

Modelo de Mobilidade para Encontros de Grupos

Ivan O. Nunes¹, Clayson Celes¹, Pedro O. S. Vaz de Melo¹, Antonio A. F. Loureiro¹

¹Departamento de Ciência da Computação – Universidade Federal de Minas Gerais (UFMG)
Av. Antônio Carlos, 6627 – Pampulha, 31270-901- Belo Horizonte - MG - Brazil

{ivanolive, claysonceles, olmo, loureiro}@dcc.ufmg.br

Abstract. *In this work we propose, implement and evaluate GRM, a novel mobility model that accounts for the role of group meeting dynamics and regularity in human mobility. Specifically, we show that the existent mobility models do not capture the regularity of human group meetings, an important aspect that should be included by synthetic mobility modeling since it is present in real mobility traces. Next, we characterize the statistical properties of such group meetings in real mobility traces and design GRM accordingly. We show that GRM maintains the typical pairwise contact properties that are also represented in other synthetic models in the literature, such as contact duration and inter-contact time distributions. In addition, GRM accounts for the role of group mobility, presenting group meetings regularity and social communities structure. Finally, we evaluate state-of-art social-aware protocols for opportunistic routing using a synthetic contact trace generated by our model. The results show that the behavior of such protocols in our model is similar to their behavior in real mobility traces.*

Resumo. *Neste trabalho é proposto, implementado e avaliado o GRM, um novo modelo de mobilidade que leva em consideração o papel dos encontros sociais de grupos e suas regularidades na mobilidade humana. Em particular, mostra-se que os modelos de mobilidade existentes na literatura não são capazes de capturar a regularidade dos encontros de grupos, um aspecto importante que deveria ser considerado por modelos sintéticos de mobilidade. Posteriormente, são caracterizadas as propriedades estatísticas dos encontros de grupos em traces de mobilidade coletados em ambientes reais e essas propriedades são utilizadas para projetar o GRM. Por meio de uma análise quantitativa, mostra-se que o GRM mantém as características estatísticas de propriedades tipicamente representadas em outros modelos da literatura, como o tempo entre os contatos e a duração dos contatos. Além disso, o GRM é capaz de modelar o papel dos encontros de grupos, sua regularidade e a existência de comunidades sociais. Finalmente, o desempenho dos protocolos de roteamento oportunístico do estado da arte são avaliados em traces sintéticos de mobilidade gerados pelo GRM. Os resultados mostram que o comportamento destes protocolos no GRM se assemelha ao comportamento apresentado em traces reais de mobilidade.*

1. Introdução

Modelos de mobilidade têm importância fundamental no projeto de redes móveis e de infraestrutura urbana [Treurniet 2014]. Eles permitem a geração de trajetórias sintéticas para nós móveis em ambientes simulados que podem ser usados para avaliar o desempenho de novos protocolos de roteamento. A validação de tais protocolos em grande escala no mundo real é frequentemente inviável devido a vários fatores, tais como custo financeiro e limitações operacionais. Nesse sentido, modelos sintéticos permitem uma avaliação rápida do desempenho de protocolos de roteamento considerando longos períodos de tempo na implantação dos protocolos e um grande número de nós na rede.

Nos últimos anos, diversos modelos de mobilidade foram propostos com o objetivo de reproduzir uma ou mais propriedades estatísticas da mobilidade humana. Exemplos de tais propriedades incluem deslocamento humano [Gonzalez et al. 2008], regularidade espacial [Ekman et al. 2008], trajetórias de pessoas e de veículos [Silva et al. 2015], padrões de encontros entre pessoas (par-a-par) [Kosta et al. 2014, Lee et al. 2009] e mobilidade de grupos de pessoas [Hong et al. 1999, Blakely and Lowekamp 2004, Musolesi and Mascolo 2006].

A propriedade de mobilidade de grupos possui papel fundamental no projeto de redes móveis [Treurniet 2014]. No entanto, os modelos de mobilidade de grupos existentes focam em modelar grupos que se mantêm juntos durante todo o período de simulação. Portanto, tais modelos não representam a regularidade estatística das interações humanas, i.e., grupos de pessoas que se encontram regularmente. Trabalhos recentes [Nunes et al. 2016a, Cruz and Miranda 2015, Starnini et al. 2014, Nunes et al. 2016b] têm mostrado que a regularidade dos encontros de grupos, existentes em *traces* reais de mobilidade, tem função importante no encaminhamento de mensagens em redes móveis oportunísticas.

Embora estudos anteriores [Ekman et al. 2008, Kosta et al. 2014, Lee et al. 2009] tenham focado em reproduzir a regularidade de contatos, esses modelos somente reproduzem a regularidade de encontros entre pares de entidades, i.e., eles somente modelam contatos entre duas pessoas, desconsiderando as interações sociais coletivas. Portanto, eles não contemplam os encontros de grupos. Essa limitação é especialmente prejudicial à validação de protocolos de roteamento oportunístico (e.g., DTN e D2D), visto que estratégias cientes do contexto social [Hui et al. 2011, Li et al. 2014] são consideradas as mais eficazes para essa classe de protocolos. Consequentemente, nenhum dos modelos de mobilidade avaliam propriamente as abordagens cientes do contexto social no roteamento oportunístico, dado que eles não capturam completamente a regularidade social presente na mobilidade humana.

Com o objetivo de abordar as questões mencionadas acima, no presente trabalho trabalho propõe-se o *Group Regularity Mobility (GRM) Model*¹. Por meio de experimentos, realizados nos modelos de mobilidade do estado da arte amplamente utilizados na literatura, mostra-se que o GRM é o primeiro modelo de mobilidade que considera o papel dos encontros de grupos e suas regularidades para simular a mobilidade humana. Mostra-se que estrutura de comunidades sociais, regularidade dos encontros de grupos e padrões estatísticos de tempo entre contatos e duração de contatos, os quais estão presentes em *traces* reais, estão presentes nos *traces* gerados pelo GRM. Além disso, verificou-se que o desempenho de protocolos de roteamento em *traces* sintéticos gerado pelo GRM é similar ao obtido em *traces* reais.

2. Trabalhos Relacionados

Mobilidade de grupos é considerada umas das principais características na modelagem de mobilidade [Treurniet 2014]. No entanto, os modelos de mobilidade de grupos existentes focam na modelagem de grupos nos quais os nós permanecem juntos durante todo o tempo de simulação [Aung et al. 2015]. Além disso, modelos de mobilidade que objetivam modelar a regularidade de padrões de contatos humanos somente consideram contatos entre pares de pessoas [Ekman et al. 2008, Kosta et al. 2014, Lee et al. 2009], ignorando o fato

¹*Traces* sintéticos de mobilidade gerados a partir do GRM contendo 100, 1000, e 2000 nós estão disponíveis juntamente com um vídeo de demonstração no simulador The ONE [Keränen et al. 2009] em "<https://www.dropbox.com/sh/792mi849nf3dvam/AAAR4RofaLBfoFaxmeONE-H4a?dl=0>". Código fonte disponível em: "<https://github.com/ivanolive/GRM>".

de que contatos sociais frequentemente envolvem mais que duas pessoas, como foi demonstrado recentemente em [Nunes et al. 2016a].

Os estudos sobre modelos de mobilidade de grupos são restritos a representar grupos como uma entidade em que as pessoas se deslocam juntas. Por exemplo, *Reference Point Group Mobility* (RPGM) [Hong et al. 1999] e *Reference Velocity Group Mobility* (RVGM) [Wang and Li 2002] são variantes de modelos aleatórios para mobilidade de grupos. Em ambos os modelos, pessoas são organizadas em grupos de acordo com um relacionamento lógico. Cada grupo contém um líder e os membros de cada grupo se movem de acordo com o respectivo líder. Esses modelos de mobilidade são baseados em determinadas propriedades do movimento, tais como velocidade, direção e aceleração, e não exprimem propriedades dos contatos (i.e., encontros) entre as entidades. Portanto, tais modelos não são capazes de reproduzir as propriedades estatísticas que são relevantes para o roteamento oportunístico.

Alguns estudos têm focado em modelos baseados em propriedades estatísticas (e.g., distribuição de deslocamento, frequência de visita em localizações diferentes) obtidas a partir de padrões espaciais e temporais. Lee et al. [Lee et al. 2009] propõem um modelo de mobilidade, chamado *Self-similar Least Action Walk* (SLAW), que captura as seguintes propriedades: distribuição de deslocamento seguindo uma *power-law* truncada, tempos de espera e tempos entre contatos, força de atração para os lugares mais populares e a heterogeneidade de áreas definidas pela mobilidade individual. O modelo usa essas propriedades para representar a mobilidade das pessoas que compartilham lugares comuns de encontro, ou seja, lugares mais visitados no dia-a-dia.

O modelo SWIM (*Small World in Motion*) [Kosta et al. 2014] é baseado na intuição que pessoas se deslocam frequentemente para lugares próximos ou populares. Essa intuição é sustentada pelos resultados obtidos por Gonzalez et al. [Gonzalez et al. 2008] que revelam regularidades espaciais e temporais no movimento. No SWIM a cada pessoa (nó) é atribuída uma casa (*home*) e probabilidades de se deslocarem até os possíveis destinos de acordo com suas popularidades e com a distância da casa da pessoa até o local. SLAW e SWIM são capazes de reproduzir as distribuições dos tempos entre contatos e das durações dos contatos assim como elas ocorrem em *traces* reais. No entanto, esses modelos consideram apenas contatos par-a-par, ignorando a mobilidade de grupos ou qualquer relação entre mais que dois nós.

Musolesi e Mascolo [Musolesi and Mascolo 2007] propuseram um modelo de mobilidade baseado na teoria de redes sociais, denominado *Community based Mobility Model* (CMM). O modelo recebe como entrada uma rede social e aplica um algoritmo de detecção de comunidades nela. A partir disso, os movimentos dos nós são determinados pelos relacionamentos sociais entre eles. A intuição é que nós se deslocam para lugares onde eles possuem alto grau de relacionamento social. Boldrini e Passarella [Boldrini and Passarella 2010] apresentam o HCMM (*Home Cell Mobility Model*), uma evolução do CMM, que considera que pessoas se deslocam para determinados destinos de acordo com a localização do destino e relacionamentos sociais. Assim como o SWIM, o HCMM adota o conceito de *home location* e a movimentação dos nós é condicionada aos relacionamentos sociais entre eles. Além disso, os nós tendem a visitar poucos locais com alta frequência e tendem a preferir locais próximos a suas casas. Nesses modelos, a estrutura de comunidade é introduzida na mobilidade do nós para gerar um contexto social. Enquanto que no GRM, a estrutura de comunidade emerge naturalmente a partir, tanto da regularidade de encontros dos grupos, como da dinâmica de composição dos grupos, refletindo o que acontece no mundo real.

Ekman et al. [Ekman et al. 2008] introduz um modelo de mobilidade chamado

Working Day Movement Model (WDM) com o objetivo de modelar o comportamento diário de pessoas. WDM simula rotinas diárias de pessoas considerando seus deslocamentos entre casa e local de trabalho. WDM expressa a regularidade da mobilidade humana, mas ele não possui representatividade quanto a mobilidade de grupos, como será mostrado na Seção 3.

O GRM é uma evolução dos modelos citados anteriormente, incluindo todas as propriedades deles e também a regularidade dos encontros de grupos. A Seção 3 mostra que o estado da arte de modelos de mobilidade não são representativos quanto a regularidade estatística de interações humanas quando tais interações envolvem grupos.

3. Mobilidade de Grupos: Mundo real vs Modelos sintéticos

Nesta seção, *traces* sintéticos gerados a partir de modelos de mobilidade amplamente utilizados na literatura são comparados com *traces* de mobilidade reais visando verificar se a propriedade da regularidade dos encontros de grupos é capturada por tais modelos. Mais especificamente, mostra-se que tais modelos não são capazes de capturar os encontros de grupos e suas regularidades ao longo do tempo. Nesse sentido, surge a oportunidade para concepção de um modelo ciente de tal propriedade, de modo que os protocolos de redes possam ser validados em cenários mais realistas.

Primeiramente, aplica-se uma metodologia baseada em grafos temporais para detectar e rastrear grupos, como descrito em [Nunes et al. 2016a], em dois *traces* reais de mobilidade, MIT e Dartmouth. Os *traces* MIT [Eagle and Pentland 2006] e Dartmouth [Henderson et al. 2008] são compostos por registros de proximidade entre nós (contatos) contendo 80 e 1200 usuários, respectivamente. No *trace* MIT, os usuários residem em dois prédios na universidade e foram monitorados por quase um ano. Contatos foram registrados quando dois usuários estavam a menos de 10 metros um do outro. O *trace* de Dartmouth registrou contatos entre estudantes no campus da universidade por dois meses usando registro de conectividade Wi-Fi. O contato entre dois estudantes é capturado quando eles se encontram conectados ao mesmo ponto de acesso Wi-Fi. Dartmouth é o *trace* real de maior escala publicamente disponível em termos de número de usuários monitorados. Por outro lado, o MIT é o *trace* publicamente disponível que possui maior período de monitoramento dos usuários.

As Figuras 1(a) e 1(b) mostram a função densidade de probabilidade (PDF) dos reencontros de grupos ao longo do tempo para os *traces* reais. Em ambos os *traces* reais, verifica-se a presença da periodicidade dos encontros dos grupos. Particularmente, a massa de probabilidade está concentrada nos picos destacados pelas linhas vermelhas pontilhadas que representam períodos de 24 horas. Além disso, nas Figuras 1(a) e 1(b), observa-se que os picos maiores acontecem em torno das linhas verdes pontilhadas que marcam períodos de sete dias. Esse padrão observado nessas PDFs mostra que os encontros de grupos nos *traces* reais possuem periodicidades diárias e semanais. Vale ressaltar que esse padrão é observado em ambos os *traces* reais. Em seguida, são analisados três modelos sintéticos de mobilidade amplamente utilizados na literatura para verificar se eles são capazes de representar o papel dos grupos sociais na mobilidade humana.

O modelo SWIM [Kosta et al. 2014] gera *small worlds* sintéticos que seguem as distribuições estatísticas da duração de contatos e tempo entre contatos de pares de pessoas como é observado nos *traces* reais de mobilidade. O SLAW [Lee et al. 2009] foi projetado para representar diversas propriedades estatísticas da mobilidade humana, tais como: distribuição *power-law* truncada dos deslocamentos das pessoas, tempos de pausa, tempo entre contatos e popularidades heterogêneas de regiões. O WDM [Ekman et al. 2008] foi projetado para representar as mesmas propriedades de duração de contatos e tempo entre contatos que o SWIM e o SLAW. Além disso, o WDM

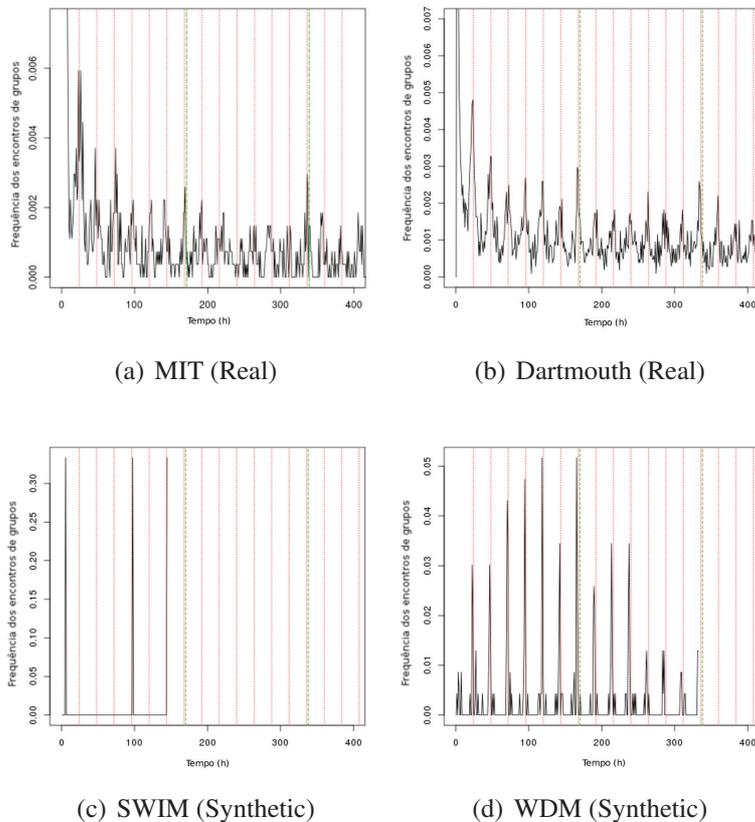


Figura 1. Comparação da regularidade dos encontros de grupos entre *traces* reais e sintéticos de mobilidade

tem o propósito de imitar a regularidade diária da mobilidade humana, i.e., como as rotinas humanas alteram a mobilidade das pessoas.

A mesma metodologia de detecção e rastreamento de grupos, aplicada aos *traces* reais MIT e Dartmouth, foi empregada para esses três modelos sintéticos. As Figuras 1(c) e 1(d) apresentam os resultados obtidos de *traces* sintéticos gerados a partir do SWIM e do WDM, respectivamente. Pode-se observar que o *trace* de contatos gerado pelo modelo SWIM (Figura 1(c)) não possui qualquer regularidade de encontros de grupos. Dentre os grupos detectados, apenas três reencontros de grupos foram registrados em um período de 15 dias. O mesmo comportamento foi apresentado pelo *trace* de contatos gerado pelo modelo SLAW (figura omitida), ou seja, nenhuma regularidade nos encontros dos grupos. Esse resultado é explicado pelo fato de que tais modelos foram projetados para representar apenas as propriedades estatísticas de contatos par-a-par, sem considerar que os contatos humanos frequentemente envolvem mais de duas pessoas. Em relação ao *trace* WDM (Fig. 1(d)), observa-se que os reencontros de grupos acontecem precisamente no período de 24 horas e com frequência maior que a percebida em *traces* reais. Isso ocorre porque o WDM primeiro define um conjunto de lugares, chamados *offices*, e distribui os nós para transitar entre um subconjunto de *offices* predefinidos com periodicidade diária. Portanto, nós com interseções em suas listas de *offices* sempre formarão grupos com regularidade exagerada de encontros.

Analisando a regularidade dos encontros dos grupos nos modelos sintéticos, conclui-se que nenhum deles representa adequadamente o padrão de mobilidade de grupos observado em *traces* reais. Portanto, a Seção 4 introduz o GRM, um modelo de mobilidade que representa as propriedades estatísticas da regularidade dos encontros de

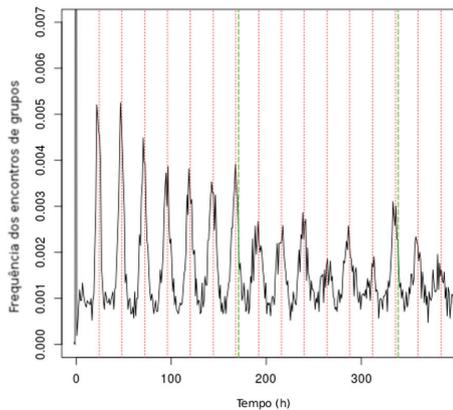


Figura 2. Regularidade dos encontros de grupo no modelo proposto

grupos. Como pode ser visto na Figura 2, ao contrário dos modelos de mobilidade da literatura, o GRM é capaz de produzir traces de mobilidade que apresentam a regularidade dos encontros dos grupos.

4. O modelo GRM

Nesta seção, o GRM é descrito em detalhes. A Figura 3 apresenta um *framework* do funcionamento do GRM. O GRM recebe como entrada um grafo social que pode ser um grafo social real, fornecido pelo usuário, ou um grafo gerado por um modelo sintético de rede social. Trata-se de um grafo não direcionado em que cada nó é uma pessoa e cada aresta representa o relacionamento social entre dois nós. A implementação do GRM da suporte a diversos modelos de rede sociais, incluindo Barabasi-Albert [Barabási and Albert 1999], Gaussian Clustering [Brandes et al. 2003], Caveman [Watts 1999], and Random Partition Graph [Fortunato 2010]. O grafo social é usado para definir quais nós irão ser membros de cada grupo, i.e., a estrutura dos grupos, como descrito posteriormente.

O GRM também recebe como entrada um conjunto de parâmetros de simulação como o tamanho da região simulada, a duração da simulação, o número de nós e o número de grupos. Além disso, alguns parâmetros estatísticos devem ser fornecidos como entrada, pois esses parâmetros são utilizados pelas distribuições estatísticas contidas no modelo. Os *traces* sintéticos gerados pelo GRM são compatíveis e podem ser importados diretamente para o simulador de redes oportunísticas The ONE [Keränen et al. 2009]. A Tabela 1 apresenta um resumo da notação que será utilizada na descrição do modelo ao longo desta seção.

4.1. Tempo entre os encontros dos grupos

Para projetar adequadamente um modelo mobilidade para a regularidade de grupos é necessário um modelo estatístico para os tempos entre os encontros dos grupos. Devido à periodicidade dos encontros de grupos apresentada na Figura 1, os tempos dos encontros de grupo são modelados da seguinte forma.

Cada grupo G_i no modelo recebe um tempo médio entre encontros, μ_{G_i} . O valor de μ_{G_i} é gerado aleatoriamente de acordo com uma distribuição *power-law* com corte exponencial. Essa forma de gerar μ_{G_i} é baseada no fato que o tempo entre contatos de *traces* de mobilidade real segue essa distribuição, como discutido nas Seções 1 e 2.

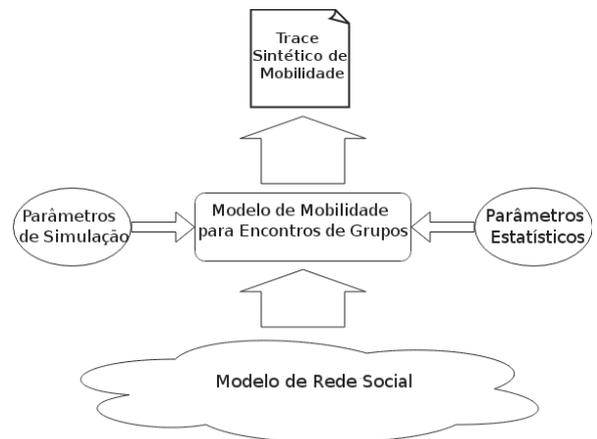


Figura 3. Framework do modelo GRM

Tabela 1. Notação

Notação	Descrição
T	A duração do <i>trace</i>
$NodesSet$	O conjunto de todos os nós da rede
G_i	O i -ésimo grupo de nós no <i>trace</i>
$ G_i $	O número de membros no Grupo G_i
T_{G_i}	O período de existência do grupo G_i
μ_{G_i}	O tempo médio entre encontros para G_i
$Meeting_{G_i}(t)$	O instante para o t -ésimo encontro de G_i
Dur_{G_i}	A duração de encontro do grupo G_i
$u \sim U(a, b)$	$u \in \mathbb{R}$ é um valor selecionado aleatoriamente com probabilidade uniforme no intervalo $[a, b]$
$\eta \sim N(\mu, \sigma^2)$	$\eta \in \mathbb{R}$ é um valor selecionado aleatoriamente com distribuição Gaussiana de média μ e variância σ^2
$\rho \sim PL(\alpha, \beta)$	$\rho \in \mathbb{R}$ é um valor selecionado aleatoriamente com distribuição <i>truncated Power Law</i> com expoente α e corte exponencial β
$P_{att}[U_j, G_i]$	A probabilidade do usuário U_j participar do encontro do grupo G_i
$P_{place}(C_j, G_i)$	A probabilidade do encontro do grupo G_i acontecer na célula C_j

O expoente da *power-law* (α_{gmt}) e o valor do corte exponencial (β_{gmt}) são parâmetros estatísticos dados como entrada para o modelo. Assim, a série horários em que o grupo G_i irá se encontrar é recursivamente gerada como na Equação 1:

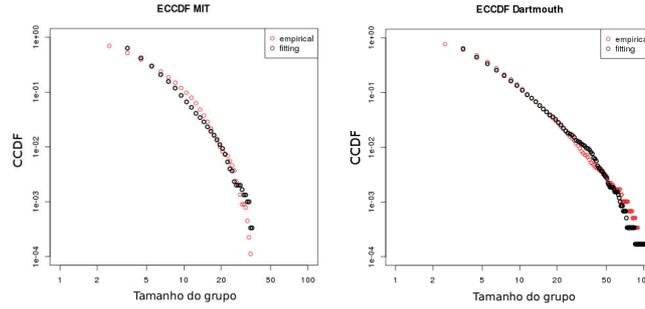
$$Meeting_{G_i}(t) = \begin{cases} \mu_{G_i} \sim PL(\alpha_{gmt}, \beta_{gmt}) & \text{se } t = 0 \\ u \sim U(0, T) & \text{se } t > 0 \end{cases} \quad (1)$$

Cada grupo G_i tem seu próprio μ_{G_i} . No entanto, a variância σ^2 é um parâmetro único para todos os grupos. Esse parâmetro permite o ajuste da pontualidade dos encontros do grupo de acordo com as propriedades da variância da distribuição Gaussiana. Seguindo recursivamente a Equação 1, para a geração dos encontros do grupo, cada grupo terá seu conjunto de encontros determinado como:

$$\bigcup_{j=0}^{\lceil \frac{T_{G_i}}{K \times \mu_{G_i}} \rceil} Meeting_{G_i}(j) \quad (2)$$

onde T_{G_i} denota o intervalo durante o qual o grupo G_i existe. O GRM considera que cada grupo G_i tem sua própria periodicidade que é representada pelo escalar K na Equação 1. Por exemplo, a maioria dos encontros de grupos com $K = 24h$ ocorrem a cada 24, 48, ou 72 horas, seguindo a função de densidade de probabilidade *power-law* para gerar os valores μ_{G_i} . K é o multiplicador que gera o comportamento periódico mostrado na Figura 1, enquanto que o valor de μ_{G_i} , obtido a partir de uma *power-law* truncada, gera tempos entre contatos estaticamente representativos da realidade.

Como cada grupo tem seu próprio valor de K , a distribuição para valores de K é dada para o modelo como parâmetro de simulação. Por exemplo, “A simulação possuirá 500 grupos; 70% desses grupos irão ter $K = 24h$, 15% irão ter $K = 7days$ e 15% $K = 6h$ ”. Na Seção 5 mostra-se que esse exemplo de configuração para a distribuição de K gera reencontros de grupos que são similares aos observados nos *traces* reais MIT e Dartmouth.



(a) $\alpha = 2.24; \beta = 30.4$. Tamanho médio do grupo: 6.06 pessoas
 (b) $\alpha = 2.42; \beta = 54.6$. Tamanho médio do grupo: 6.96 pessoas

Figura 4. Tamanhos dos grupos: dados empíricos dos traces MIT e Dartmouth e seu fitting em *power-laws* truncadas de expoentes α e cortes exponenciais β .

4.2. Duração dos Encontros de Grupos

Uma vez gerados os tempos entre encontros de grupo, o próximo passo consiste em definir a duração dos encontros, i.e., o tempo que os nós do grupo permanecerão juntos. Para isso, como discutido nas Seções 1 e 2, estudos na literatura mostram que a duração dos contatos em cenários reais segue uma *power-law* truncada. Portanto, de forma analoga à geração do valor de μ_{G_i} na Equação 1, a duração do encontro de um grupo é definida como:

$$Dur_{G_i} \sim PL(\alpha_{dur}, \beta_{dur}) \quad (3)$$

onde α_{dur} e β_{dur} são parâmetros estatísticos do GRM.

4.3. Estrutura dos Grupos e Contexto Social

As seções anteriores mostram como gerar o tempo entre encontros e a duração deles. Outro fator importante na modelagem do GRM é definir a composição dos grupos, i.e., determinar quais nós irão para cada encontro. Para tanto, verifica-se qual a distribuição do tamanho dos grupos em *traces* reais. Nos *traces* do MIT e Dartmouth, constata-se que o tamanho dos grupos segue uma *power-law* com corte exponencial com diferentes parâmetros, como pode ser observado em 4. Portanto, o número de membros em cada grupo G_i é definido como:

$$||G_i|| \sim PL(\alpha_{size}, \beta_{size}) \quad (4)$$

onde α_{size} e β_{size} são os últimos parâmetros estatísticos do GRM.

O GRM define os nós que irão compor um dado grupo G_i de tamanho $||G_i||$ (calculado de acordo com a Eq. 4) usando o algoritmo *snowball* [Berg 1988] probabilístico. Para fazer isso, um nó n é selecionado aleatoriamente com probabilidade uniforme a partir do conjunto de nós da rede. O algoritmo *snowball* seleciona aleatoriamente um conjunto de vizinhos de n . Em seguida, ele seleciona outro conjunto aleatório dentre os vizinhos dos vizinhos de n e assim por diante até que o conjunto de nós selecionados tenha tamanho $||G_i||$. Esse conjunto de nós selecionados formam o grupo G_i . O *snowball* recebe como entrada o grafo social dado como entrada ao GRM, dessa forma preserva-se a estrutura social da rede. Em resumo, a composição estrutural do grupo é definida como:

$$\begin{aligned} Node_n &= U(NodesSet) \\ Members_{G_i} &= Snowball(Node_n, ||G_i||, SocialGraph) \end{aligned} \quad (5)$$

Neste ponto, vale ressaltar que, como acontece na realidade, um único nó pode participar de vários grupos sociais. Além disso, o número de diferentes grupos possíveis é combinatório em relação ao número de nós. Na prática, o número de grupos detectados em um *trace* de mobilidade real é maior do que o número de nós existentes nesse *trace*. Por exemplo, cinco mil grupos diferentes foram detectados no *trace* de Dartmouth, que monitora apenas 1200 nós.

Ademais, na realidade, não é razoável esperar que todos os nós participem de todos os encontros de um determinado grupo. No GRM, cada usuário U_j , que é membro de um grupo G_i , recebe a probabilidade $P_{att}[U_j, G_i]$ de comparecer a um encontro de G_i definida como:

$$P_{att}[U_j, G_i] = \frac{Known(User_j, G_i, SocialGraph)}{||G_i||} \quad (6)$$

A intuição da probabilidade P_{att} é que uma pessoa tem uma probabilidade mais alta de comparecer a um encontro de um grupo em que ela conheça mais membros. A função *Known* retorna o número de nós em G_i que tem laços sociais (arestas) com U_j no grafo social (*SocialGraph*) recebido como entrada no GRM.

Usando essa modelagem, cada grupo social no *trace* tem uma composição diferente em cada encontro. No entanto o grupo mantém a maior parte de sua estrutura ao longo de todos os seus encontros. Esse comportamento também é apresentado nas relações sociais no mundo real [Nunes et al. 2016a].

4.4. Mobilidade e Locais dos Encontros

O passo final do GRM consiste em gerar a mobilidade dos nós mantendo as propriedades e encontros de grupos que foram definidas nas seções anteriores. A mobilidade no GRM é inspirada no modelo SWIM [Kosta et al. 2014]. No entanto, os nós não definem suas trajetórias individualmente. O grupo define o lugar mais apropriado para um benefício comum a todos membros, como descrito a seguir.

Como no SWIM, GRM define uma *home* para cada nó com probabilidade uniforme no espaço de simulação. Em seguida, o espaço de simulação é dividido em células quadradas de mesmo tamanho e cada grupo G_i atribui para cada célula C_j um peso que é proporcional a distância das células às *homes* de cada membro de G_i :

$$W(C_j, G_i) = \frac{1}{||G_i||} \sum_{U_k \in G_i} dist(Home(U_k), C_j) \quad (7)$$

Como no SWIM, no GRM a função *dist* tem um decaimento de *power-law* com a distância euclidiana. Isso permite a geração de deslocamentos dos nós de acordo com uma *power-law* truncada, como ocorre na realidade [Gonzalez et al. 2008]. Finalmente, cada célula C_j recebe a probabilidade de receber um encontro do grupo G_i como:

$$P_{place}(C_j, G_i) = \frac{W(C_j, G_i)}{\sum_{i=0}^{N_{cells}} W(C_i, G_i)} \quad (8)$$

onde N_{cells} denota o número total de células no espaço a ser modelado.

No GRM, os nós transitam entre *homes* e locais de encontros. Se o próximo encontro do grupo acontece antes do tempo necessário para um nó chegar na sua *home*, o nó transita diretamente entre os locais dos encontros.

5. Avaliação

Um modelo de mobilidade deve representar bem as propriedades que se pretende capturar. Nesta seção, mostra-se que os *traces* de mobilidade gerados pelo GRM mantêm as características típicas de mobilidade real, que são fundamentais para os protocolos de redes móveis oportunísticas.

A primeira propriedade avaliada no GRM é o tempo entre contatos par a par. O tempo entre contatos é uma métrica importante porque os contatos são as oportunidades para se encaminhar mensagens em redes reais. Vários estudos usam um grande número de *traces* reais para mostrar que as distribuições de tempo entre contatos e duração de contato seguem *power-laws* truncadas.

A Figura 5(a) compara a distribuição dos tempos entre contatos para o GRM e o *trace* de Dartmouth. Nota-se que a distribuição do tempo entre contato no GRM está de acordo com a apresentada no *trace* de Dartmouth. Ambas seguem *power-laws* com cortes exponenciais, em conformidade com os resultados para a mobilidade do mundo real relatados nos estudos anteriores.

Na Figura 5(b), observa-se que a distribuição de duração dos contatos também segue uma *power-law*, em conformidade com as distribuições mostradas na mobilidade humana real. A duração dos contatos é importante porque determina a quantidade de dados que podem ser transferidos durante um determinado contato.

A Figura 5(c) mostra que o GRM de fato simula bem a regularidade dos encontros de grupos. A distribuição dos tempos de reencontro dos grupos é muito semelhante à dos *traces* de mobilidade real (Figuras 1(a) and 1(b)). Nota-se a existência de picos em períodos de 24 horas e sete dias, ressaltando a presença de periodicidade diária e semanal. Este resultado confirma que o GRM cumpre o seu objectivo de modelar adequadamente o papel da regularidade das reuniões de grupo na mobilidade humana.

Finalmente, a Figura 5(d) apresenta um resultado importante. Ela ilustra as comunidades detectadas no *trace* do GRM usando o Método de Percolação de Cliques [Palla et al. 2005]. Tal resultado confirma que, a partir da geração de reuniões regulares de grupos, compostos de membros que compartilham vínculos sociais (definidos no grafo social dado como entrada), a estrutura de comunidades sociais surge naturalmente na rede móvel. Portanto, os *traces* gerados pelo GRM são representativos do contexto social envolvido na mobilidade humana.

6. Roteamento Oportunístico no GRM

Uma das características mais importantes de modelos de mobilidade é a representatividade do comportamento de protocolos para redes móveis. Com isso, nesta seção são avaliados, no GRM, alguns dos protocolos do estado da arte em roteamento oportunístico. Como as estratégias cientes de contexto social são as que apresentam o melhor desempenho nesse tipo de rede, a análise foca-se nesse tipo de protocolo. Especificamente, são avaliados os protocolos Flooding, Bubble Rap [Hui et al. 2011], e Groups-Net [Nunes et al. 2016b].

No protocolo Flooding, também comumente chamado de Epidemic, as mensagens sempre são propagadas quando um nó que detem a mensagem encontra um nó que não a

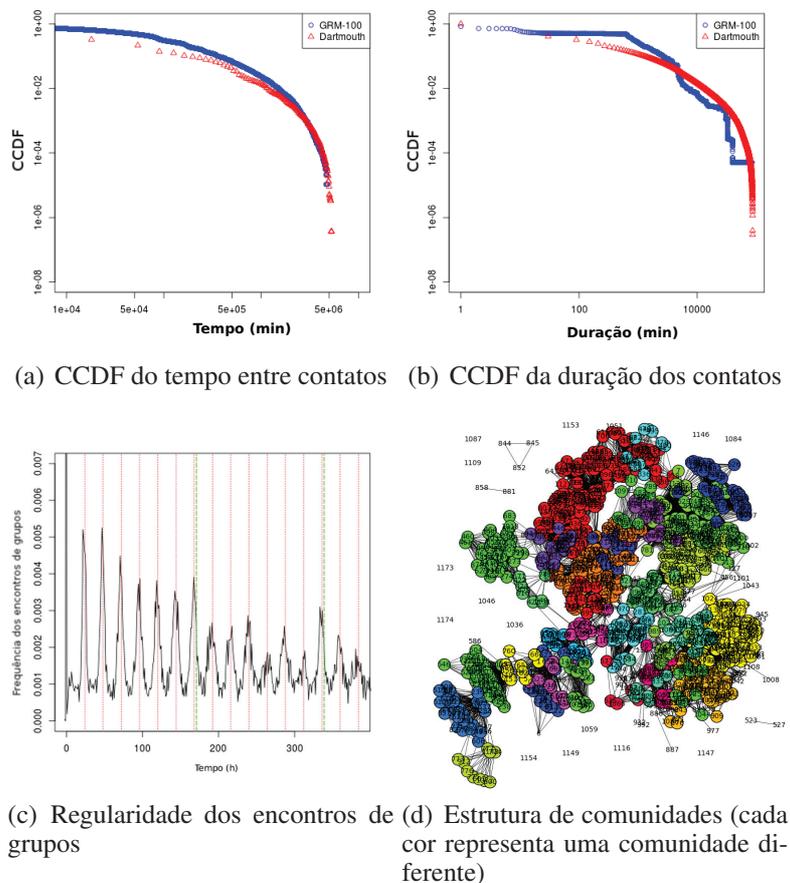


Figura 5. Propriedades importantes para o encaminhamento oportunístico que estão em *traces* e também no GRM

possui ainda. Em redes de maior escala esse protocolo não é um solução viável, tendo em vista que o número de retransmissões de mensagens cresce exponencialmente, gerando uma grande sobrecarga na rede. Porém, esse protocolo estabelece um limite superior para a taxa de entrega e para a sobrecarga da rede.

O algoritmo Bubble Rap identifica comunidades sociais a partir do grafo agregado de contatos entre nós do *trace*. Cada nó da rede deve pertencer a pelo menos uma comunidade. Nós que não pertençam a nenhuma comunidade são assinalados a uma pseudo-comunidade de apenas um nó. Esse procedimento é necessário para a operação do algoritmo. Além disso, cada nó recebe uma medida de sua popularidade global na rede (*GlobalRank*) e uma medida de sua popularidade local, que é válida apenas dentro da comunidade à qual o nó pertence (*LocalRank*). Usando essas métricas a estratégia de encaminhamento procede como a segue. A cada encontro, um determinado nó transmite o seu conteúdo se o nó encontrado apresentar um *GlobalRank* maior que o seu próprio ou se o nó pertencer à mesma comunidade do nó de destino. Uma vez que a mensagem encontra-se dentro da comunidade de destino o encaminhamento ocorre se o *LocalRank* do nó encontrado for maior do que o *LocalRank* do nó que possui a mensagem. Esse procedimento é executado até que a mensagem atinja o nó de destino.

O Groups-Net funciona encaminhando as mensagens do nó de origem até o nó de destino pela rota grupo-a-grupo mais provável. Para definir esta rota, o algoritmo considera a probabilidade de um grupo de nós se re-encontrar no futuro próximo e a probabilidade da mensagem ser carregada entre dois grupos por um nó que é membro

Tabela 2. Parâmetros de Simulação

Parâmetros	Cenários	
	GRM-100	GRM-1000
#Nós	100	1000
#Grupos	500	5000
Duração Sim.	60 days	
Duração Grupos	30 days	
Grid	30 x 30	
Tamanho Células	50	
α_{gmt}	2	
β_{gmt}	30 days	
α_{dur}	2	
β_{dur}	30 days	
α_{size}	2.24	2.42
β_{size}	30	50
K	70%-24h; 15%-7days; 15%-6h	
Grafo social	Gauss.R.P. [Brandes et al. 2003]	

de ambos. A probabilidade de um grupo se encontrar no futuro é definida baseada na ideia que grupos que se encontraram mais frequentemente no passado recente têm uma tendência maior a se re-encontrarem no futuro próximo.

Na avaliação foram consideradas as seguintes métricas:

- **Taxa de entrega:** Avalia a porcentagem de mensagens entregues ao nó destino para diferentes TTLs.
- **Número de retransmissões:** Mede a sobrecarga da rede, i.e., o número de transmissões dispositivo-dispositivo que cada algoritmo realiza para diferentes TTLs.

Algoritmos de encaminhamento oportunístico tem o objetivo de prover o melhor custo-benefício na entrega das mensagens, i.e., a maior taxa de entrega com o mínimo de sobrecarga na rede.

Para avaliar os algoritmos no GRM, foram gerados dois cenários de simulação contendo 100 e 1000 nós. Os parâmetros de simulação utilizados para cada cenário são especificados na Tabela 2. Cada um dos protocolos descritos foi executado com 10000 pares (*origem, destino*). O tempo de início da propagação para cada mensagem também é selecionado aleatoriamente dentro da duração do *trace*.

A Figura 6 apresenta o desempenho dos três protocolos considerados em traces sintéticos gerados pelo GRM. O resultado mostra que o desempenho desses algoritmos no GRM é similar ao seu desempenho em *traces* reais, conforme reportado nos trabalhos originais [Nunes et al. 2016b, Hui et al. 2011]. Os algoritmos cientes de contexto social apresentam altas taxas de entrega comparáveis à do Flooding. Por outro lado, ao explorar o contexto social, por meio de comunidades no Bubble Rap e por meio de encontros de grupos no Groups-Net, esses protocolos propiciam uma baixa sobrecarga na rede.

Com o aumento do número de nós na rede, de 100 para 1000, observa-se que a sobrecarga do protocolo Flooding cresce extremamente rápido, como esperado devido à sua política de encaminhamento promíscua. No *trace* com 100 nós, o Bubble Rap apresenta uma sobrecarga menor que o Groups-Net. Quando o número de nós na rede aumenta, a sobrecarga com o Groups-Net passa a ser menor do que a do Bubble Rap. Conforme discutido em [Nunes et al. 2016b], a sobrecarga do algoritmo Bubble Rap apresenta um aumento linear com o número de nós na rede. Esse comportamento é explicado pela natureza gulosa do encaminhamento do Bubble Rap. Por outro lado, a sobrecarga do Groups-Net tende a se manter estável com o aumento do número de nós na rede, tornando-o propício para redes de maior escala. O resultado apresentado nos *traces* gerados pelo GRM condiz com essa observação realizada a partir de traces reais.

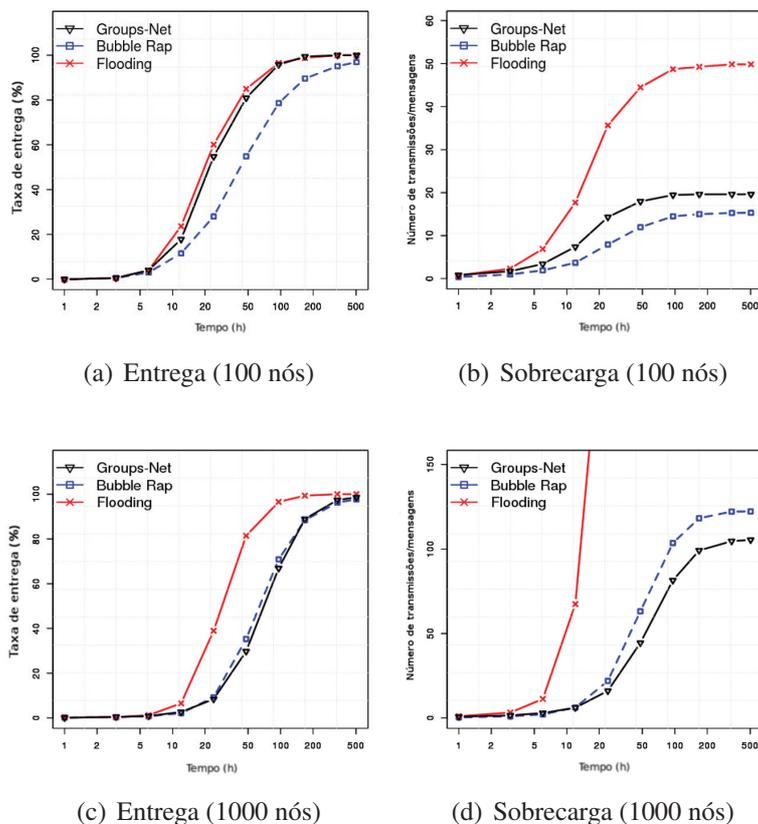


Figura 6. Desempenho do Flooding, Bubble Rap e Groups-Net em *traces* sintéticos gerados pelo GRM

7. Conclusão

Neste trabalho foi implementado e avaliado o GRM, um novo modelo de mobilidade projetado para representar a regularidade dos encontros de grupos e seu impacto na mobilidade humana. Observou-se que o GRM preserva as propriedades da mobilidade humana que são fundamentais para redes oportunísticas com tempo entre contatos, duração dos contatos, comunidades sociais e regularidade dos encontros de grupos. Além disso, mostrou-se que o desempenho de protocolos do estado da arte para redes oportunísticas têm, no GRM, um desempenho similar ao apresentado em cenários reais. *Traces* de mobilidade gerados pelo GRM e seu código fonte encontram-se públicos.

A existência de um modelo de mobilidade social representativo da realidade, como o GRM, propicia diversas oportunidades de trabalhos futuros relacionados ao encaminhamento oportunístico ciente de contexto social em DTNs e redes D2D. Por exemplo, seria interessante avaliar como os algoritmos de encaminhamento oportunístico existentes se comportam em cenários de larga escala, com milhares de nós já que não existem *traces* reais disponíveis que monitorem essa quantidade de nós. Finalmente, seria interessante estender o para incorporar outras características, como trajetórias baseadas em mapas ou diferentes popularidades e quantidade de visitas em diferentes regiões no espaço do *trace*.

Referências

[Aung et al. 2015] Aung, C. Y., Seet, B. C., Zhang, M., Xie, L. F., and Chong, P. H. J. (2015). A review of group mobility models for mobile ad hoc networks. *Wireless Personal Communications*, 85(3):1317–1331.

- [Barabási and Albert 1999] Barabási, A.-L. and Albert, R. (1999). Emergence of scaling in random networks. *science*, 286(5439):509–512.
- [Berg 1988] Berg, S. (1988). Snowball sampling—i. *Encyclopedia of statistical sciences*.
- [Blakely and Lowekamp 2004] Blakely, K. and Lowekamp, B. (2004). A structured group mobility model for the simulation of mobile ad hoc networks. In *Proceedings of the second international workshop on Mobility management & wireless access protocols*, pages 111–118. ACM.
- [Boldrini and Passarella 2010] Boldrini, C. and Passarella, A. (2010). Hcmm: Modelling spatial and temporal properties of human mobility driven by users’ social relationships. *Computer Communications*, 33(9):1056–1074.
- [Brandes et al. 2003] Brandes, U., Gaertler, M., and Wagner, D. (2003). Experiments on graph clustering algorithms. In *European Symposium on Algorithms*, pages 568–579. Springer.
- [Cruz and Miranda 2015] Cruz, N. and Miranda, H. (2015). Recurring contact opportunities within groups of devices. In *12th EAI International Conference on Mobile and Ubiquitous Systems: Computing, Networking and Services*, pages 160–169. ICST (Institute for Computer Sciences, Social-Informatics and Telecommunications Engineering).
- [Eagle and Pentland 2006] Eagle, N. and Pentland, A. (2006). Reality mining: sensing complex social systems. *Personal and ubiquitous computing*, 10(4):255–268.
- [Ekman et al. 2008] Ekman, F., Keränen, A., Karvo, J., and Ott, J. (2008). Working day movement model. In *Proceedings of the 1st ACM SIGMOBILE workshop on Mobility models*, pages 33–40. ACM.
- [Fortunato 2010] Fortunato, S. (2010). Community detection in graphs. *Physics reports*, 486(3):75–174.
- [Gonzalez et al. 2008] Gonzalez, M. C., Hidalgo, C. A., and Barabasi, A.-L. (2008). Understanding individual human mobility patterns. *Nature*, 453(7196):779–782.
- [Henderson et al. 2008] Henderson, T., Kotz, D., and Abyzov, I. (2008). The changing usage of a mature campus-wide wireless network. *Computer Networks*, 52(14):2690–2712.
- [Hong et al. 1999] Hong, X., Gerla, M., Pei, G., and Chiang, C.-C. (1999). A group mobility model for ad hoc wireless networks. In *Proceedings of the 2nd ACM MSWIM, MSWiM ’99*, pages 53–60. ACM.
- [Hui et al. 2011] Hui, P., Crowcroft, J., and Yoneki, E. (2011). Bubble rap: Social-based forwarding in delay-tolerant networks. *Mobile Computing, IEEE Transactions on*, 10(11):1576–1589.
- [Keränen et al. 2009] Keränen, A., Ott, J., and Kärkkäinen, T. (2009). The one simulator for dtn protocol evaluation. In *Proceedings of the 2nd international conference on simulation tools and techniques*, page 55.
- [Kosta et al. 2014] Kosta, S., Mei, A., and Stefa, J. (2014). Large-scale synthetic social mobile networks with swim. *IEEE Transactions on Mobile Computing*, 13(1):116–129.
- [Lee et al. 2009] Lee, K., Hong, S., Kim, S. J., Rhee, I., and Chong, S. (2009). Slaw: A new mobility model for human walks. In *INFOCOM 2009, IEEE*, pages 855–863. IEEE.
- [Li et al. 2014] Li, Y., Wu, T., Hui, P., Jin, D., and Chen, S. (2014). Social-aware d2d communications: qualitative insights and quantitative analysis. *Communications Magazine, IEEE*, 52(6):150–158.
- [Musolesi and Mascolo 2006] Musolesi, M. and Mascolo, C. (2006). A community based mobility model for ad hoc network research. In *Proceedings of the 2nd international workshop on Multi-hop ad hoc networks: from theory to reality*, pages 31–38. ACM.
- [Musolesi and Mascolo 2007] Musolesi, M. and Mascolo, C. (2007). Designing mobility models based on social network theory. *ACM SIGMOBILE Mobile Computing and Communications Review*, 11(3):59–70.
- [Nunes et al. 2016a] Nunes, I. O., Vaz de Melo, P., and A.F. Loureiro, A. (2016a). Group mobility: Detection, tracking and characterization. In *IEEE ICC 2016 International Conference on Communications (ICC’16 SAC-8 SN)*, Kuala Lumpur, Malaysia.
- [Nunes et al. 2016b] Nunes, I. O., Vaz de Melo, P., and A.F. Loureiro, A. (2016b). Leveraging d2d multi-hop communication through social group meetings awareness. *Wireless Communications Magazine, IEEE*.
- [Palla et al. 2005] Palla, G., Derényi, I., Farkas, I., and Vicsek, T. (2005). Uncovering the overlapping community structure of complex networks in nature and society. *Nature*, 435(7043):814–818.
- [Silva et al. 2015] Silva, F. A., Celes, C., Boukerche, A., Ruiz, L. B., and Loureiro, A. A. (2015). Filling the gaps of vehicular mobility traces. In *Proceedings of the 18th ACM MSWIM*, pages 47–54. ACM.
- [Starnini et al. 2014] Starnini, M., Baronchelli, A., and Pastor-Satorras, R. (2014). Model reproduces individual, group and collective dynamics of human contact networks. *arXiv preprint arXiv:1409.0507*.
- [Treurniet 2014] Treurniet, J. (2014). A taxonomy and survey of microscopic mobility models from the mobile networking domain. *ACM Computing Surveys (CSUR)*, 47(1):14.
- [Wang and Li 2002] Wang, K. H. and Li, B. (2002). Group mobility and partition prediction in wireless ad-hoc networks. In *Communications, 2002. ICC 2002. IEEE International Conference on*, volume 2, pages 1017–1021 vol.2.
- [Watts 1999] Watts, D. J. (1999). Networks, dynamics, and the small-world phenomenon 1. *American Journal of sociology*, 105(2):493–527.