

Validação Realística de Métricas Espaço-Temporais para Redes ad hoc Sem Fio

Elmano Ramalho Cavalcanti¹ e Marco Aurélio Spohn²

Resumo—Resultados de trabalhos recentes apontaram que duas destacadas métricas de mobilidade espaço-temporais para redes *ad hoc* sem fio possuem limitações críticas. Paralelamente, duas novas métricas espaciais e uma temporal foram propostas e validadas através de modelos de mobilidade puramente sintéticos. Todavia, devido às limitações que tais modelos possuem para representar as características reais da mobilidade humana, este artigo apresenta uma abrangente validação dessas novas métricas empregando-se um recente e bem aceito modelo de mobilidade realístico.

Palavras-Chave—mobilidade, dependência espacial, dependência temporal, rede *ad hoc* sem fio.

Abstract—Results from recent studies have pointed out that two well-known spatial and temporal mobility metrics for mobile ad hoc networks have critical drawbacks. At the same time, two new spatial and one temporal mobility metrics have been proposed and validated through purely synthetic mobility models. However, due to the limitations that such models have to characterize the real trace provided by human mobility, this paper presents a comprehensive validation of these new metrics employing a recently well-accepted realistic mobility model.

Keywords—mobility, spatial dependence, temporal dependence, wireless ad hoc network.

I. INTRODUÇÃO

Os últimos anos têm testemunhado o elevado crescimento no interesse por estudos que avaliem os efeitos e impactos que a mobilidade de pessoas e veículos provocam em protocolos e serviços projetados para as redes *ad hoc* móveis (MANETs) e variantes (VANETs, DTNs). O desenvolvimento de soluções para essas redes sem fio que sejam cientes da mobilidade dos dispositivos (nós) é um dos grandes benefícios a serem alcançados. Como consequência, tal interesse tem provocado elevado crescimento do número de propostas de novos modelos e métricas de mobilidade.

Modelo de mobilidade é o responsável por regular o padrão de movimento dos usuários móveis, impactando principalmente no desempenho de protocolos [1], [3]. De acordo com suas características, ele pode ser utilizado para descrever o movimento de pessoas, veículos terrestres, ou mesmo aeronaves [7], [8]. Os modelos de mobilidade são quantificados através das métricas de mobilidade, as quais também podem ser empregadas para classificação dos mesmos.

Bai et al. [3] propuseram um arcabouço para analisar o impacto da mobilidade no desempenho de protocolos de roteamento em MANETs. Como parte do arcabouço, foram

propostas duas métricas de mobilidade para medir o nível de dependência espacial e temporal entre dispositivos móveis (Seção II). Essas métricas, denominadas GDE (Grau de Dependência Espacial) e GDT (Grau de Dependência Temporal), têm sido utilizadas para diversos propósitos como, por exemplo, no desenvolvimento e avaliação de protocolos de roteamento [9], na avaliação de modelos de mobilidade [14] e no desenvolvimento de algoritmos de agrupamento (*clustering*) adaptativos à mobilidade [15].

Alguns estudos recentes [4], [5] apontam que as métricas GDE e GDT apresentam limitações críticas, as quais podem comprometer vários resultados. Como solução para as falhas detectadas nas métricas, os autores propuseram duas métricas espaciais, GDEA (Grau de Dependência Espacial Aprimorado) e GPN (Grau de Proximidade entre Nós), e uma métrica temporal, GDTA (Grau de Dependência Temporal Aprimorado). Essas métricas, segundo os autores, não apresentam as deficiências inerentes às métricas GDE e GDT. Porém, o comparativo entre as métricas do arcabouço IMPORTANT e as propostas pelos autores foi realizado empregando-se apenas modelos de mobilidade de primeira geração (sintéticos) [13], que possuem limitações em caracterizar adequadamente a mobilidade dos dispositivos em cenários reais. Dessa forma, surge a necessidade e oportunidade tanto de reavaliar as métricas GDE e GDT como de revalidar as métricas GDEA, GDTA e GPN, em ambos os casos considerando um modelo de mobilidade comprovadamente realístico.

Dessa forma, duas são as contribuições deste artigo. Primeiro, apresenta uma reavaliação das métricas espaço-temporais do popular arcabouço IMPORTANT [3], com o objetivo de comprovar ou não as limitações encontradas. Em segundo lugar, apresenta uma revalidação das recentes métricas espaço-temporais (GDEA, GPN e GDTA), com o propósito de verificar se de fato são ou não mais confiáveis que as do arcabouço IMPORTANT. Esta investigação será feita considerando cenários comprovadamente realísticos de mobilidade humana. Até o presente momento, não há estudos na literatura que tenha conduzido tal análise.

O restante deste artigo encontra-se estruturado da seguinte forma. A Seção II apresenta uma breve discussão sobre modelos e métricas de mobilidade. A metodologia empregada neste trabalho é descrita na Seção III. Em seguida, na Seção IV encontra-se a validação das recentes métricas espaço-temporais em cenários realísticos de mobilidade. Por fim, a Seção V contém as conclusões do trabalho e recomendações para trabalhos futuros.

¹Departamento de Sistemas e Computação, Universidade Federal de Campina Grande, Campina Grande-PB, Brasil. E-mail: elmano@copin.ufcg.edu.br

²Universidade Federal da Fronteira Sul, Chapecó-SC, Brasil. E-mail: marco.spohn@uffs.edu.br

II. FUNDAMENTAÇÃO TEÓRICA

As métricas de mobilidade têm sido desenvolvidas tanto para avaliar quantitativamente/qualitativamente como para classificar os diversos modelos existentes, sejam estes sintéticos ou não-sintéticos. Uma vez que um nó móvel (e.g., pedestre) pode movimentar-se de acordo com o movimento de outro nó, parece oportuno pensar sobre métricas de mobilidade que tenham como fundamento essa relação. A respeito disso, Bai et al [3] propuseram o grau de dependência espacial (GDE), que indica o nível de similaridade entre as velocidades dos dispositivos que estejam razoavelmente próximos uns dos outros. O valor de GDE é alto quando as velocidades dos dispositivos são similares, em magnitude e direção. Isso normalmente ocorre quando o movimento de um nó depende de outro. Assim, quando aplicada em toda uma rede *ad hoc* móvel, essa métrica dá indícios do quanto os dispositivos se movimentam em grupo. Uma ilustração de dependência espacial está retratada na Figura 1 (a).

A métrica GDE tem sido bastante utilizada em uma vasta gama de trabalhos de pesquisa: avaliação de protocolos de roteamento geográfico [11]; na validação [12] e avaliação [10], [14] de modelos de mobilidade; na análise de desempenho de protocolos de roteamento [3], [6], [9]; e no projeto de algoritmos de agrupamento [15].




Fig. 1. Ilustração dos conceitos de dependência espacial e temporal.

Para as definições de fórmulas a seguir, são consideradas as seguintes notações: T é o tempo da simulação, N é o número de dispositivos móveis, X, Y representam o comprimento e largura do cenário geográfico de simulação, R é o alcance de transmissão do rádio dos dispositivos, $\vec{v}(i, t)$ indica o vetor velocidade do dispositivo i no instante t , e $D(i, j, t)$ é a distância Euclidiana entre os dispositivos i, j no instante t .

O grau de dependência espacial entre dois dispositivos i, j no instante t , $GDE(i, j, t)$, é dado pelo produto entre o cosseno do ângulo formado pelos vetores da velocidade dos dispositivos e a razão entre a menor e maior magnitude da velocidade dos dispositivos (Equação 1).

$$GDE(i, j, t) = \text{Cos}(\vec{v}(i, t), \vec{v}(j, t)) \times RV(\vec{v}(i, t), \vec{v}(j, t)) \quad (1)$$

Uma outra métrica baseada no vetor velocidade é o grau de dependência temporal (GDT) [3]. O propósito dessa métrica é de distinguir modelos temporais (e.g., Gauss-Markov, SLAW) dos modelos aleatórios e baseados em grupo. Embora semelhante ao GDE, a métrica GDT é aplicada individualmente a cada dispositivo. O objetivo é medir a suavidade do movimento, ou seja, o quão abruptamente a velocidade

de um dispositivo i varia ou não ao longo do tempo. Se o vetor velocidade do dispositivo i no instante t é semelhante ao vetor do mesmo dispositivo nos instantes predecessores, $t-1, t-2, \dots, t-k$, então o $GDT(i, t)$ será alto. Uma ilustração da métrica GDT está retratada na Figura 1 (b), onde se pode observar três posições e velocidades consecutivas de um dispositivo ao longo da trajetória do movimento.

O grau de dependência temporal do dispositivo i entre os instantes t e t' é dado pelo produto entre o cosseno do ângulo formado pelos vetores da velocidade do dispositivo e a razão entre a menor e maior magnitude da velocidade do dispositivo (Equação 2).

$$GDT(i, t, t') = \text{Cos}(\vec{v}(i, t), \vec{v}(i, t')) \times RV(\vec{v}(i, t), \vec{v}(i, t')) \quad (2)$$

A importância das métricas GDE e GDT também pode ser verificada pelo fato de já terem sido implementadas em outras conhecidas ferramentas de geração e análise de mobilidade, a exemplo da BonnMotion [2].

Contudo, como já mencionado na introdução, resultados recentes [4], [5] mostraram que ambas GDE e GDT apresentam limitações e/ou falhas críticas. Como solução para esse problema, foram propostas duas métricas espaciais (GDEA e GPN) e uma temporal (GDTA), as quais supostamente são mais confiáveis que aquelas. O problema é que a avaliação comparativa descrita nesses trabalhos foi baseada unicamente em modelos de mobilidade de primeira geração, ou seja, em modelos puramente sintéticos. Entretanto, as métricas de mobilidade devem ser testadas tanto em modelos puramente matemáticos (sintéticos) como, principalmente, em modelos baseados em traços reais de movimento.

As fórmulas para calcular as novas métricas Grau de Dependência Espacial Aprimorado (GDEA), Grau de Proximidade entre Nós (GPN) e Grau de Dependência Temporal Aprimorado (GDTA) estão mostradas, respectivamente, nas Equações 3, 4 e 5:

$$GDEA(i, j, t) = \begin{cases} \frac{1}{K} \sum_{k=t-K}^{t-1} GDE(i, j, k) & \text{se } \vec{v}(i, t), \vec{v}(j, t) = \vec{0} \\ GDE(i, j, t) & \text{caso contrário.} \end{cases} \quad (3)$$

$$GPN = 1 - \frac{\frac{1}{N(N-1)/2} \sum_{i=1}^{N-1} \sum_{j=i+1}^N \frac{\sum_{t=1}^T D(i, j, t)/R}{T}}{\frac{\sqrt{X^2 + Y^2}}{2R}} \quad (4)$$

$$GDTA(i, t) = \begin{cases} 0, & \text{se } \text{velocidadeNaoMudou}(i, t) \\ \text{Cos}(i, t) \times RV(i, t), & \text{caso contrário.} \end{cases} \quad (5)$$

Na Equação 3, o valor da variável K é proporcional ao tempo médio de pausa dos dispositivos, um típico parâmetro de mobilidade.

III. SIMULAÇÃO

O modelo de mobilidade de segunda geração SLAW [8] foi escolhido para a validação das métricas de mobilidade neste trabalho. O elevado nível de realismo do modelo, as variadas opções de configuração e o rápido interesse despertado pela comunidade justificam essa escolha.

Para a validação das métricas são considerados quatro conjuntos de cenários, os quais são definidos pela variação da quantidade de dispositivos móveis na rede (50 e 100) e da quantidade de pontos

TABELA I
CONFIGURAÇÃO DO MODELO SLAW PARA A SIMULAÇÃO.

Parâmetro	Valor	Parâmetro	Valor
Tempo de simulação	900 s	Raio de agrupamento	50 m
Qtde de dispositivos (N)	50, 100	Expoente Levy (β)	1
Tamanho do cenário	0,5 x 0,5 km	Tempo mín. de pausa	1, 20, 40, ..., 100 s
Alcance de comun. (R)	50 m	Tempo máx. de pausa	900 s
Distância alfa	3	Pontos de passagem (W)	20, 25, 40, 50, 60, 80, 100
Parâmetro Hurst	0,75		

^a Tempo mín. de pausa. ^b Tempo máx. de pausa. ^c Pontos de passagem.

de passagem (*waypoints*) no cenário (25 e 50). Em todos os casos o tempo mínimo de pausa (p) dos dispositivos foi variado entre 1 a 100 segundos (ver Tabela I), de forma a comprovar ou não a queda do valor do GDE em decorrência desse aumento (fenômeno discutido em [5]). O tempo máximo de pausa é igual ao tempo de simulação, que é de 900 s. O cenário tem geometria quadrangular de lado igual a 500 m. Cinco cenários adicionais foram especificados para compor a avaliação das métricas temporais, baseados em uma variação mais ampla do número de pontos de passagem. A configuração dos demais parâmetros do modelo SLAW seguiu os valores padrões especificados pelos idealizadores do modelo.

Ao todo foram gerados 29 cenários de mobilidade; sendo que cada cenário foi executado dez vezes, totalizando 290 experimentos. O nível de confiança utilizado nos gráficos é de 95%, o qual foi calculado utilizando-se o programa Excel 2010.

IV. VALIDAÇÃO DAS MÉTRICAS DE MOBILIDADE ESPAÇO-TEMPORAIS

A análise da validação das métricas está dividida em duas seções. A primeira (Seção IV-A) mostra a avaliação das métricas espaciais GDE, GDEA e GPN, enquanto que o comparativo das métricas temporais GDT e GDTA encontra-se na Seção IV-B.

A. Métricas Espaciais

O principal problema relatado sobre a métrica GDE, nas avaliações em que foram empregados modelos de mobilidade de primeira geração [5], é que esta métrica apresentaria um fenômeno de queda da dependência espacial entre os dispositivos, na medida em que estes passassem menos tempo se movimentando e mais tempo parados. Por consequência, dois cenários gerados por um mesmo modelo de mobilidade e que tenham os mesmos valores para os parâmetros de entrada, com exceção do tempo de pausa nodal (i.e., do nó), poderiam apresentar valores do GDE muito diferentes.

Por esse motivo, decidiu-se repetir a análise apresentada em [5], onde as métricas GDE e GDEA foram comparadas em diferentes níveis de tempo de pausa dos dispositivos. A Figura 2 retrata o comportamento das métricas espaciais GDE e GDEA quando se aumenta o tempo de pausa mínimo de 1 a 100 segundos nos quatro conjuntos de cenários descritos na seção anterior.

As Figuras 2(a), 2(c), 2(e) e 2(g) retratam o diferente impacto que o tempo de pausa provoca em cenários com diferentes quantidades de dispositivos (N) e número de *waypoints* (W). No cenário em que $N=50$ e $W=25$, o valor do GDE cai quase que continuamente com o aumento do tempo de pausa, partindo de 0,07 ($p = 1$ s) para menos de 0,03 ($p = 100$ s). Enquanto isso, GDEA sofre um aumento seguido por um período de oscilação.

Resalta-se que, quando o tempo de pausa é pequeno (1 s) ambos GDE e GDEA possuem valores próximos, visto que nessa situação a quase totalidade da correlação espacial deve-se aos períodos de movimento e não de pausa. O crescimento contínuo da correlação de pausa (diferença entre GDEA e GDE) pode ser observado na Figura 2(b), que mostra que a correlação de pausa (capturada pela métrica GDEA) torna-se maior com o aumento do tempo de pausa dos nós. Evidentemente que, em um cenário atípico em que os dispositivos nunca se movimentem não existirá correlação de pausa, dado que




Fig. 3. Grau de Proximidade entre Nós para vários níveis de pausa.

seu cálculo é baseado no histórico do movimento dos dispositivos (Equação 3).

No cenário com o dobro de dispositivos ($N=100$ e $W=25$) o comportamento das métricas GDEA e GDE é semelhante ao do cenário com $N=50$ e $W=25$ (Figuras 2(e) e 2(f)), sendo semelhantes aos resultados apresentados em [5].

Nos cenários que possuem o dobro do número de pontos de passagens ($W=50$), novamente percebe-se uma forte queda no valor do GDE (Figuras 2(c) e 2(g)). Por outro lado, o valor do GDEA sofre um aumento seguido por períodos de declínio. Um fenômeno semelhante foi descrito em [5]. Essa variação ocasiona um crescimento oscilatório da correlação de pausa (Figuras 2(d) e 2(h)).

Quanto ao grau de proximidade entre nós (GPN), seu comportamento ao variar-se o número de dispositivos (N), a quantidade de pontos de passagens (W) e o tempo de pausa dos dispositivos está ilustrado na Figura 3. A partir desse resultado, duas observações podem ser feitas. Primeiro, o fato de os dispositivos passarem mais tempo parados não afetou o GPN da rede. Este resultado está de acordo com o encontrado quando GPN foi avaliada em modelos sintéticos [4].

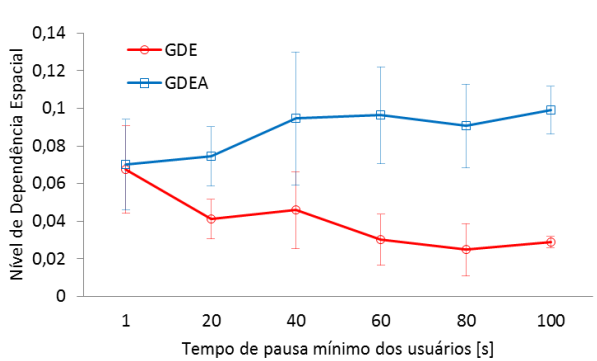
Segundo, o aumento de N ou W não afetou o valor do GPN. O fato de que a distribuição dos pontos de passagem no mapa é heterogênea e auto-similar, aliado ao fato de que os usuários (que carregam os dispositivos móveis) tendem a primeiro visitar os destinos mais próximos e só então os mais distantes (conforme descrito em [8]), pode ter contribuído para essa pouca variabilidade no valor do GPN.

B. Métricas Temporais


Conforme explicado na Seção II, o objetivo das métricas GDT e GDTA é o mesmo: quantificar o nível de dependência temporal do movimento dos dispositivos. Como o movimento dos seres humanos possui características naturalmente temporais, e visto que o modelo SLAW comprovadamente capta essa propriedade, então, a credibilidade das métricas GDT e GDTA ficará comprometida caso elas sejam consideravelmente influenciadas pela variação de algum parâmetro do modelo. Dado que alguns parâmetros do modelo SLAW já são configurados de forma a melhor corresponder com os traços reais (e.g., expoente Levy = 1), torna-se mais sensato analisar o impacto que outros parâmetros possam ocasionar nessas métricas, a exemplo do próprio tempo de pausa e do número de pontos de passagem.

A variação do número de pontos de passagem (W) ocasionou uma queda no valor do GDT (Figura 4). Entretanto, o fato de haver mais ou menos pontos de passagem não deveria estar relacionado ao nível de correlação temporal do movimento do usuário. Por outro lado, a métrica GDTA não demonstrou ser afetada por W.


A variação sofrida pelas métricas temporais quando se aumenta o tempo de pausa dos dispositivos da rede está ilustrada na Figura 5. Em todos os casos nota-se o mesmo cenário: a métrica GDT inicialmente sofre um declínio abrupto, seguido de uma queda constante, porém, menos acentuada. A métrica GDTA não foi influenciada pelo tempo de pausa, sempre apresentando valores bastante elevados (entre 0,96 e 0,98).




(a) GDE x GDEA N=50 e W=25




(b) GDEA-GDE N=50 e W=25




(c) GDE x GDEA N=50 e W=50




(d) GDEA-GDE N=50 e W=50




(e) GDE x GDEA N=100 e W=25



(f) GDEA-GDE N=100 e W=25



(g) GDE x GDEA N=100 e W=50



(h) GDEA-GDE N=100 e W=50

Fig. 2. Análise comparativa das métricas espaciais GDE e GDEA.

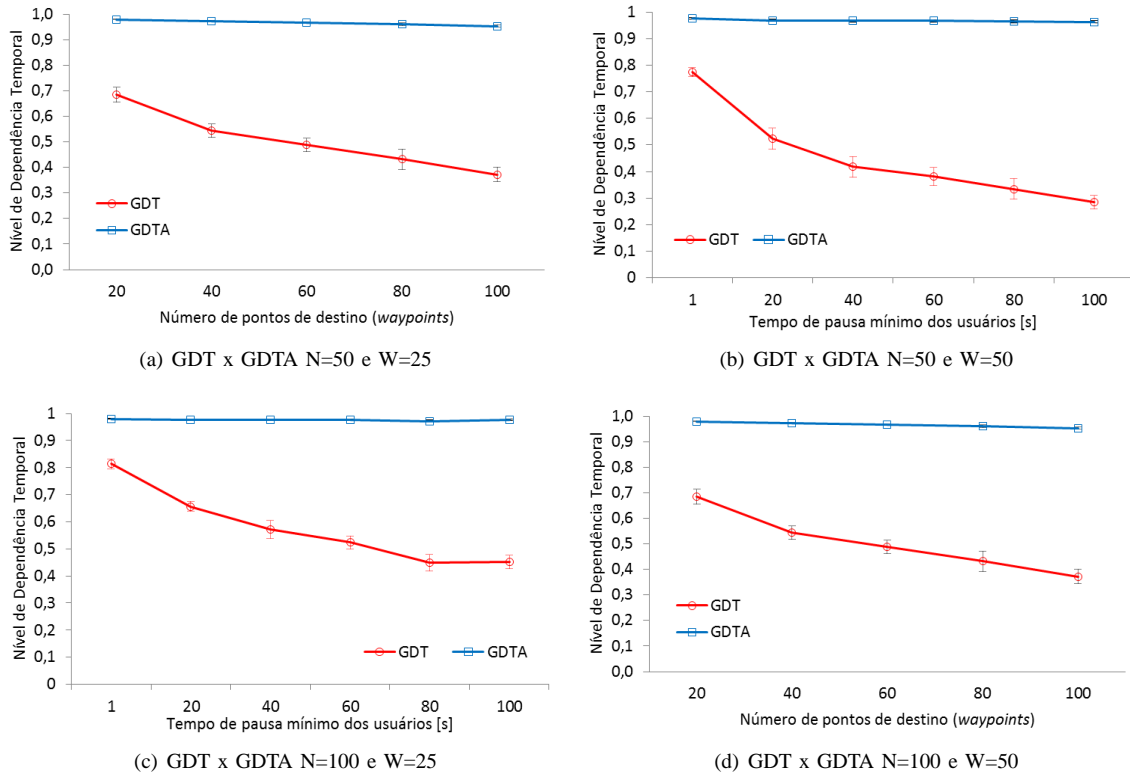


Fig. 5. Análise comparativa das métricas de mobilidade temporais.

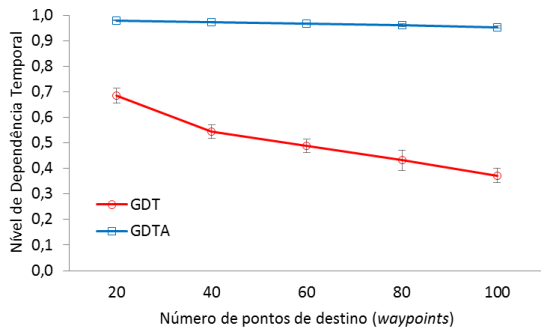


Fig. 4. Impacto da quantidade de waypoints sobre GDT e GDTA.

V. CONCLUSÃO

Os resultados descritos neste artigo comprovaram que as métricas de mobilidade recentemente propostas na literatura (GDEA, GDTA e GPN) [4], [5] são mais adequadas na captura das dependências espacial e temporal em dispositivos móveis do que as existentes atualmente (GDE e GDT) [3]. A comprovação foi realizada por meio de um realístico modelo de mobilidade humana (SLAW). Entretanto, parte dos resultados apontam que a métrica GDEA ainda necessita de aprimoramentos, de forma a não apresentar o nível de oscilação encontrado nos períodos transientes de pausa. Também foi observado que a métrica temporal GDT, ao contrário do GDTA, sofre variação negativa com o aumento do número de pontos de parada/passagem (waypoints) e do tempo de pausa nodal.

REFERÊNCIAS

[1] W. Alasmay e W. Zhuang. Mobility impact in IEEE 802.11p infrastructureless vehicular networks. *Ad Hoc Networks*, 10(2):222–230, 2012.

[2] Nils Aschenbruck, Raphael Ernst, Elmar Gerhards-Padilla, and Matthias Schwamborn. BonnMotion: a mobility scenario generation and analysis tool. In *Proc of the 3rd SIMUTools*, pp. 51–60, 2010. ICST.

[3] F. Bai, N. Sadagopan e A. Helmy. IMPORTANT: A framework to systematically analyze the impact of mobility on performance of routing protocols for adhoc networks. In *Proc. 22nd IEEE INFOCOM*, pp. 825–835, San Francisco, CA, USA, 2003. IEEE.

[4] E.R. Cavalcanti e M.A. Spohn. Degree of node proximity: a spatial mobility metric for MANETs. In *Proc. of the 9th ACM MobiWac*, pp. 61–68, Miami Beach, FL, USA, 2011. ACM.

[5] E.R. Cavalcanti e M.A. Spohn. On improving temporal and spatial mobility metrics for wireless ad hoc networks. *Inf. Sci*, 188:182–197, 2012.

[6] J. Ghosh, S. J. Philip e Chunming Qiao. Sociological orbit aware location approximation and routing (SOLAR) in manet. *Ad Hoc Networks*, 5(2):189–209, 2007.

[7] J. Haerri, F. Filali, e C. Bonnet. Mobility models for vehicular ad hoc networks: a survey and taxonomy. *IEEE Communications Surveys & Tutorials*, 11(4):19–41, 2009.

[8] K. Lee, S. Hong, S. J. Kim, I. Rhee e S. Chong. SLAW: A new mobility model for human walks. In *Proc. 28th IEEE INFOCOM*, pp. 855–863, Rio de Janeiro, Brazil, 2009. IEEE.

[9] Y. Lu, H. Lin, Y. Gu e A. Helmy. Towards mobility-rich performance analysis of routing protocols in ad hoc networks: Using contraction, expansion and hybrid models. In *IEEE ICC*, pp. 4346–4351, 2004.

[10] Y. Lu, H. Lin, Y. Gu e A. Helmy. Towards mobility-rich analysis in ad hoc networks: Using contraction, expansion and hybrid models. In *Proc. of ICC*, pp. 4346–4351. IEEE, 2004.

[11] D. Son, A. Helmy e B. Krishnamachari. The effect of mobility-induced location errors on geographic routing in mobile ad hoc and sensor networks. *IEEE Tran. on Mobile Comp.*, 3(3):233–245, 2004.

[12] C. Tuduca e T.R. Gross. A mobility model based on wlan traces and its validation. In *Proc. of IEEE INFOCOM*, pp. 664–674. IEEE, 2005.

[13] C. Walsh, A. Doci, e T. Camp. A call to arms: it's time for REAL mobility models. *MC2R*, 12(1):34–36, 2008.

[14] S.A. Williams e D. Hua. A group force mobility model. *Simulation Series*, 38(2):333–340, 2006.

[15] Y. Zhang, J.M. Ng e C.P. Low. A distributed group mobility adaptive clustering algorithm for mobile ad hoc networks. *Computer Communications*, 32(1):189–202, 2009.