

SocialRoute: Roteamento Oportunístico de Baixo Custo baseado em Contatos Sociais

Augusto C.S.A. Domingues¹, Henrique S. Santana², Fabrício A. Silva²,
Pedro O. S. Vaz de Melo¹, Antonio A. F. Loureiro¹

¹Instituto de Ciências Exatas (ICEEx) – Universidade Federal de Minas Gerais (UFMG)
Belo Horizonte, MG – Brasil

²Universidade Federal de Viçosa, *campus* Florestal – Florestal, MG – Brasil

Resumo. *O estudo de características sociais em interações humanas é um tópico recorrente em redes móveis, aumentando o conhecimento sobre o comportamento dos nós, levando a melhores estratégias de roteamento. O estado da arte de algoritmos de roteamento oportunísticos baseados em características sociais aplica métricas sociais simples, como propriedades dos nós e comunidades, que não são capazes de capturar laços sociais individuais fortes e duradouros. Neste trabalho, propomos SocialRoute, um algoritmo de roteamento oportunístico baseado em contatos sociais que considera laços sociais individuais ao invés de comunidades para disseminar mensagens de forma eficiente. A solução é avaliada utilizando dois traces de contatos reais e comparada ao estado da arte, e os resultados mostram que o SocialRoute obtém taxas de entrega similares enquanto mantém overheads até 30 vezes menores.*

1. Introdução

Em redes complexas, uma aresta entre dois nós pode representar um encontro físico, um recurso compartilhado, uma característica em comum, entre outros. Quando consideramos um cenário de mobilidade humana, uma aresta entre dois indivíduos é denominada como um contato, que representa uma oportunidade de compartilhar informações. Assim, rastrear a ocorrência de contatos entre humanos e entender suas características, como frequência e duração, é essencial para a caracterização do comportamento humano [de Melo et al. 2015], bem como para o desenvolvimento de algoritmos de roteamento oportunísticos em redes [Hui et al. 2010, Nunes et al. 2018], a geração de dados sintéticos [Nunes et al. 2017b] e a predição de encontros futuros [Lindgren et al. 2004].

Estratégias de disseminação de dados frequentemente exploram as relações sociais entre indivíduos para transmitir dados de forma mais eficiente [Moreira et al. 2013]. Uma abordagem comum é o agrupamento de usuários em comunidades sociais através do uso de algoritmos de detecção de comunidades [Javed et al. 2018]. Alternativamente, métricas de redes complexas como centralidade do nó, *betweenness* e grau [Costa et al. 2020, Daly and Haahr 2007] também são usadas como forma de capturar traços sociais e detectar nós influentes em redes. Porém, tais abordagens falham em capturar características relevantes da rede, e no caso das comunidades, também podem ter um alto custo computacional.

Neste trabalho, investigamos como características sociais robustas podem melhorar os algoritmos de roteamento oportunístico baseados em aspectos sociais quanto a sua

efetividade e seu custo. Entende-se como características sociais robustas aquelas que se mantêm verdadeiras ao longo do tempo e que possuem relevância na caracterização das relações sociais. Mostramos que existe uma lacuna nesse ponto, a qual preenchemos ao propor uma nova estratégia de roteamento oportunístico chamada *SocialRoute*, que dissemina conteúdo somente para nós que compartilham relações sociais fortes com o destinatário. *SocialRoute* reduz de forma significativa o número de mensagens (*overhead*) necessário para alcançar o destinatário sem degradar a taxa de entrega. Adicionalmente, o algoritmo não necessita do cálculo de estruturas de comunidade, somente de relações sociais par-a-par, que na prática podem ser calculadas individualmente.

As principais contribuições deste trabalho são:

1. Análise de dois trazes de contato reais em termos de métricas sociais usadas na literatura, e como essas métricas falham em capturar traços sociais robustos.
2. *SocialRoute*, um algoritmo de roteamento oportunístico que faz uso das relações sociais para transmitir mensagens de forma eficiente entre usuários.
3. Avaliação do *SocialRoute* em ambos os trazes e comparação com quatro algoritmos sociais (estado da arte) obtendo um *overhead* até 30 vezes inferior mantendo uma taxa de entrega similar.

O restante deste trabalho está organizado da seguinte forma. A Seção 2 apresenta os conceitos fundamentais e os trabalhos relacionados. Em seguida, a Seção 3 apresenta uma análise das características sociais encontradas em trazes de contato e as suas relações à disseminação de dados em redes. A Seção 4 introduz o *SocialRoute*, a solução proposta. A validação é apresentada na Seção 5, seguido das considerações finais na Seção 6.

2. Background e Trabalhos Relacionados

O roteamento oportunístico trata de estratégias de encaminhamento que fazem uso de nós intermediários em uma rede para transmitir dados do remetente ao destinatário quando ambos não estão em contato direto. Os nós intermediários são escolhidos para aumentar a probabilidade de que a mensagem será entregue, quando comparado com a transmissão direta. Em alguns protocolos de roteamento, o caminho de roteamento é calculado e definido antes da mensagem deixar a origem, enquanto que nos protocolos oportunísticos um nó passa a mensagem a outros à medida que os contatos ocorrem, até que a mensagem chegue ao destino. Assim, esse tipo de roteamento é robusto a mudanças na topologia da rede, bem como em situações em que não a conhecemos. De forma geral, as limitações das redes e a busca pela otimização do uso dos recursos nos levará em direção a estratégias de disseminação que utilizam de informação contextual para reduzir o *overhead* [Poonguzharselvi and Vetriselvi 2013]. À medida que as redes crescem em escala e o seu conteúdo aumenta em tamanho, algoritmos baseados em inundação serão cada vez menos usados.

A abordagem mais simples para enriquecimento de contexto baseado em características sociais é a adição de métricas sociais que visam capturar as interações entre os nós. Tal abordagem é vista em PROPHET [Lindgren et al. 2004], o qual considera a frequência de encontros entre dois nós e os laços de transitividade para construir as probabilidades de um remetente entregar uma mensagem ao destinatário. De forma similar, SCORP [Moreira et al. 2013] considera duas métricas: o interesse do nó no conteúdo da mensagem e as interações do nó com outros que estejam interessados no conteúdo. Finalmente, PeopleRank [Mtibaa et al. 2010] se inspira no PageRank para ranquear nós em

Algoritmo	Tipo	Característica socia.	Comunidades/grupos	Nós estáticos
PROPHET [Lindgren et al. 2004]	Probabilístico	Regularidade de encontros	Não	Não
BUBBLE Rap [Hui et al. 2010]	Baseado em contexto	Comunidades	Sim	Não
GROUPS-NET [Nunes et al. 2017a]	Baseado em contexto + Probabilístico	Grupos	Sim	Não
SGBR [Abdelkader et al. 2012]	Baseado em contexto	Comunidades	Sim	Não
SCORP [Moreira et al. 2013]	Baseado em contexto	Interesse no conteúdo	Não	Não
PeopleRank [Mtibaa et al. 2010]	Baseado em contexto	Importância do nó	Não	Não
SAMPLER [Nunes et al. 2018]	Baseado em contexto	Comunidades	Sim	Sim
SocialRoute	Baseado em contexto + Probabilístico	Contatos sociais	Não	Sim

Tabela 1. Comparação dos algoritmos de roteamento oportunístico sociais presentes na literatura com a nossa proposta

uma rede de acordo com sua popularidade. Essas soluções, apesar de capazes de capturar interações sociais e suas intensidades, possuem desempenho limitado em termos de *overhead* quando comparadas com soluções baseadas em critérios sociais mais robustas.

Para extrair características sociais mais robustas, alguns estudos consideram a existência de estruturas coletivas sociais latentes, como comunidades ou grupos. Nesse cenário, indivíduos em uma mesma comunidade ou grupo compartilham conexões ou localidades em comum. Dada essa suposição, um indivíduo terá uma maior probabilidade de entregar uma mensagem para alguém que se encontra na mesma estrutura em comparação com alguém fora dela. Essa estratégia é aplicada no BUBBLE Rap [Hui et al. 2010], GROUPS-NET [Nunes et al. 2017a], SGBR [Abdelkader et al. 2012] e SAMPLER [Nunes et al. 2018] Enquanto que as comunidades são eficientes em detectar relações sociais, o cálculo das mesmas pode ter alta complexidade computacional e precisar de calibrações precisas de parâmetros.

Finalmente, o uso de infraestrutura adicional para ajudar na disseminação oportunística é também discutido. Essa infraestrutura é frequentemente vista na forma de nós estáticos, i.e., servidores ou pontos de acesso com fontes de energia ilimitadas e capacidade de armazenamento estendida. Dadas as suas características, eles são capazes de receber e transmitir mensagens dentro da rede com taxas de transmissão mais elevadas. Apesar de não substituírem o papel de nós móveis, os nós estáticos auxiliam na disseminação, aumentando a probabilidade do nó receber o conteúdo destinado a ele. O SAMPLER [Nunes et al. 2018] extrai um conjunto de Pontos de Interesse (PoI) que são usados como localização dos nós estáticos em suas simulações. Os resultados mostram que a solução foi capaz de aumentar consideravelmente a taxa de entrega.

De forma geral, este trabalho avança o estado da arte de roteamento oportunístico ao introduzir SocialRoute, um algoritmo para roteamento que utiliza de contatos sociais duradouros. A Tabela 1 destaca as características dos algoritmos de roteamento oportunístico com características sociais encontrados na literatura e como a nossa solução se compara a elas, sendo a primeira a aplicar uma abordagem mais robusta na detecção de interações sociais em contatos.

3. O Papel das Relações Sociais na Conectividade das Redes

Em redes móveis, estamos interessados em maximizar a qualidade do serviço (QoS) através do entendimento e do uso do contexto no qual os usuários estão inseridos. Existem muitas formas de fazer isso, e nesta seção, queremos detectar as relações sociais presentes em ambientes movimentados, e como essas relações podem afetar a conectividade dos usuários das redes. Primeiro, introduzimos os traces de contatos utilizados neste traba-

lho seguida de sua análise utilizando algoritmos de detecção de comportamento social existentes na literatura, como também uma abordagem mais robusta.

3.1. Dados

Neste trabalho, usamos dois traces reais de contato em nossas análises: Dartmouth e NCCU. Ambos foram extraídos de ambientes similares (campus universitários), mas o trace de Dartmouth apresenta uma escala muito maior – tanto em número de usuários quanto em tempo de coleta – quando comparado ao trace de NCCU. Assim, comparamos como as técnicas existentes se adaptam a cenários com escalas diferentes, o que por si só é uma contribuição relevante. As principais características de cada trace são:

- **NCCU** O trace de NCCU [Tsai and Chan 2015] contém registros de 115 usuários que se movem em um campus universitário durante um período de 15 dias. Uma aplicação instalada em seus *smartphones* coleta seus dados GPS, e a proximidade entre indivíduos é capturada via Bluetooth. Esses dados são registrados uma vez a cada 10 minutos, e os contatos foram detectados sempre que dois usuários estão a menos de 10 metros de distância.
- **Dartmouth.** O trace de Dartmouth [Kotz et al. 2009] contém registros das conexões de usuários aos Access Points (AP) da rede do campus da Universidade de Dartmouth, EUA. Durante mais de quatro anos, mais de 5 mil usuários distintos foram registrados no trace. Um novo registro é gerado sempre que um dispositivo se conecta a um AP, contendo o ID do AP e o *timestamp* do momento da conexão. Um contato é registrado quando dois usuários estão conectados simultaneamente a um mesmo AP. Em nossas análises, utilizamos um subconjunto dos dados correspondente ao mês de Outubro de 2001.

Em adição aos contatos já capturados nos traces, também estamos interessados em detectar contatos que acontecem enquanto os usuários estão se movendo. Para isso, usamos o simulador ONE [Keränen et al. 2009] para simular o movimento dos usuários entre as posições registradas nos traces e, a partir desses movimentos, extraímos contatos adicionais. Consideramos um raio de 10 m para que ocorra um contato, sem duração mínima de tempo. Os traces utilizados em nossas análises contêm não só seus contatos originais, como também os detectados nesta etapa.

3.2. Propriedades dos Nós

Nós e seus contatos em uma rede podem ser modelados como um grafo, possibilitando a aplicação de um grande número de propriedades e algoritmos. Desta forma, muitas métricas utilizadas na teoria de grafos para indicar propriedades de nós e contatos também são aplicáveis a nossa modelagem da rede. Mais do que isso, podemos usar esse conhecimento das propriedades dos grafos para modelar os comportamentos sociais de usuários e para definir regras que regulam a disseminação de mensagens. Para isso, analisamos duas métricas de grafo comumente usadas em estratégias de roteamento oportunístico: grau do nó e *betweenness* do nó. A primeira trata do número de arestas conectadas ao nó (i.e., seus contatos), um indicador claro de sua popularidade. Já o segundo é uma medida de sua centralidade, definida como a proporção de caminhos mais curtos entre cada par de nós na rede que passam por ele.

Com base nisso, alguns estudos [Mtibaa et al. 2010, Costa et al. 2020, Hui et al. 2010] consideram a correlação positiva entre o grau (ou *betweenness*) do

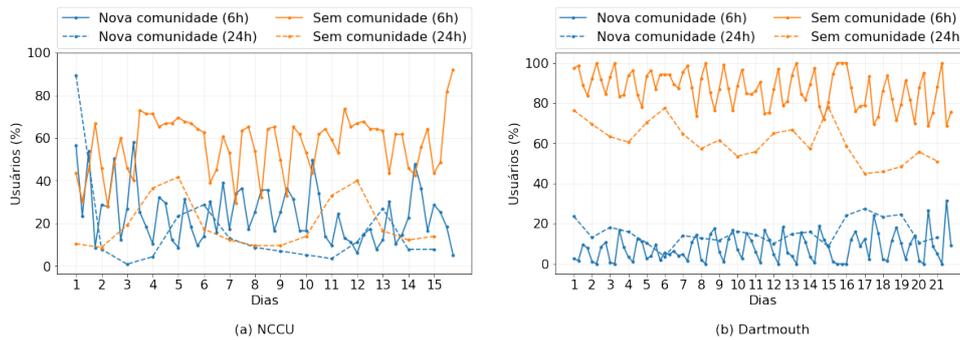


Figura 1. Evolução das comunidades dos usuários

nó com sua capacidade de transmitir uma mensagem. Para investigar essa suposição, realizamos o seguinte teste: para cada trace, um conjunto de mensagens foi disseminado através da estratégia de inundação (*flooding*), e para cada mensagem entregue, analisamos o caminho tomado por ela e contamos para cada nó o número de vezes que ele participou em algum caminho. Em seguida, essa informação foi correlacionada com seus valores de grau e *betweenness*. Em ambos os casos, existe uma correlação positiva fraca ($R = 0.3$ para NCCU e $R^2 = 0.17$ para Dartmouth quanto ao grau, e $R = 0.28$ para NCCU e $R = 0.2$ para Dartmouth quanto ao *betweenness*). Além disso, estudos mais recentes [Domingues et al. 2019, Nunes et al. 2018] argumentam que tais abordagens simples falham em capturar as propriedades intrínsecas das relações sociais, suas distribuições espaciais e como elas evoluem com o tempo. Finalmente, ao utilizar esse tipo de estratégia, aplicamos nos nós mais qualificados a carga de serem *switches* altamente demandados na rede, o que pode levar ao uso excessivo de seus recursos, enquanto outros nós menos populares permanecem ociosos grande parte do tempo.

3.3. Comunidades Sociais

Outra possível abordagem para capturar laços sociais em uma rede é através da detecção de comunidades, usando métodos como o *Clique Percolation Method* (CPM) [Palla et al. 2005]. Nele, comunidades são definidas como a união de cliques adjacentes em um grafo. Assim, dada a alta conectividade entre nós em uma mesma comunidade, existe uma alta probabilidade que mensagens sejam entregues ao adentrá-las. Ou seja, um nó fora da comunidade poderia transmitir a mensagem para qualquer nó na comunidade mantendo uma alta probabilidade de que ela chegue ao destinatário.

Essa estratégia é usada por BUBBLE Rap [Hui et al. 2010], GROUPS-NET [Nunes et al. 2017a] e SAMPLER [Nunes et al. 2018]. No entanto, em aplicações reais, as comunidades necessitam ser computadas e atualizadas periodicamente para considerar as mudanças na rede. Como visto na Fig. 1, avaliamos como os nós mudam de comunidades com o passar do tempo. Após dividir cada trace em períodos de tempo, comparamos as comunidades detectadas previamente com aquelas recentemente recalculadas. Para isso, utilizamos o CPM e checamos, para cada nó, se mais do que 50% de seus pares da comunidade anterior mudaram para outra. Essa análise foi feita com intervalos de tempo de 6 h e 24 h, e de forma geral, os intervalos de 24 h oferecem comunidades mais estáveis do que aqueles de 6 h. Entretanto, em ambos os cenários, há uma grande porcentagem de nós que não pertencem a nenhuma comunidade, sendo esse valor ainda mais

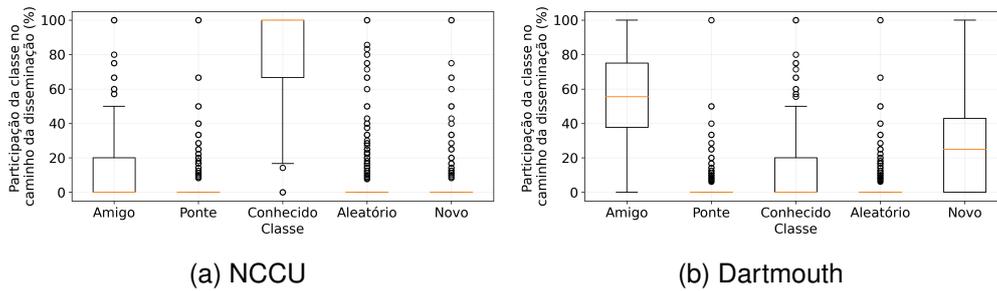


Figura 2. Participação das classes sociais na disseminação de mensagens por inundação

expressivo para Dartmouth (Fig. 1b). Considerando que o CPM é um algoritmo computacionalmente intensivo, o fato de muitos nós não possuírem comunidades atribuídas é um desperdício de recursos e uma subutilização das estratégias de roteamento.

3.4. Contatos Sociais

A caracterização de contatos em uma rede possui inúmeras implicações em seu desenvolvimento. Ao identificar o comportamento de um grupo de usuários, podemos, por exemplo, prover melhores estimativas da habilidade de cada usuário de transmitir uma mensagem em um cenário oportunístico. RECAST [de Melo et al. 2015] utiliza duas métricas de redes complexas, persistência dos contatos e sobreposição topológica (coeficiente de *jaccard*), para classificar os contatos em traces de mobilidade como sociais ou aleatórios. A primeira métrica indica a frequência na qual ocorrem contatos entre dois usuários em uma rede, enquanto que a segunda indica quantas conexões em comum são feitas entre os seus contatos. Esses valores são computados para cada par de usuários no trace e comparados com valores obtidos de um grafo aleatório, para indicar se estão próximos (i.e., são aleatórios) ou não (i.e., são sociais) de um comportamento estocástico. Adicionalmente, contatos classificados como sociais são divididos em três subcategorias: *amigos* (alta regularidade de encontro e alto número de contatos em comum), *conhecidos* (encontros menos frequentes, porém ainda compartilham um alto número de contatos em comum) e *pontes* (encontros frequentes porém com baixo número de contatos em comum).

Na Fig. 2, avaliamos como cada classificação dos contatos – incluindo aqueles aleatórios – participam na entrega de mensagens na rede. Novamente, utilizamos a estratégia de inundação e contamos somente as transmissões que levam a uma entrega com sucesso. Como pode ser visto para ambos os casos (Figs. 2a e 2b), contatos sociais possuem um papel consideravelmente mais importante no roteamento, sugerindo que o RECAST é um algoritmo útil na avaliação de quais contatos devem ser preferidos na transmissão de mensagens. Como as três subcategorias representam traços sociais entre usuários, não iremos analisá-las separadamente neste trabalho. Portanto, a partir de agora, consideramos cada uma delas como um contato social, para visualizar de forma mais clara as diferenças entre contatos sociais e aleatórios.

Ao considerarmos o problema da evolução das comunidades discutido acima, decidimos analisar se os contatos sociais iriam exibir um comportamento diferente. A análise foi feita supondo que se um contato foi classificado como social no primeiro dia de cada trace permaneceria como social nos dias seguintes, dadas as novas interações

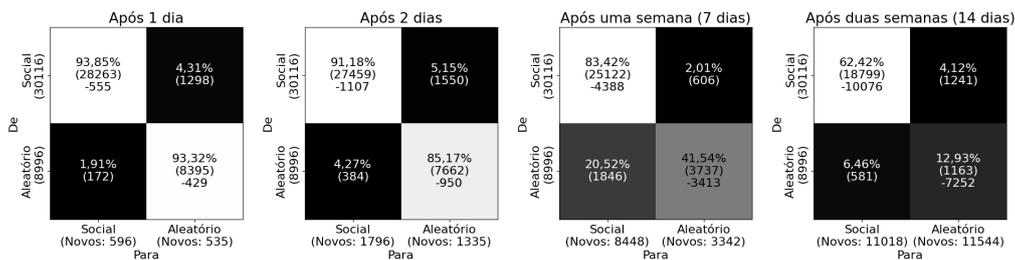


Figura 3. Mudanças nos contatos sociais e aleatórios capturadas com o passar do tempo para o trace de Dartmouth

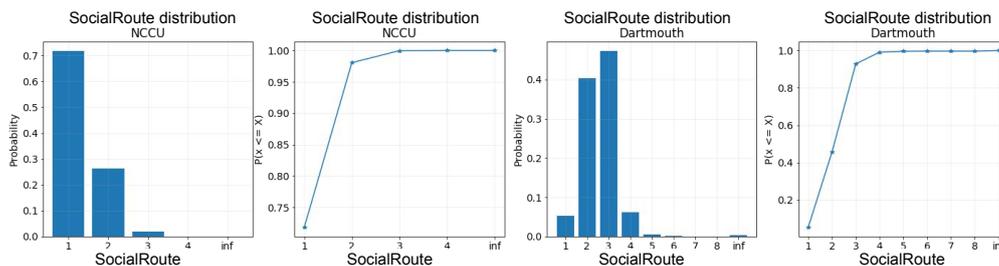


Figura 4. Análise do SocialRoute para os trace de NCCU e Dartmouth

que ocorrem. A Fig. 3 mostra os resultados dessa análise, onde cada matriz representa o número de contatos que permaneceram como social (e os que mudaram para aleatório) nos próximos dias, até duas semanas depois. Ela também mostra o número de novos contatos que não foram detectados previamente, e os contatos que desapareceram (marcados com um sinal negativo). Considerando até uma semana, mais do que 80% dos contatos primeiramente classificados como social assim se mantiveram, indicando que a atualização das classificações dos contatos de forma frequente pode não ser necessária. Mais além, neste ponto existem mais contatos aleatórios que se tornaram sociais do que o contrário. Finalmente, mesmo se considerarmos um período de atualização mais curto, como dois dias (o que garantiria uma consistência na classificação maior do que 90%), o custo computacional ainda será menor quando comparado às comunidades, que precisam ser atualizadas com maior frequência.

4. SocialRoute

Nesta seção introduzimos SocialRoute, uma estratégia de roteamento oportunístico baseada em contatos sociais. SocialRoute substitui a coleta de traços sociais através de comunidades pelo uso de contatos sociais, que são classificados de acordo com cada relacionamento individual e suas características. Com essa informação em mãos, o algoritmo faz o roteamento de mensagens de acordo com o grau da relação social entre usuários em um contato. Adicionado a isso, SocialRoute considera a implantação de nós transmissores estáticos localizados em Pontos-de-Interesse (PoI) para auxiliar na disseminação. O algoritmo pode ser dividido em duas partes: a primeira é a fase de classificação, responsável por usar dados históricos de contatos para o ranqueamento dos contatos entre todos os nós na rede; a segunda parte é a fase de aplicação, que utiliza o conhecimento obtido na primeira para realizar o roteamento oportunístico das mensagens na rede.

4.1. Fase de Classificação

Nesta fase, o algoritmo analisa dados históricos de contatos para detectar as relações sociais e aleatórias, de acordo com o algoritmo RECAST. Os traces servem como entrada ao RECAST, que produz as classificações dos contatos, e em seguida removemos os contatos classificados como aleatórios, dado o seu papel irrelevante na disseminação. Dado isso, a tabela de roteamento social é construída, contendo as distâncias (em *hops*) entre todos os pares de nós na rede. Dessa forma, um par de nós diretamente conectados terão um valor de SocialRoute igual a 1, enquanto que um par de nós conectados através de um nó intermediário terá um valor igual a 2, e assim por diante. Caso o grafo seja desconexo, dois nós inalcançáveis terão valores de SocialRoute definidos como infinito.

Essa fase é o gargalo do SocialRoute, dado que as melhores soluções para computar o caminho mínimo entre todos os pares em um grafo possuem complexidade de tempo de $\mathcal{O}(n^3)$, onde n é o número de nós na rede. Entretanto, a detecção de comunidades utilizando o CPM possui complexidade de $\mathcal{O}(n^k)$, onde n é o número de nós na rede e k é o tamanho da clique, que usualmente é 3. Por outro lado, enquanto que o CPM precisa ser executado frequentemente para atualizar as comunidades, a fase de classificação do SocialRoute pode ser executada esporadicamente, dado que os laços sociais detectados duram mais tempo (Fig. 3).

A Fig. 4 mostra a distribuição dos valores de SocialRoute obtidos para todos os contatos dos traces de NCCU e Dartmouth. Para NCCU, é possível observar que aproximadamente 70% dos pares possuem valor de SocialRoute igual a 1, indicando que a rede é densa e fortemente conexa. Os 30% restantes estão concentrados no valor de SocialRoute 2, e somente alguns poucos pares possuem grau 3 de separação. Para o trace de Dartmouth, somente uma fração dos pares possui valores de SocialRoute igual a 1, com a maioria se concentrando nos valores de 2 ou 3. Ao contrário de NCCU, Dartmouth possui alguns valores de SocialRoute igual a infinito, indicando que o grafo é desconexo, o que é esperado devido à escala maior da rede.

4.2. Fase de Aplicação

Esta fase consiste na disseminação oportunística considerando os valores de SocialRoute extraídos na fase anterior. De forma geral, SocialRoute funciona da seguinte maneira:

1. Uma mensagem sempre é replicada se um nó encontra o destinatário;
2. Uma mensagem sempre é replicada a um nó estático se ele não possui uma cópia da mesma;
3. Ao encontrar um nó sem a mensagem, um nó estático a replicará somente se o nó possuir valor de SocialRoute igual a 1, de acordo com uma função de probabilidade de disseminação \mathcal{F} ;
4. Em qualquer encontro de nós não estáticos, a mensagem é replicada se o nó encontrado não possui uma cópia e se ele possui valor de SocialRoute menor do que aquele portando a mensagem. Quando isso acontece, o nó portador atualizará seu valor de SocialRoute para o valor do nó encontrado, e portanto transmissões futuras só ocorrerão a nós com valores abaixo do valor encontrado;

O Algoritmo 1 mostra os passos da aplicação do SocialRoute quando dois nós quaisquer – um portando a mensagem e o outro não – se encontram. Esse procedimento é executado

em cada encontro para cada mensagem única enviada de um remetente para um destinatário, até que o tempo de vida da mensagem (TTL) passe e as cópias sejam descartadas. Algumas observações podem ser feitas: não há regra definida que limite o número de transmissões feitas por um nó não-estático; por outro lado, quando dois nós não-estáticos se encontram e o valor de SocialRoute é igual a 1, eles não serão capazes de encontrar nós com valores inferiores, e portanto cessarão suas transmissões. Adicionalmente, para cada destinatário diferente, existirá um conjunto diferente de nós com valores inferiores de SocialRoute que serão preferidos, resultando em uma distribuição das tarefas de disseminação mais balanceada quando comparada às outras abordagens existentes.

Algorithm 1: SocialRoute – Transmissão em um contato

Data: Nó N_i com mensagem \mathcal{M} , Nó encontrado N_j sem mensagem \mathcal{M}

```

1 if  $N_j$  é NÓ_DESTINO then
2   | transmit  $\mathcal{M}$  from  $N_i$  to  $N_j$ 
3 else if  $N_j$  é NÓ_ESTÁTICO then
4   | transmit  $\mathcal{M}$  from  $N_i$  to  $N_j$ 
5 else if  $N_i$  é NÓ_ESTÁTICO then
6   | if  $N_j$ .SocialRoute = 1 then
7     | | transmit  $\mathcal{M}$  from  $N_i$  to  $N_j$  according to  $\mathcal{F}$ 
8 else if  $N_j$ .SocialRoute <  $N_i$ .SocialRoute then
9   |  $N_i$ .SocialRoute  $\leftarrow$   $N_j$ .SocialRoute;
10  | transmit  $\mathcal{M}$  from  $N_i$  to  $N_j$ 
11 end

```

A implantação de nós estáticos nos PoIs aumenta o alcance das mensagens na rede ao garantir sua disponibilidade constante em locais frequentemente visitados. Por outro lado, a sua popularidade pode resultar em um grande número de encontros, aumentando o *overhead* sem que haja um ganho significativo em entrega. Para evitar esse comportamento, introduzimos dois perfis de disseminação, que podem ser selecionados de acordo com o interesse do remetente, as características do conteúdo sendo enviado e a prioridade do mesmo. Tais perfis são representados por funções que levam em consideração o tempo decorrido desde a transmissão da mensagem pelo remetente e o número de cópias já disseminadas pelo nó estático. Assim, temos:

- Função de probabilidade crescente: aqui, estamos interessados em evitar a disseminação por nós estáticos para favorecer possíveis encontros que podem acontecer entre os nós de origem e destino em um futuro próximo. Essa estratégia permite uma redução geral no *overhead* em troca de um aumento no tempo de entrega. A probabilidade de transmissão começa em um valor inferior e aumenta na medida que o tempo passa. Ao mesmo tempo, a probabilidade diminui na medida em que o número de cópias transmitidas pelo nó estático aumenta. A função recebe a forma de um decaimento exponencial e é definida como:

$$\mathcal{F}_i = e^{\frac{x-I}{\max(M-t,1)}} \times P$$

onde x representa o tempo passado – em intervalos discretos de um total I – desde a criação da mensagem na origem, M é um limiar superior para o número esperado de cópias que o nó estático enviará para cada mensagem, t é o número de cópias já enviadas, e P é um limiar superior para a probabilidade máxima de transmissão.

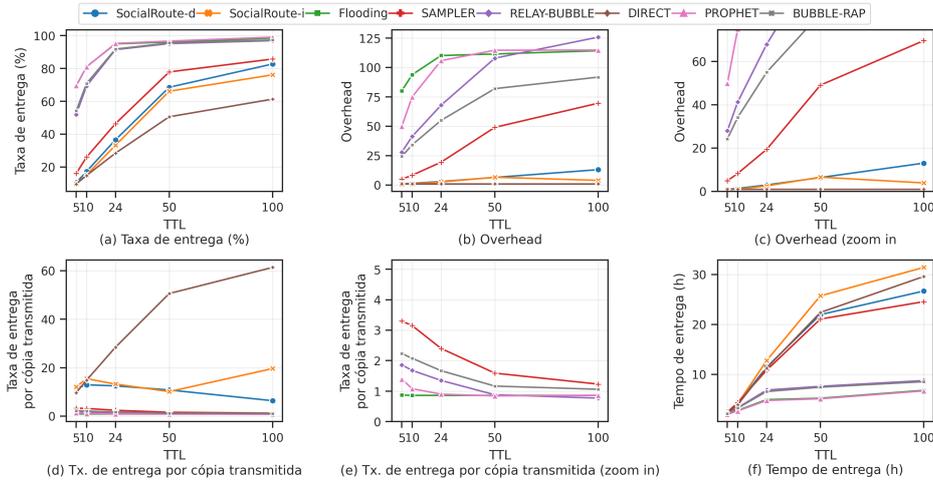


Figura 5. Simulações para o trace de NCCU com 5 nós estáticos

- Função de probabilidade decrescente: ao utilizar essa função, estamos interessados em disseminar o maior número de cópias a partir do início da transmissão de forma a alcançar o destino no menor tempo possível. Assim, favorecemos um tempo menor de entrega em troca de um *overhead* maior. A probabilidade de transmissão começa no valor mais alto possível e diminui com o tempo. Assim como na função crescente, a probabilidade decresce na medida em que o número de cópias já enviadas pelo nó estático aumenta. A função é definida como:

$$\mathcal{F}_d = e^{\frac{-x}{\max(M-t, 1)}} \times P.$$

5. Validação

No trace de NCCU, todos os 177 usuários participam como remetentes e destinatários, com cada usuário realizando uma tentativa de entrega a todos os outros, totalizando 13,572 mensagens. Por outro lado, dada a escala do trace de Dartmouth, selecionamos um subconjunto de usuários que participam como remetentes e destinatários. Para fazer essa amostra, estratificamos os usuários em grupos de acordo com o seu grau na rede. Nove grupos foram criados, e 13 usuários de cada grupo foram amostrados aleatoriamente, totalizando 117 usuários selecionados e 13,572 mensagens. Os usuários restantes no trace participam da disseminação, atuando como nós intermediários para a mensagem.

Em ambos os cenários, cada mensagem parte do nó de origem quando o mesmo se torna ativo na rede (i.e., gerando registros), dentro do intervalo de 8 h às 16 h, visando evitar a disseminação em horários indesejados, como a madrugada. Para a configuração dos nós estáticos, variamos o número k de PoIs cobertos de $k = \{5, 30\}$ para avaliar as variações no desempenho. Porém, diferente de [Nunes et al. 2018], não selecionamos os nós estáticos de acordo com os k locais mais populares, e sim de acordo com os k locais que fornecem a maior cobertura de usuários distintos (dado o histórico de localizações reportadas pelos usuários durante a fase de classificação). Finalmente, consideramos os valores $H = \{5, 10, 24, 50, 100\}$ como o tempo de vida da mensagem (TTL, em horas). Essas definições são compartilhadas por todos os algoritmos avaliados. Para comparar os resultados entre os algoritmos, avaliamos as seguintes métricas:

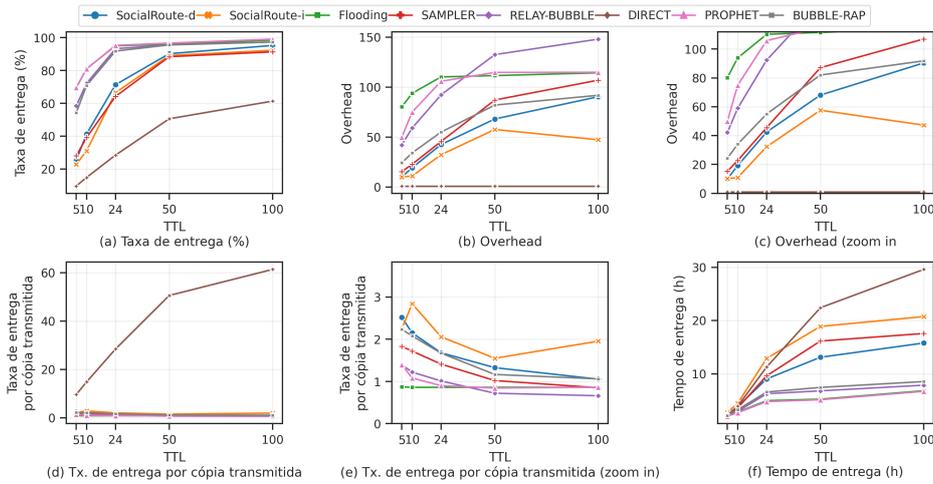


Figura 6. Simulações para o trace de NCCU com 30 nós estáticos

- Taxa de entrega: representa a porcentagem de mensagens entregues;
- Número de transmissões por mensagem (*overhead*): representa o número de cópias transmitidas entre nós para uma dada mensagem;
- Aumento na taxa de entrega por cópia transmitida: representa a razão entre as duas primeiras métricas, dando uma compreensão de como cada cópia transmitida contribui para a taxa de entrega final;
- Tempo de entrega: mede o tempo que leva para a mensagem sair do nó de origem e chegar ao nó de destino.

Por fim, para comparar com o SocialRoute, consideramos seis soluções existentes na literatura, sendo quatro baseadas em características sociais:

- Inundação (*Flooding*): mensagens são replicadas sempre que um nó é encontrado – representa o limite superior de taxa de entrega e o inferior de tempo de entrega;
- Transmissão direta (*Direct*): mensagens são encaminhadas ao encontrar diretamente o destinatário – representa o limite inferior da taxa de entrega e *overhead*;
- PROPHET [Lindgren et al. 2004]: mensagens são replicadas de acordo com um modelo probabilístico – cada nó é atribuído uma probabilidade de ser capaz de entregar mensagens a um destinatário;
- BUBBLE Rap [Hui et al. 2010]: mensagens são replicadas de acordo com os valores de *GlobalRank* e *LocalRank* dos usuários, definidos de acordo com suas comunidades;
- Relay-BUBBLE [Nunes et al. 2018]: opera de forma similar ao BUBBLE Rap, com a adição de nós estáticos em PoIs;
- SAMPLER [Nunes et al. 2018]: similar ao Relay-BUBBLE, porém utiliza o raio de giro dos nós como *GlobalRank*.

Avaliamos o SocialRoute usando ambas \mathcal{F}_i e \mathcal{F}_d (*SocialRoute-i* e *SocialRoute-d*, respectivamente). Para o trace de NCCU, os parâmetros de ambas as funções são $I = 10$, $M = 2$ e $P = 0.25$, enquanto que para Dartmouth utilizamos $I = 10$, $M = 5$ e $P = 0.9$ – definidos empiricamente. Em relação à fase de classificação dos contatos, usamos dados históricos de contatos (11 dias para NCCU e 15 para Dartmouth) como entrada. Tais

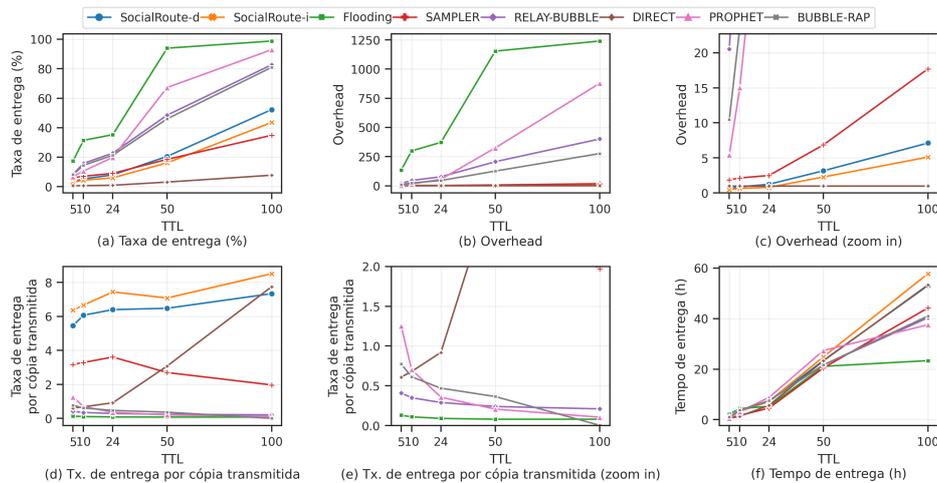


Figura 7. Simulações para o trace de Dartmouth com 5 nós estáticos

dados não são considerados durante a simulação, e as classificações obtidas são utilizadas durante toda a simulação. Por outro lado, para as soluções baseadas em comunidades, atualizamos as mesmas a cada 6 h, de acordo com suas implementações originais.

Começamos avaliando os resultados para o trace de NCCU com 5 (Fig. 5) e 30 (Fig. 6) nós estáticos. Para a taxa de entrega, há uma divisão em três grupos: BUBBLE Rap, PROPHET, Flooding e Relay-BUBBLE possuem as maiores taxas, ultrapassando 95% para o TTL 100. Em seguida, temos o SAMPLER (85%), SocialRoute-d (82%) e SocialRoute-i (76%), e por fim Direct, com somente 61%. Por outro lado, o melhor desempenho quanto ao *overhead* é Direct (1), SocialRoute-i (3,9) e SocialRoute-d (13). Mais além, o *overhead* do SocialRoute-i é mais de 17 vezes menor (5 para SocialRoute-d) do que o do SAMPLER – o algoritmo com características sociais com a maior taxa de entrega – e mais de 25 vezes menor (7 para SocialRoute-i) do que o do PROPHET. Esta eficiência pode ser vista melhor ao olharmos para a taxa de entrega por cópia transmitida, onde SocialRoute-i e SocialRoute-d atingem valores de 19,6 e 6,4, respectivamente. Por fim, SocialRoute-d possui tempo médio de entrega próximo dos valores obtidos por SAMPLER, enquanto SocialRoute-i possui tempos maiores (atendendo as definições das funções de disseminação). Considerando 30 nós estáticos (Fig. 6), SocialRoute obtêm taxas de entregas maiores que o SAMPLER, enquanto mantém *overheads* menores, especialmente para SocialRoute-i.

Para o trace de Dartmouth (Figs. 7 e 8), há um comportamento similar. Porém, dada a maior escala deste cenário, a diferença do *overhead* entre o SocialRoute e as outras soluções é ainda maior. Para a simulação com 5 nós estáticos (Fig. 7), SocialRoute-d e SocialRoute-i alcança taxas de entrega de 52,3% e 43,5%, respectivamente, contra 34,8% do SAMPLER e 92,9% do PROPHET. Porém, ambas as estratégias do SocialRoute possuem *overhead* menor que 10, enquanto o PROPHET atinge 879. Esta abordagem de baixo-custo se traduz em um tempo médio de entrega mais alto para o SocialRoute. Para a simulação com 30 nós estáticos (Fig. 8), as diferenças de taxa de entrega e tempo médio de entrega entre SocialRoute e os outros algoritmos reduz, enquanto o mesmo mantém *overhead* mais do que 30 vezes menor. Finalmente, os resultados para o trace de Dartmouth também confirmam que as funções de probabilidade de disseminação se

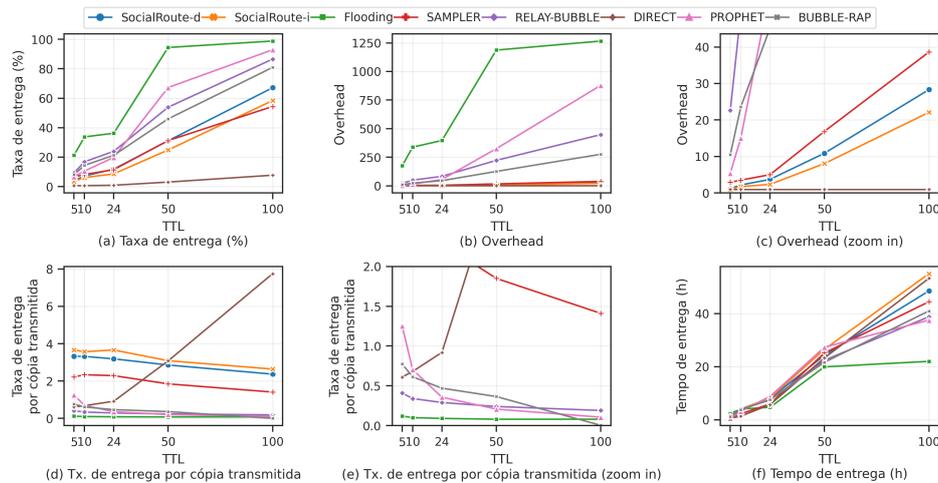


Figura 8. Simulações para o trace de Dartmouth com 30 nós estáticos

comportaram como esperado.

6. Conclusão

De forma geral, SocialRoute apresenta uma solução para roteamento oportunístico de baixo custo, alcançando altas taxas de entrega enquanto mantém um *overhead* baixo. Apesar de apresentar tempos de entrega maiores, a variação é pouco expressiva e aceitável no contexto de redes tolerantes a atrasos (DTN). Assim, não é a melhor alternativa para conteúdos de alta prioridade; nesse caso, algoritmos que priorizam o tempo de entrega devem ser adotados. Adicionalmente, também vimos como as funções de probabilidade resultaram em perfis de disseminação diferentes – com um *trade-off* claro entre *overhead* e tempo de entrega. Assim, a seleção pode ser feita de acordo com o conteúdo sendo disseminado e sua prioridade. Adicionalmente, em comparação com soluções baseadas em comunidades, SocialRoute requer atualizações menos frequentes para sua camada social, reduzindo o uso dos recursos dos usuários. Por fim, os resultados para a simulação de Dartmouth enriquecem estudos prévios ao mostrar como os algoritmos analisados se comportam em um cenário maior. Trabalhos futuros incluem testes adicionais do papel das classes na disseminação, a criação de outros perfis de transmissão, e a avaliação de cenários com contextos sociais, espaciais e temporais diferentes, dadas as limitações dos conjuntos de dados utilizados.

Referências

- Abdelkader, T., Naik, K., Nayak, A., Goel, N., and Srivastava, V. (2012). Sgr: A routing protocol for delay tolerant networks using social grouping. *IEEE Transactions on Parallel and Distributed Systems*, 24(12):2472–2481.
- Costa, R. L., Viana, A. C., Ziviani, A., and Sampaio, L. N. (2020). Towards human-aware d2d communication. In *Intl’ Conf. on Distributed Computing in Sensor Systems (DCOSS)*, pages 173–180. IEEE.
- Daly, E. M. and Haahr, M. (2007). Social network analysis for routing in disconnected delay-tolerant manets. In *Proceedings of the 8th ACM Intl’ Symp. on Mobile Ad hoc Networking and Computing*, pages 32–40.

- de Melo, P. O. V., Viana, A. C., Fiore, M., Jaffrès-Runser, K., Le Mouël, F., Loureiro, A. A., Addepalli, L., and Guangshuo, C. (2015). Recast: Telling apart social and random relationships in dynamic networks. *Performance Evaluation*, 87:19–36.
- Domingues, A. C., Santana, H. d. S., Silva, F. A., Vaz de Melo, P. O., and Loureiro, A. A. (2019). Are we still friends? evaluating tie persistence in mobility traces. In *17th Intl' Symp. on Mobility Management and Wireless Access*, pages 1–8.
- Hui, P., Crowcroft, J., and Yoneki, E. (2010). Bubble rap: Social-based forwarding in delay-tolerant networks. *IEEE Transactions on Mobile Computing*, 10(11):1576–1589.
- Javed, M. A., Younis, M. S., Latif, S., Qadir, J., and Baig, A. (2018). Community detection in networks: A multidisciplinary review. *Journal of Network and Computer Applications*, 108:87–111.
- Keränen, A., Ott, J., and Kärkkäinen, T. (2009). The one simulator for dtn protocol evaluation. In *2nd Intl' Conf. on Simulation Tools and Techniques*, pages 1–10.
- Kotz, D., Henderson, T., Abyzov, I., and Yeo, J. (2009). CRAWDAD dataset dartmouth/campus (v. 2009-09-09). Downloaded from <https://crawdad.org/dartmouth/campus/20090909>.
- Lindgren, A., Doria, A., and Schelen, O. (2004). Probabilistic routing in intermittently connected networks. In *Intl' Workshop on Service Assurance with Partial and Intermittent Resources*, pages 239–254. Springer.
- Moreira, W., Mendes, P., and Sargento, S. (2013). Social-aware opportunistic routing protocol based on user's interactions and interests. In *Intl' Conf. on Ad hoc Networks*, pages 100–115. Springer.
- Mtibaa, A., May, M., Diot, C., and Ammar, M. (2010). Peoplerank: Social opportunistic forwarding. In *2010 Proceedings IEEE INFOCOM*, pages 1–5. IEEE.
- Nunes, I. O., Celes, C., de Melo, P. O. V., and Loureiro, A. A. (2017a). Groups-net: Group meetings aware routing in multi-hop d2d networks. *Computer Networks*, 127:94–108.
- Nunes, I. O., Celes, C., Nunes, I., de Melo, P. O. V., and Loureiro, A. A. (2018). Combining spatial and social awareness in d2d opportunistic routing. *IEEE Communications Magazine*, 56(1):128–135.
- Nunes, I. O., Celes, C., Silva, M. D., Vaz de Melo, P. O., and Loureiro, A. A. (2017b). Grm: Group regularity mobility model. In *Intl' Conf. on Modelling, Analysis and Simulation of Wireless and Mobile Systems*, pages 85–89. ACM.
- Palla, G., Derényi, I., Farkas, I., and Vicsek, T. (2005). Uncovering the overlapping community structure of complex networks in nature and society. *Nature*, 435:814–818.
- Poonguzharselvi, B. and Vetriselvi, V. (2013). Survey on routing algorithms in opportunistic networks. In *Intl' Conf. on Computer Communication and Informatics*, pages 1–5. IEEE.
- Tsai, T.-C. and Chan, H.-H. (2015). Nccu trace: Social-network-aware mobility trace. *IEEE Communications Magazine*, 53(10):144–149.