tempo. Nela pode-se observar que a frequência do total de comunidades identificadas não apresenta uma distribuição simétrica, ou seja, há uma frequência maior de comunidades entre 27 e 32 unidades, do que, entre 24 e 25. Além disso, nota-se que o número médio de comunidades foi de 26 unidades. Já na Figura 5(b), é demonstrada a dispersão do tamanho das comunidades. Nesta figura observa-se que o tamanho médio das comunidades foi de aproximadamente 32 integrantes e que o tamanho das comunidades não apresenta uma distribuição simétrica. Houve uma maior dispersão de comunidades que possuíram de 33 a 84 participantes, do que, comunidades com 12 a 31. Enquanto o número médio de *links* internos das comunidades, demonstrado pela Figura 4, foi de aproximadamente 600 unidades. Novamente não houve uma dispersão simétrica. Isso significa que existiram muito mais comunidades com *links* entre 601 a 4100 unidades, do que, com 0 (zero) a 599 unidades. Vale destacar que 0 (zero) *links* significa que o veículo está isolado, ou seja, esta fora do alcance de outros veículos.

A Figura 6 ilustra a evolução das comunidades em relação ao espaço em diferentes instantes de tempo. No instante 3 segundos, Figura 6(a), foram constituídas 40 comunidades de um total de 285 veículos. No instante seguinte, Figura 6(b), o total de veículos aumentou para 420 veículos e as comunidades sofreram uma redução em uma unidade, indo de 40 comunidades para 39. A Figura 6(c) ilustra o instante em que o número máximo de veículos, 492 unidades, esteve presente no cenário e constituíram 24 comunidades. Enquanto a Figura 6(d) mostra as 3 maiores comunidades formadas ao longo do tempo de simulação.

## 5.2. Considerações Finais

Sabe-se que mecanismos de detecção de comunidades foram amplamente aplicados em redes sociais para agrupar os membros em comunidades, de tal forma que as interações entre os membros da comunidade sejam maiores do que as interações fora dos membros da comunidade. Além disso, vale destacar que as estruturas das redes sociais pos-



**Figura 4. Links nas comunidades**

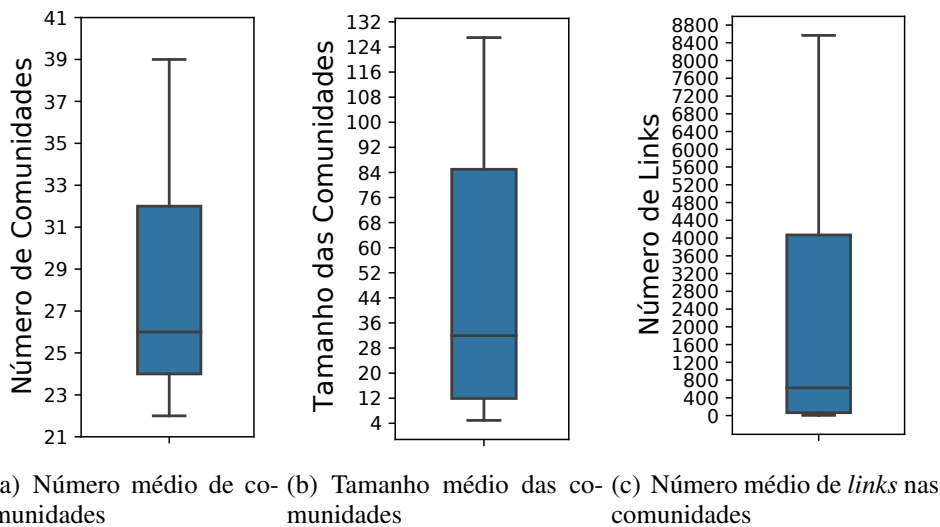
suem baixa dinamicidade, se comparada com as VANETs. Assim, a detecção de comunidades em VANETs é uma tarefa desafiadora, devido às características intrínsecas da rede [Kamakshi and Sriram 2020].

Comunidades no contexto das VANETs possuem como principal vantagem a existência de *links* de comunicação mais robustos entre os membros, uma vez que possuem uma densidade de arestas maior interligando-os. Em virtude disso o paradigma de *Vehicular Cloud Computing* (VCC) pode tirar proveito das comunidades para formação das nuvens veiculares [Boukerche and Robson 2018]. Além disso, vale destacar algumas aplicações de VCC que podem ser beneficiadas com o uso de comunidades, tais como gerenciamento de tráfego, Internet de veículos, alocação de recursos, entre outras [Boukerche and Robson 2018].

Vale destacar que cada cenário possui suas próprias características, assim a análise da evolução das comunidades não pode ser generalizada. Em poucas palavras, os resultados alcançados nesse trabalho estão diretamente relacionados com o cenário utilizado (segmento de mapa da cidade de Erlangen - Alemanha). Além disso, o modelo de mobilidade aplicado também influencia na evolução da comunidade.

## 6. Conclusão

Neste estudo, foram identificadas comunidades em VANETs e analisadas as suas estruturas, utilizando uma versão convertida para grafos dinâmicos do Método de Louvain. O objetivo do trabalho foi analisar a dinamicidade das estruturas das comunidades em VANETs, com o intuito de estudar suas características e comportamentos ao longo do tempo. Além disso, avaliar sua potencialidade para a utilização por aplicações desenvolvidas para VANETs, por exemplo, VCC, Sistemas de Transporte Inteligentes, entre outras. Os resultados obtidos demonstram que as comunidades em VANETs são altamente dinâmicas e possuem uma alta densidade de conexões entre seus integrantes, uma vez que possuem tamanho médio significativo, tornando-as adequadas para utilização pelas VCCs.



**Figura 5. Resultado médio das métricas aplicadas.**

Foi demonstrado que a análise da dinamicidade das comunidades em VANETs é útil para inferir *insights* interessantes que permitem o desenvolvimento de novas aplicações/soluções ou a melhoria das atuais. Como trabalho futuro, pretende-se realizar essa mesma análise em cenário mais complexo, por exemplo: TAPASCologne<sup>1</sup> e também comparar com os resultados já alcançados. Adicionalmente, pretende-se analisar o comportamento da propagação de informação dentro e fora das comunidades. Além disso, pretende-se explorar a formação das comunidades nas VANETs para propor ou auxiliar o desenvolvimento de novos protocolos e aplicações, como por exemplo, protocolo para disseminação de dados, e a alocação de recursos utilizando o paradigma de VCC, entre outros.

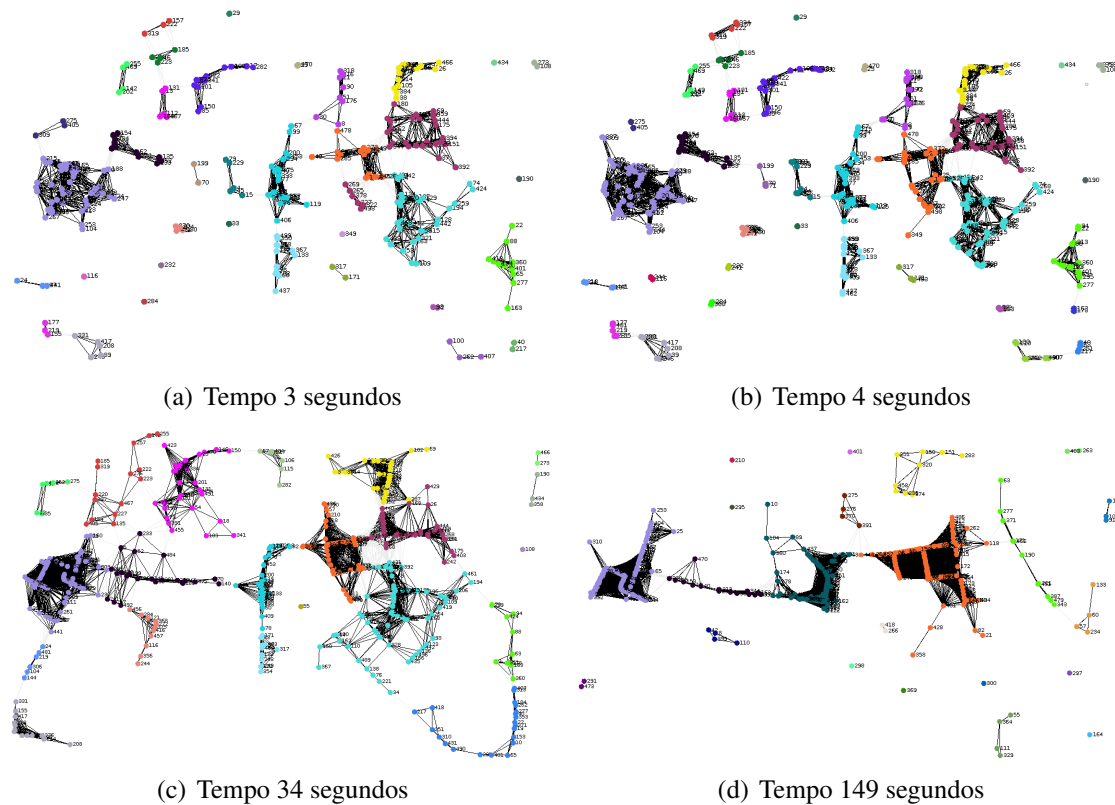
## Agradecimentos

Este trabalho faz parte do projeto INCT denominado Internet do Futuro para Cidades Inteligentes (CNPq 465446/2014-0, CAPES 88887.136422/2017-00 e FAPESP 2014/50937-1). O primeiro autor agradece o apoio financeiro da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Código de Financiamento 001.

## Referências

- Akabane, A. T., Immich, R., Bittencourt, L. F., Madeira, E. R., and Villas, L. A. (2020). Towards a distributed and infrastructure-less vehicular traffic management system. *Computer Communications*, 151:306–319.
- Akabane, A. T., Villas, L. A., and Madeira, E. R. M. (2015). An adaptive solution for data dissemination under diverse road traffic conditions in urban scenarios. In *2015 IEEE wireless communications and networking conference (WCNC)*, pages 1654–1659. IEEE.
- Bedi, P. and Sharma, C. (2016). Community detection in social networks. *WIREs Data Mining and Knowledge Discovery*, 6(3):115–135.

<sup>1</sup><http://kolntrace.project.citi-lab.fr/>



**Figura 6. Formação e evolução de comunidades em relação ao tempo e ao espaço.**

- Blondel, V. D., Guillaume, J.-L., Lambiotte, R., and Lefebvre, E. (2008). Fast unfolding of communities in large networks. *Journal of Statistical Mechanics: Theory and Experiment*, 2008(10):P10008.
- Boukerche, A. and Robson, E. (2018). Vehicular cloud computing: Architectures, applications, and mobility. *Computer networks*, 135:171–189.
- Chakraborty, T., Dalmia, A., Mukherjee, A., and Ganguly, N. (2017). Metrics for community analysis: A survey. *ACM Computing Surveys (CSUR)*, 50(4):1–37.
- Chaudhary, L. and Singh, B. (2019). Community detection using an enhanced louvain method in complex networks. In *International Conference on Distributed Computing and Internet Technology*, pages 243–250. Springer.
- Clauset, A., Newman, M. E. J., and Moore, C. (2004). Finding community structure in very large networks. *Phys. Rev. E*, 70:066111.
- da Costa, J. B., Meneguette, R. I., Rosário, D., and Villas, L. A. (2020). Combinatorial optimization-based task allocation mechanism for vehicular clouds. In *2020 IEEE 91st Vehicular Technology Conference (VTC2020-Spring)*, pages 1–5. IEEE.
- Dakiche, N., Tayeb, F. B.-S., Slimani, Y., and Benatchba, K. (2019). Tracking community evolution in social networks: A survey. *Information Processing & Management*, 56(3):1084–1102.
- Das, D. and Misra, R. (2018). Improvised dynamic network connectivity model for vehicular ad-hoc networks (vanets). *Journal of Network and Computer Applications*, 122:107–114.

- Fortunato, S. (2010). Community detection in graphs. *Physics Reports*, 486(3):75 – 174.
- Fortunato, S. and Hric, D. (2016). Community detection in networks: A user guide. *Physics Reports*, 659:1 – 44. Community detection in networks: A user guide.
- Girvan, M. and Newman, M. E. (2002). Community structure in social and biological networks. *Proceedings of the national academy of sciences*, 99(12):7821–7826.
- Grzybek, A., Seredynski, M., Danoy, G., and Bouvry, P. (2014). Detection of stable mobile communities in vehicular ad hoc networks. In *17th International IEEE Conference on Intelligent Transportation Systems (ITSC)*, pages 1172–1178.
- Hagel, J. and Armstrong, A. G. (1997). Net gain–profit im netz. *Märkte erobern mit virtuellen Communities*. Wiesbaden: Gabler.
- Herbiet, G. and Bouvry, P. (2010). Sharc: Community-based partitioning for mobile ad hoc networks using neighborhood similarity. In *2010 IEEE International Symposium on "A World of Wireless, Mobile and Multimedia Networks" (WoWMoM)*, pages 1–9.
- Herbiet, G. and Bouvry, P. (2011). On the generation of stable communities of users for dynamic mobile ad hoc social networks. In *The International Conference on Information Networking 2011 (ICOIN2011)*, pages 262–267.
- Herbiet, G., Bouvry, P., and Guinand, F. (2011). Social relevance of topological communities in ad hoc communication networks. In *2011 International Conference on Computational Aspects of Social Networks (CASoN)*, pages 19–24.
- Kamakshi, S. and Sriram, V. S. (2020). Modularity based mobility aware community detection algorithm for broadcast storm mitigation in vanets. *Ad Hoc Networks*, 104:102161.
- Ministério da Infraestrutura (2021). Frota de veículos - 2021. <https://www.gov.br/infraestrutura/pt-br/assuntos/transito/conteudo-denatran/frota-de-veiculos-2021>, Último acesso: 08/04/2022.
- Newman, M. E. (2006). Modularity and community structure in networks. *Proceedings of the national academy of sciences*, 103(23):8577–8582.
- Newman, M. E. J. (2004). Fast algorithm for detecting community structure in networks. *Phys. Rev. E*, 69:066133.
- Park, N., Kee, K. F., and Valenzuela, S. (2009). Being immersed in social networking environment: Facebook groups, uses and gratifications, and social outcomes. *Cyberpsychology & behavior*, 12(6):729–733.
- Ridings, C. M. and Gefen, D. (2017). Virtual Community Attraction: Why People Hang out Online. *Journal of Computer-Mediated Communication*, 10(1). JCMC10110.
- Shilin, P., Kirichek, R., Paramonov, A., and Koucheryavy, A. (2016). Connectivity of vanet segments using uavs. In *Internet of Things, Smart Spaces, and Next Generation Networks and Systems*, pages 492–500. Springer.
- Xu, C., Jia, S., Wang, M., Zhong, L., Zhang, H., and Muntean, G.-M. (2014). Performance-aware mobile community-based vod streaming over vehicular ad hoc networks. *IEEE transactions on Vehicular Technology*, 64(3):1201–1217.