

Aplicando Métricas de Mobilidade na Classificação de Rastros de Movimento em MANETs

Elmano Ramalho Cavalcanti^{1,3} e Marco Aurélio Spohn²

Resumo— Neste artigo são propostas novas métricas de mobilidade, as quais são empregadas em um método de aprendizagem supervisionado através do algoritmo de árvore de decisão, com intuito de classificar rastros de mobilidade de usuários em modelos de mobilidade específicos. O modelo classificador apresentou uma acurácia de 99,5% e índice Kappa de 0,994, o que indica um elevado nível de concordância entre o modelo de classificação e a classificação verdadeira.

Palavras-Chave— Modelo de mobilidade, métrica de mobilidade, reconhecimento de padrões, classificação supervisionada.

Abstract— In this paper new mobility metrics are proposed, which are employed in a supervised learning method using the decision tree algorithm, in order to classify user mobility traces into specific mobility models. The classifier model had an accuracy of 99.5% and Kappa index of 0.994, which indicates a high level of agreement between the classification model and the real classification.

Keywords— Mobility model, mobility metric, pattern recognition, supervised classification.

I. INTRODUÇÃO

O estudo da mobilidade humana e de veículos aplicado ao setor de comunicação móvel está entre os tópicos de pesquisa de grande interesse atualmente. Diversas pesquisas teóricas e experimentais têm demonstrado que a mobilidade de usuários constitui um fator essencial no desempenho de protocolos das mais diversas camadas das arquiteturas de redes [1], [2]. O padrão de movimento dos usuários é descrito através do que se chama modelo de mobilidade. Nos últimos anos dezenas de modelos de mobilidade foram propostos para, em geral, as redes *ad hoc* móveis (MANETs) e suas variantes. Alguns destes foram desenvolvidos e/ou validados através de dados reais provenientes de repositórios de rastros de mobilidade de redes sem fio, a exemplo do bem conhecido projeto CRAWDAD (*Community Resource for Archiving Wireless Data At Dartmouth*) [10], o qual reúne a maior base de dados oriundos das mais diversas redes sem fio.

Com intuito de comparar os diversos modelos de mobilidade existentes, uma gama de métricas de mobilidade têm sido projetadas nos últimos anos. As métricas objetivam mensurar as propriedades existentes no padrão de movimento gerado pelo modelo, a exemplo do nível de aleatoriedade do movimento,

do grau de dependência de movimento entre usuários e da existência de restrição geográfica no cenário (e.g., ruas).

Nesse contexto, uma proeminente aplicação de métricas de mobilidade é de auxiliar na construção de modelos de inferência capazes de classificar rastros de movimentos em modelos de mobilidade familiares; ou seja, naqueles que sejam mais capazes de replicar as características de movimento detectadas. Tais modelos de classificação podem ser empregados, por exemplo, na determinação do modo de transporte do usuário móvel (e.g., estacionário, caminhando, andando de bicicleta ou dirigindo), que podem ser utilizados por serviços e aplicações cientes de contexto [12], [15].

Após detalhar os conceitos de modelos e métricas de mobilidade (Seção II), é proposto neste artigo um conjunto de métricas de mobilidade (Seção III) que são empregadas para construção de um modelo classificador de rastros de movimento em modelos de mobilidade reconhecidos (Seção IV). As conclusões do trabalho são apontadas na Seção V.

II. FUNDAMENTAÇÃO TEÓRICA

Um modelo de mobilidade pode ser visto como um processo de entrada/saída. Na entrada estão os parâmetros de entrada do modelo de mobilidade. Número de usuários, comprimento e largura do cenário geográfico, velocidade e tempo de pausa máximos são exemplos de parâmetros de entrada. Na saída do processo encontram-se os arquivos de rastros de mobilidade, que contêm os dados dos movimentos de todos os nós durante o tempo de vida da rede. A partir desses arquivos é possível calcular as métricas de mobilidade.

A primeira geração de modelos de mobilidade para redes *ad hoc* móveis teve início no final da década de 90. O principal modelo dessa primeira geração, que ainda é razoavelmente utilizado em trabalhos baseados em simulações é o *Random Waypoint* (RWP). Outros modelos dessa geração são o Caminhada Aleatória (*Random Walk*), Direção Aleatória (*Random Direction*), RPGM (*Reference Point Group Mobility*), Gauss-Markov e Manhattan (o leitor poderá encontrar informações sobre esses modelos em [5]). Todos esses modelos são considerados sintéticos; ou seja, baseados apenas em modelagem matemática.

A segunda geração de modelos de mobilidade foi iniciada a partir do momento em que rastros reais do movimento dos nós (usuários) passaram a ser considerados na construção e/ou validação do modelo, algo que teve início por volta do ano de 2005. Entre esses modelos, pode-se citar o modelo de mobilidade baseado em comunidades (CMM) [14], o SLAW (*Self-similar Least-Action Walk*) [11] e, mais recentemente, o

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 ³Instituto Federal de Educação, Ciência e Tecnologia de Pernambuco, Garanhuns-PE, Brasil. E-mail: elmano.cavalcanti@garanhuns.ifpe.edu.br




Fig. 1. Classificação das métricas de mobilidade.

Smooth [13]. Esses modelos são reputados como sendo mais realísticos que os anteriores.

Métricas de mobilidade têm sido desenvolvidas para avaliar quantitativamente e qualitativamente os diversos modelos de mobilidade. As métricas podem ser classificadas de acordo com o tipo de informação utilizada no cálculo. Algumas são derivadas da teoria dos grafos, a exemplo do grau de um vértice em um grafo que, no contexto das MANETs, representa o grau do nó (ou número de vizinhos). Métricas baseadas nos enlaces de comunicação entre vizinhos e caminhos (*paths*) existentes entre pares de nós na rede também podem ser consideradas pertencente a esse mesmo grupo.

Outra categoria de métricas são baseadas nos componentes do vetor velocidade (i.e., módulo e ângulo), a exemplo da velocidade relativa [6]. Métricas que consideram a distância física entre os nós como fator primordial no cálculo, são do tipo baseadas em distância (e.g., grau de proximidade entre nós [7]). Semelhantemente, se o tempo for o fator crucial, a métrica será do tipo temporal (e.g., tempo de vida do enlace). Por fim, métricas que tratam conjuntamente da localização dos nós e as dimensões do espaço geográfico do cenário da rede, são rotuladas como métricas espaciais. A Figura 1 ilustra essa classificação.

Em geral, métricas de mobilidade têm sido bastante utilizadas em uma vasta gama de pesquisas como no projeto, validação e avaliação de modelos de mobilidade, algoritmos de agrupamento e protocolos de roteamento.

III. NOVAS MÉTRICAS DE MOBILIDADE

As características espaço-temporais do movimento de um usuário estão descritas na Figura 2, que ilustra um rastro de movimento típico de um usuário. No início o usuário encontra-se no ponto de parada (*waypoint*) 1, W_1 , onde permanece parado por 2 u.t. (unidade de tempo), $U_{0..2}$. Depois, inicia um movimento com velocidade de magnitude v_1 e ângulo θ_1 , com destino ao ponto de parada W_2 , distante d_1 u.d. (unidade de distância) de W_1 . Em seguida, permanece parado até o instante $t = 8$, quando inicia um novo trajeto. Após T u.t. o usuário termina o percurso. Essa representação gráfica é importante na contextualização de algumas métricas propostas a seguir, separadas de acordo com a classificação ilustrada na Figura 1.

A. Métricas Baseadas em Velocidade

Os modelos de mobilidade utilizam diferentes funções de distribuição de probabilidade (fdp) para a geração de valores como velocidade e direção do movimento, tempo de pausa, tempo de intercontato, e coordenadas dos pontos de parada.

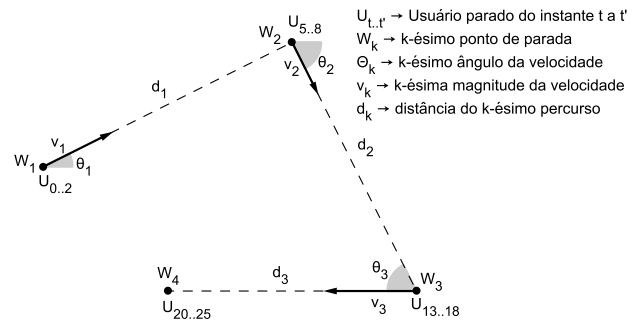


Fig. 2. Exemplo de movimento de um usuário móvel.

As distribuições mais recorrentes são a Uniforme, Normal, Exponencial e Power-law. Como exemplo, o clássico modelo Random Waypoint atribui a distribuição uniforme para geração dos valores da magnitude e ângulo da velocidade e do tempo de pausa nos pontos de parada. Por outro lado, o modelo Manhattan modela a velocidade dos nós através de uma distribuição Normal. Dessa forma, há a necessidade de métricas que possam ser utilizadas para distinguir os modelos com respeito às diferentes fdps utilizadas.

Outro ponto importante é o fato de que existem várias unidades de medida para as variáveis velocidade, ângulo e tempo de pausa. Em relação à velocidade, caso o nó seja um pedestre, a unidade m/s é comumente a mais adequada, enquanto que Km/h ou milhas por hora são utilizadas para veículos terrestres. O ângulo de um vetor pode ser expresso tanto em graus como em radianos, enquanto que o tempo pode ser medido em segundos ou minutos (mais apropriado para redes tolerantes a atrasos e interrupções - DTNs).

Uma das medidas utilizadas para caracterizar a variabilidade de uma variável que pode ser representada por diferentes unidades de medida é o coeficiente de variação (CV). O CV é dado pela divisão do desvio-padrão pela média, sendo uma medida normalizada de dispersão e livre de escalas (i.e., adimensional). Visto que a magnitude e ângulo da velocidade e o tempo de pausa são variáveis escalares de razão, o CV pode ser aplicado sem restrições.

Coefficientes de Variação de Velocidade e Ângulo: seja μ_v a média entre os valores da velocidade apresentados por todos os nós e σ_v o desvio-padrão desses valores. O coeficiente de variação de velocidade (CVV) é dado por σ_v/μ_v . Analogamente, o coeficiente de variação de ângulo (CVA) é dado pela fórmula σ_a/μ_a .

B. Métricas Espaciais

Grau de Distribuição Espacial da Rede (GDER): seja $D=[c_{i,j}]$, $1 \leq i, j \leq N$, uma matriz $N \times N$, em que N é o número de nós da rede. Considere que $c_{i,j}$ representa uma região retangular do cenário geográfico, onde podem estar presentes uma quantidade entre 0 e N nós. A matriz D representa a distribuição espacial de nós no cenário. Formalmente,

$$D = \begin{vmatrix} c_{11} & c_{12} & \cdots & c_{1n} \\ \vdots & \vdots & \ddots & \vdots \\ c_{n1} & c_{n2} & \cdots & c_{nn} \end{vmatrix}$$

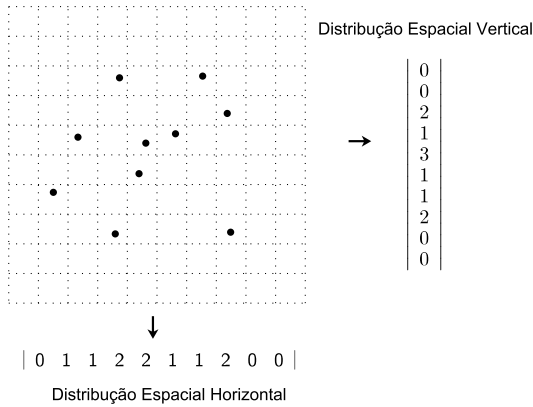


Fig. 3. Exemplo de Distribuição Espacial de Nós.

A Figura 3 ilustra a distribuição espacial de nós em certo instante de tempo em uma rede contendo dez usuários. As matrizes linha e coluna adicionais na figura expressam a distribuição de nós nos eixos da abscissa e ordenada, respectivamente. Essas matrizes são denominadas de matrizes de distribuição horizontal (MDH) e vertical (MDV), em que $MDH = [h_{1,j}]$, $1 \leq j \leq N$ e $h_{1,j} = \sum_{i=1}^N c_{i,j}$ e $MDV = [h_{i,1}]$, $1 \leq i \leq N$ e $h_{i,1} = \sum_{j=1}^N c_{i,j}$.

Considerando essa representação, os limites inferior e superior do GDER serão dados nos casos de menor e maior uniformidade, respectivamente. O limite será superior quando todos os elementos da MDH e MDV forem iguais a 1; ou seja, quando em cada linha e coluna existir exatamente um único usuário. Por outro lado, GDER terá valor mínimo quando todos os nós estiverem em uma mesma célula. Um exemplo de configuração de limite inferior é indicado a seguir:

$$D = \begin{pmatrix} N & 0 & \dots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \dots & 0 \end{pmatrix}$$

Desse modo, seja $L = [c_{1,j}]$, $c_{1,j} = 1$, $1 \leq j \leq N$, uma matriz linha em que todos os valores sejam iguais a 1. Analogamente, seja $C = [c_{i,1}]$, $c_{i,1} = 1$, $1 \leq i \leq N$ uma matriz coluna em que todos os valores sejam iguais a 1. Neste caso, tem-se que o desvio vertical será dado pela diferença entre as matrizes MDV e C (em termos absolutos):

$$\left| \begin{array}{c|c|c} N & 1 & (N-1) \\ 0 & 1 & 1 \\ \vdots & \vdots & \vdots \\ 0 & 1 & 1 \end{array} \right| = \left| \begin{array}{c|c|c} (N-1) & 1 & 1 \\ 1 & 1 & 1 \\ \vdots & \vdots & \vdots \\ 1 & 1 & 1 \end{array} \right|$$

A soma do desvio vertical será igual a $(N-1) + (N-1).1 = 2(N-1)$. Da mesma forma, o desvio horizontal será também igual a $2(N-1)$. Consequentemente, o desvio total da distribuição será de $4(N-1)$. Desse modo, definimos o grau de distribuição espacial da rede no instante t pela seguinte fórmula:

$$GDER(t) = 1 - \log(Desvio(t)/4(N-1)). \quad (1)$$

em que $Desvio(t)$ é igual a soma dos elementos das matrizes MDH e MDV da rede no instante t . O valor do GDER será

a média entre os valores de $GDER(t)$, $t' < t \leq T + t'$ (considerando que em $t = t'$ o modelo já tenha alcançado o período de estabilidade). No exemplo da Figura 3 o $GDER(t)$ é dado por $1 - \log(14/36) \approx 0,59$. O uso da escala logarítmica se faz necessário devido a grande escala de valores do GDER¹.

Grau de Acessibilidade Espacial (GAE): considerando a mesma modelagem empregada na métrica GDER, em que o cenário é dividido em uma grade $N \times N$ ($N =$ número de nós), o grau de acessibilidade espacial é dado como a proporção de células visitadas pelo total de células do cenário. Em modelos de restrição geográfica, existem regiões no mapa em que um nó nunca poderá estar; consequentemente, o GAE será menor que em modelos onde os nós podem, teoricamente, estar em qualquer posição do cenário, como ocorre em modelos aleatórios (e.g., Random Waypoint, Caminhada Aleatória e Direção Aleatória).

Evidente que, para uma justa comparação entre modelos, é necessário que o tempo de vida da rede seja suficientemente grande para que os nós possam, teoricamente, atravessar todo o cenário. Quanto maior o tempo de vida da rede, maior a chance de que mais células sejam visitadas. Um possível limiar mínimo seria o tempo necessário para um nó percorrer a maior distância do cenário com velocidade média, sem parar.

C. Métricas Temporais

Coefficiente de Variação de Tempo de Parada (CVP): calculado de forma análoga ao coeficiente de variação de velocidade. Seja μ_p a média dos tempos de parada dos usuários durante o tempo de vida da rede e σ_v o desvio-padrão desses valores, tem-se que $CVP = \sigma_p / \mu_p$.

D. Métricas Baseadas em Distância

Deslocamento médio de Percurso (DeP): Uma outra métrica importante é o comprimento do deslocamento do percurso entre os pontos de parada do usuário. Nos últimos anos alguns estudos experimentais sobre mobilidade humana [9], [16] têm mostrado que essa medida segue uma distribuição power-law truncada.

Seja $\langle W^i \rangle = \{w_1^i, w_2^i, \dots, w_{n-1}^i, w_n^i\}$ o conjunto de pontos de parada do nó i ao longo de um período de tempo. O deslocamento do percurso do nó i partindo do ponto de parada w_k a w_{k+1} é dado por:

$$DeP(w_k^i, w_{k+1}^i) = D((x_{w_k}^i, y_{w_k}^i), (x_{w_{k+1}}^i, y_{w_{k+1}}^i)) \quad (2)$$

em que $x_{w_k}^i$ e $y_{w_k}^i$ representam o valor das coordenadas x,y do k-ésimo ponto de parada do nó i e $D(w_k^i, w_{k+1}^i)$ a distância euclidiana entre dois pontos de parada consecutivos.

Distância média de Percurso (DiP): semelhante à métrica anterior, porém considera a distância efetiva percorrida pelo usuário móvel entre dois pontos de parada. Em alguns modelos de mobilidade, como no Random Waypoint, o deslocamento de percurso será igual à distância de percurso, dado que

¹Pode-se provar que o número de matrizes $N \times N$, cujos elementos são inteiros não-negativos e soma igual a N é dado pela fórmula $\binom{n^2+n-1}{n}$ <http://oeis.org/A054688>.

Parâmetro	Valor	Parâmetro	Valor
Tempo de simulação	900 s	Raio de comunicação (R)	200 m
Dimensão do cenário	1x1 km ²	Número de nós	50, 100
Velocidade mín.	1 m/s	Velocidade máx.	10 m/s
Tamanho médio do grupo ¹	5 nós	Dimensões da grade ²	10x10

¹ Para os modelos de movimento coletivo (RPGM, *Column* e CMM).

² Número de ruas horizontais/verticais nos modelos Manhattan e CMM.

TABELA II
CONFIGURAÇÃO DOS MODELOS DE MOBILIDADE

entre dois pontos de parada consecutivos o nó mantém a direção do movimento. Obviamente, sempre será verdadeira a desigualdade $DeP \leq DiP$.

Sejam $t_{w_k^i}$ e $t_{w_{k+1}^i}$ os instantes de tempo em que o nó i atinge os k -ésimo e $k+1$ -ésimo pontos de parada. A distância total percorrida pelo nó i entre esses dois pontos será dada por:

$$DiP(w_k^i, w_{k+1}^i) = \sum_{j=t_{w_k^i}}^{t_{w_{k+1}^i}} Dist((x_j, y_j), (x_{j+1}, y_{j+1})) \quad (3)$$

IV. MODELO CLASSIFICADOR DE PADRÕES DE MOBILIDADE

A. Materiais e Métodos

Foram utilizados dez modelos de mobilidade, descritos sucintamente na Tabela I. Devido a limitações de páginas do artigo, não foi possível descrever cada um desses modelos. Para gerar os rastros dos modelos Smooth [13] e CMM [14] foram utilizados os códigos disponibilizados publicamente na Web pelos autores. Para os demais, usou-se a versão 2.0 da ferramenta BonnMotion [3], um gerador de cenários de mobilidade para vários simuladores de redes sem fio. Para construção do modelo classificador foi aplicada a ferramenta de código aberto RapidMiner [17], versão 5.3.

Para cada modelo de mobilidade foram gerados 40 arquivos de rastros de mobilidade, a partir da configuração de parâmetros descrita na Tabela II. O método de classificação empregado foi desenvolvido a partir do algoritmo de aprendizagem supervisionada de Árvore de Decisão (AD).

Para cada arquivo contendo os rastros de mobilidade, foram calculadas todas as métricas propostas na Seção III, acrescentando-se um rótulo indicando o nome do modelo de mobilidade. Os dados tabulados foram armazenados em planilha, com cada linha contendo os valores das métricas e rótulo.

Após essa etapa de pré-processamento, iniciou-se o algoritmo de AD, o qual consiste em duas fases: treinamento e teste. No treinamento, é gerado o modelo classificador a partir dos dados tabulados. Em seguida, para a fase de teste é utilizado um conjunto de dados não-rotulados, que deverão ser rotulados (classificados) pelo modelo. Para validação do modelo, utilizou-se o método de validação cruzada do tipo *stratified 10-fold*, técnica estatística padrão na validação de algoritmos de aprendizagem [4].

B. Resultados e Discussão

O modelo classificador resultante utilizou-se das métricas espaciais GDER e GAE, da métrica baseada em distância DiP e da métrica baseada em velocidade CVV, conforme ilustrado na Figura 4. Os cenários do modelo Gauss-Markov (GM) foram os que apresentaram maior índice do grau de distribuição espacial da rede, com valores acima de 0,2. Há pelo menos duas justificativas para esse resultado. Primeiro, no modelo GM não existe nenhum tipo de restrição geográfica, ou seja, os usuários podem mover-se para qualquer lugar. Segundo, a direção do movimento do usuário sofre alterações contínuas, diferentemente do que ocorre nos modelos RWP e RD, em que a direção permanece constante até o próximo ponto de parada. O RWP é conhecido por apresentar uma distribuição maior no centro do cenário, enquanto que no RD há uma distribuição maior nas bordas, razões que justificam esses modelos terem apresentados menores valores do GDER.

A métrica distância de percurso (DiP), cuja unidade de medida é normalizada em R (raio de comunicação), foi capaz de separar o modelo Smooth dos restantes. Nesse modelo os pontos de parada são distribuídos de maneira não equidistantes, de tal forma que as distâncias entre eles sigam uma distribuição *power-law* truncada. Por essa razão, a média da distância de percursos tende a ser menor do que em modelos aleatórios (RWP, RW, RD), onde a DiP variou de 2 a 3 Rs. Entretanto, esperava-se que a DiP separasse também os cenários gerados pelo modelo SLAW que, a princípio, deveria distribuir os pontos de parada de maneira semelhante ao Smooth.

O coeficiente de variação de velocidade (CVV) separou os modelos em dois grupos: RWP, RD, RW, RPGM e *Column*, de um lado, e CMM, SLAW e Manhattan, de outro. Nos modelos do primeiro grupo, a velocidade dos usuários é geralmente determinada por uma distribuição Uniforme, enquanto que no segundo, por distribuição Normal (Manhattan e CMM) e *power-law* truncada (SLAW). Logo, a métrica CVV mostrou-se útil para separar cenários de mobilidade onde a velocidade do usuário segue diferentes distribuições.

Ademais, a dupla de métricas espaciais, GAE e GDER, foi eficaz em separar individualmente os modelos restantes. O GAE do modelo RWP (média de 81%) foi consideravelmente menor que no modelo RD (média de 94%), o que provavelmente está relacionado à famosa distribuição não-uniforme (centralizada) dos usuários no RWP. Os menores valores do GAE foram registrados nos cenários do modelo CMM, pelo fato deste apresentar mobilidade coletiva e, principalmente, restrição geográfica, limitando o movimento dos usuários em vias de transporte pre-determinadas. Por fim, as métricas GDER e GAE puderam distinguir entre os cenários do SLAW e Manhattan e entre os cenários do RPGM e *Column*, respectivamente.

O modelo falhou ao classificar erroneamente dez cenários do modelo *Column* como sendo do modelo RPGM. Entretanto, o modelo preditivo acertou em todos os demais casos. A acurácia do algoritmo de aprendizagem ficou em 99,5%, e o índice Kappa, que mede o nível de concordância entre a classificação do modelo e a classificação verdadeira, em 0,994.

TABELA I
 MODELOS DE MOBILIDADE SELECIONADOS PARA SIMULAÇÃO.

Propriedade	RWP	RPGM	GM ¹	Manhattan	Column	RD ²	RW ³	CMM	SLAW	Smooth
Movimento individual	X		X	X		X	X		X	X
Movimento coletivo		X			X			X		
Restrição Geográfica				X				X	X	X
1ª geração (sintético)	X	X	X	X	X	X	X			
2ª geração								X	X	X

¹ Gauss-Markov. ² Random Direction. ³ Random Walk.

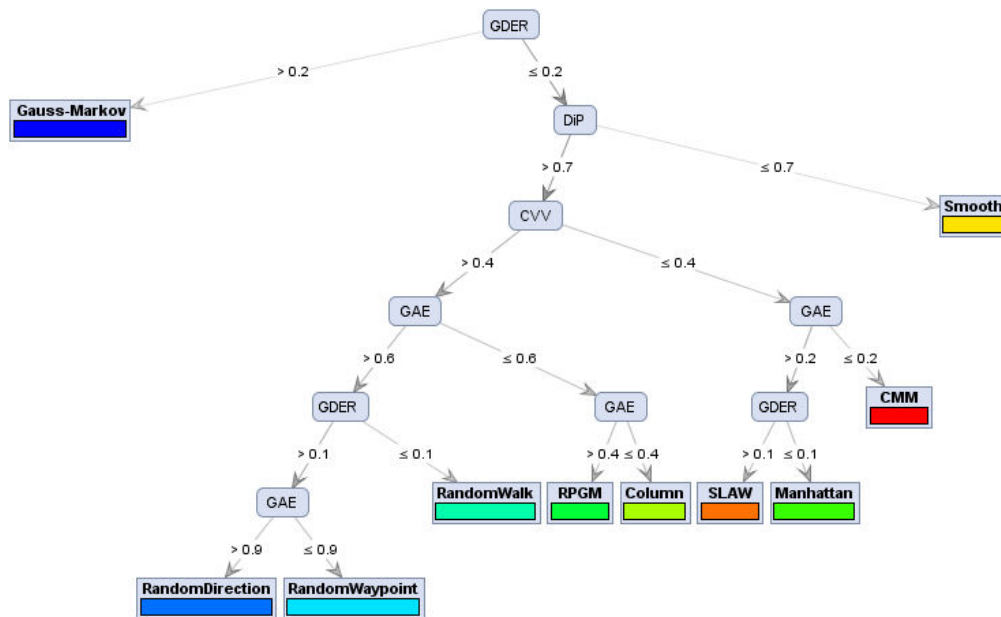


Fig. 4. Árvore de decisão para classificação de rastros de mobilidade.

V. CONCLUSÕES

Neste artigo foram propostas uma nova classificação e um conjunto inédito de métricas de mobilidade, as quais foram empregadas na elaboração de um modelo classificador de padrões de mobilidade de usuários em redes *ad hoc* móveis (MANETs). Para construção do modelo, foram utilizados dados de rastros de movimento provenientes de dez reconhecidos modelos de mobilidade. O modelo classificador demonstrou ser capaz de rotular adequadamente (acurácia de 99,5%) os rastros de movimento de usuários a partir de quatro novas métricas de mobilidade: Grau de Distribuição Espacial da Rede (GDER), Grau de Acessibilidade Espacial (GAE), Distância média de Percurso (DiP) e Coeficiente de Variação de Velocidade (CVV). Como trabalho futuro, pretende-se considerar outros modelos de mobilidade recentes e realísticos.

REFERÊNCIAS

- [1] Waleed Alasmay e Weihua Zhuang. Mobility impact in ieee 802.11p infrastructureless vehicular networks. *Ad Hoc Networks*, 10(2):222–230, 2012.
- [2] A. Chaintreau, P. Hui, J. Crowcroft, C. Diot, R. Gass e J. Scott. Impact of human mobility on the design of opportunistic forwarding algorithms. In *INFOCOM*. IEEE, 2006.
- [3] Nils Aschenbruck et al. *BonnMotion - a mobility scenario generation and analysis tool*. University of Bonn, <http://net.cs.uni-bonn.de/wg/cs/applications/bonnmotion>, 2011.
- [4] Daniel T. Larose. *Discovering Knowledge in Data - An Introduction to Data Mining*. Wiley, 2004.
- [5] Radhika Ranjan Roy. *Handbook of Mobile Ad Hoc Networks for Mobility Models*. Springer, 2011.
- [6] 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 *IEEE INFOCOM*, p. 825–835, 2003.
- [7] Elmano R. Cavalcanti e Marco A. Spohn. Degree of node proximity: a spatial mobility metric for manets. In *ACM MobiWac*, p. 61–68, 2011.
- [8] Elmano R. Cavalcanti e Marco A. Spohn. On improving temporal and spatial mobility metrics for wireless ad hoc networks. *Information Science*, 188:182–197, 2012.
- [9] M.C. González, C.A. Hidalgo e A.L. Barabási. Understanding individual human mobility patterns. *Nature*, 453(7196):779–782, 2008.
- [10] D. Kotz e T. Henderson. Crawdad: A community resource for archiving wireless data at dartmouth. *IEEE Pervasive Computing*, p. 12–14, 2005.
- [11] Kyunghan Lee, Seongik Hong, Seong Joon Kim, Injong Rhee, e Song Chong. SLAW: A new mobility model for human walks. In *INFOCOM*, p. 855–863, Rio de Janeiro, Brazil, 2009. IEEE.
- [12] Min Y. Mun, Deborah Estrin, Jeff Burke e Mark Hansen. Parsimonious mobility classification using GSM and WiFi traces. In *HotEmNets*. ACM, 2008.
- [13] Aarti Munjal, Tracy Camp e William Navidi. SMOOTH: a simple way to model human mobility. In *MSWiM*, p. 351–360. ACM, 2011.
- [14] M. Musolesi e C. Mascolo. Designing mobility models based on social network theory. *MC2R*, 11(3):59–70, 2007.
- [15] Sasank Reddy et al. Using mobile phones to determine transportation modes. *ACM TOSN*, 6(2):1–13, 2010.
- [16] I. Rhee et al. On the levy-walk nature of human mobility. *IEEE/ACM TON*, 19(3):630–643, 2011.
- [17] Ingo Mierswa, Michael Wurst, Ralf Klinkenberg, Martin Scholz e Timm Euler YALE: rapid prototyping for complex data mining tasks In *Proc. of the 12th ACM SIGKDD*, p. 935–940. ACM, 2006.