

# Predição de Mobilidade Baseado em Comportamento Social

*Wilson Lima Mendes Neto*  
wilsonlimann@gmail.com

*Paulo Henrique Bezerra*  
ph@unama.br

*Pós-Graduação Lato Sensu em Redes de Computadores – Universidade da Amazônia UNAMA*  
*"Campus" Quintino - Tv. Quintino Bocaiúva, 1808 - 66035-190 - Nazaré – Belém, PA – Brasil*

## Resumo

Mesmo com a liberdade do movimento humano, esse apresenta padrões estruturais devido a restrições geográficas e sociais, utilizando aplicativos de localização baseado em aplicativos de redes sociais e dados de localização de telefone celular, pretendemos entender o movimento humano e sua dinâmica, a combinação de movimentos periódicos e movimentos aleatórios correlacionados com a sua rede social. A essa frequência de movimentos periódicos e semelhantes foi elaborado modelo baseado em perfis móveis, esse perfil caracteriza o movimento do usuário, como se comporta ao longo do dia e semana.

### **Palavras-Chaves:**

*Predição de Mobilidade, Comportamento e redes sociais, mobilidade baseada em perfil móvel, amizade e comportamento.*

## 1. Introdução

O Trabalho propõe um estudo sobre a mobilidade humana, pretendendo entender essa mobilidade. Acreditamos que os seres humanos passam por uma combinação de movimentos aleatórios relacionados à sua rede sociais. A mobilidade é limitada geograficamente pela distância, as viagens curtas e periódicas não são influenciadas por sua rede social, enquanto a viagem de longa distância são mais influenciadas por sua estrutura de rede social, na qual somos mais propensos a visitar um lugar onde temos um amigo ou parente que mora ou que visitou no passado, apresentamos algumas questões fundamentais sobre a dinâmica humana, mas baseado em dados de localização de sites de redes sociais e dados de telefonia celular, nos oferece uma nova dimensão sobre mobilidade humana e seu comportamento social, em particular os dados de telefone celular nos fornece uma grossa precisão da localização, mas uma melhor resolução temporal, já os dados de localização fornecidos por redes sociais nos oferece uma localização mais precisa, mas por outro lado esses dados são mais esporádicos. A obtenção dos dados

baseado em redes sociais são na forma de *check-ins*, onde usuário marca sua localização fazendo um *check-in* no local onde se encontra naquele momento. Já os *check-ins* de telefone celular são feitos quando o usuário recebe ou faz uma ligação dentro do raio de alcance da torre de célula por isso não é tão preciso quanto a sua localização. Estas informações permite estudar três aspectos sobre a mobilidade humana: movimento geográfico (aonde vamos?), dinâmica temporal (quantas vezes nos movemos?) e nossa rede social (como nos laços sociais influenciam no nosso movimento?). Estudamos a interação de todos os três aspectos da mobilidade humana para elaborar um modelo coerente com a dinâmica do movimento humano. Em um contexto mais amplo, o entendimento e a modelagem da mobilidade humana possuem várias aplicações e consequências, um modelo preciso de mobilidade humana é essencial para o planejamento urbano, para compreensão da migração humana e uma visão na propagação de doenças. Para as redes de comunicação, a previsão de mobilidade se bem executada pode constituir uma solução de *handover* eficientes, especialmente em áreas urbanas, onde a gestão da mobilidade tem de lidar com aumento do número de assinantes móveis e células de recursos limitados.

Quanto ao comportamento periódico, a mobilidade apresenta-se na forma regular e aleatória, onde os movimentos regulares são mais previsíveis, que seria os movimentos que se apresentam periodicamente, como ir à aula que é sempre no mesmo horário e todos os dias, com ir ao trabalho e voltar pra casa, são movimentos que acontecem sempre nos mesmos horários e todos os dias da semana. Já os movimentos aleatórios geralmente se dão nos finais de semana e também à noite, esse são mais difíceis de prever. E são mais influenciados pela sua rede social. Esta noção baseia-se na hipótese de que o usuário móvel tem um comportamento regulares e que não é único, ele pode ser caracterizado por vários perfis de sua mobilidade.

## 2. Trabalhos Relacionados

Usando dados de localização, bem como os dados de *check-ins*, pretendemos entender as leis básicas que regem o movimento humano, usando dados de aplicativos de sites de redes sociais, como *Foursquare*, *Facebook*, *Gowalla*, onde os usuários compartilham sua localização com outros usuários da sua rede social, essa marcação da sua posição é chamada de *check-ins*, com isso temos dados mais específicos quanto a sua localização, um exemplo é que podemos distinguir um *check-in* feito no escritório do 2º andar de um *check-in* feito na cafeteria que fica no 1º andar do mesmo edifício. Já os *check-ins* de celular que são feitos todas as vezes que o usuário recebe ou faz uma ligação, esses *check-ins* de celular nos fornece uma grossa precisão da localização, isso porque é identificado localização da torre que atende aquela celular, mas possui uma ótima resolução temporal. Ambos os tipos de dados também contem informações de rede.

Com base no nosso estudo desenvolvemos um modelo de mobilidade humana que combina movimentos periódicos curtos e movimentos de longo alcance devido sua a estrutura de sua rede social. Propusemos um modelo em que o usuário possui perfis de sua mobilidade, baseado na hipótese de que usuário móvel tem a tendência de se comporta regularmente da mesma maneira. O objetivo do perfil móvel é pegar os comportamentos recorrentes, como ir e voltar do escritório a cada dia da semana e no mesmo horário que provavelmente usa o mesmo caminho para ir e para voltar, com esse grau de mobilidade, cada usuário móvel pode ser caracterizado por vários perfis de sua mobilidade, que geralmente tende a seguir ao se deslocar na área de cobertura. Assim é proposto comparar os dados de mobilidade identificando a existência de um perfil móvel que identifique a trajetória a ser seguida, tal como a sequencia de células ordenadas a parti da célula de origem até a célula destino, propomos uma abordagem algorítmica para identificar esse perfil, que reflete o caminho que o usuário ira seguir.

O modelos de perfil de previsão de mobilidade nos propõem a aproveitar arquitetura de redes com dois nós, em que nesta arquitetura todas as funções de mobilidade e recursos são a segurados por dois nós principais, *Enhanced GateWay* (EGW) e o *Base Station* (BS), ou melhor gateway aprimorado e estação base, cada conjunto de dados contém informações relacionadas as células a serem utilizadas pelo usuário móvel, cada célula sabe qual vai ser a próxima que o usuário móvel irá. Este modelo consiste

em duas etapas principais: etapa de aprendizagem e etapa de previsão, a etapa de aprendizagem consiste em identificar a celular seguinte a ser visitada pelo usuário, usando uma lista de perfis ou rastreamento de mobilidade, isso senão houver perfil disponível que identifique aquela trajetória.

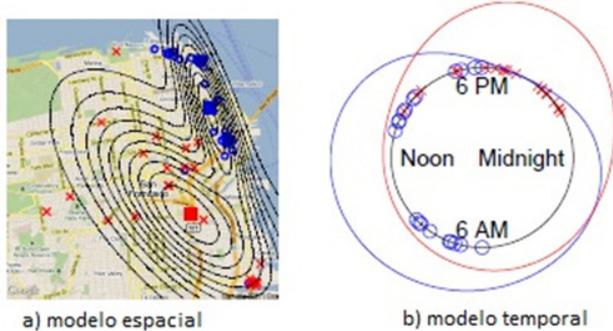
O método proposto pelo modelo de perfil móvel para previsão da mobilidade é uma combinação de um modelo de previsão de mobilidade e algoritmo de *Markov*, baseado em previsão de mobilidade. As cadeias de *Markov* são amplamente utilizadas como técnica de modelagem para previsão de mobilidade, o fundamental parâmetro de entrada para construir esse modelo Markoviano é a historia da mobilidade. Os modelos de mobilidades têm sido muito utilizados na execução de simulações para avaliações de algoritmos para *handoff*, na previsão de mobilidade, de vazão máxima, em algoritmos de roteamento, etc.

## 3. Análise das Propostas sobre a mobilidade baseada em site de redes sociais

A mobilidade é, provavelmente, limitada geograficamente pela distância que se pode viajar dentro de um dia. Além disso, a mobilidade pode ainda estar na forma de nossas relações sociais, como podemos ser mais propensos a visitar lugares que os nossos amigos ou parentes foram no passado, as hipóteses sobre a dinâmica da mobilidade humana e as respostas permanecem largamente desconhecidas, principalmente devido ao fato de que os dados sobre mobilidade humana eram difíceis de obter, entretanto recentemente surgiram aplicativos de localização baseados em rede social, onde o usuário compartilha sua localização atual com *check-in* em sites de redes sociais como o *Foursquare*, *Facebook*, *Gowalla*, etc. Estudos também têm explorado como redes sociais são incorporadas a geografia subjacente, e como esses geo dados podem ser usados para inferir em nossas relações sociais. Em contraste, estudamos a interação de todos os aspectos da mobilidade do ser humano para elaborar um modelo coerente com movimento humano e sua dinâmica. Nós estudamos a relação entre geográfica humana, movimento e sua dinâmica temporal, e os laços de rede social. Em particular, analisamos o papel da geografia e rotina diária sobre os padrões de mobilidade humana, bem como o seu comportamento social. Buscamos identificar os fatores fundamentais que regem essa mobilidade.

O Modelo de Mobilidade Periódica (PMM), construímos um modelo na intuição de que a maioria do movimento

humano é baseado no movimento periódico e entre um conjunto de estado latentes (locais). Para simplificar, introduzimos no nosso modelo apenas dois estados latentes (embora o modelo possa lidar com um numero arbitrário deles), podendo ser esses dois estados latentes “trabalho” e “casa”, onde dependendo da hora do dia o indivíduo estará em casa, no trabalho ou em algum lugar entres estes dois.



**Figura 1:** a) *Check-ins* de um usuário em San Francisco: distribuição geográfica de *check-ins*, quando em casa e no trabalho. b) Temporal modelo: a distância do centro para a linha vermelha / azul é proporcional a usuário estar em casa e no trabalho.

A Figura 1 ilustra o modelo onde no modelo espacial podemos ver informações geográficas quanto a sua localização nos dois estados latentes, no caso “trabalho” e “casa” e modelá-los em uma distribuição gaussiana, que modela a probabilidade do usuário estar em casa ou no trabalho em função da hora do dia, esse modelo temporal ilustra como o usuário fica em casa durante a noite em azul e no trabalho em vermelho durante o dia, na fig. 1 também temos o modelo espacial que mostra um usuário que vive em *Mission District*, um bairro de *San Francisco, CA*. Marcadas por cruzes vermelhas e marcadas por círculos azuis onde ele trabalha que é no centro financeiro de *San Francisco*. Para cada *check-ins* nos inferimos se ele foi gerado durante o estado “trabalho” ou “casa”, assim obtivemos um centro geográfico entre casa e trabalho. Podemos pensar também em nosso modelo de uma forma generativa. Um usuário determina a sua localização em *check-in* no seguinte modo: dada a hora do dia, as amostras do usuário revela se ele esta em casa ou no trabalho, dando prosseguimento a introdução do Modelo de Mobilidade Periódica, seja  $t$  a hora atual do dia e  $xu(t)$  o “estado” no tempo  $t$ , onde  $cu(t)=H$  denota que o usuário esta no estado “casa” do tempo  $t$ , e  $cu(t)=W$  indica que o

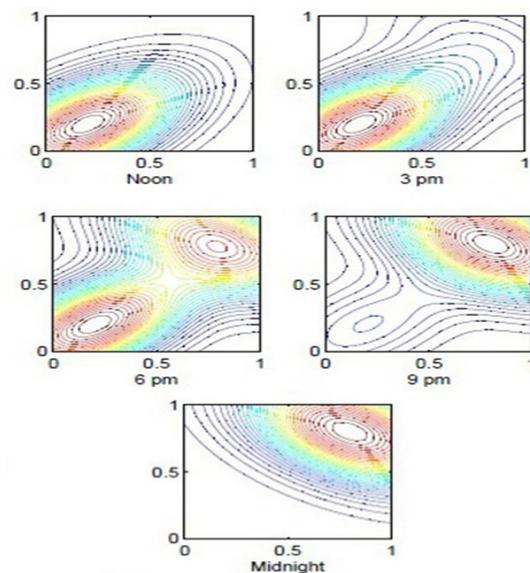
usuário esta no estado “trabalho”, a sua localização espacial é então regida pela distribuição dos *check-ins* “casa” e “trabalho”, que é  $P[x(t)=x|cu(t)]$  a distribuição de probabilidade da localização do usuário no tempo  $t$ , é simplesmente a mistura da localizações “casa” e “trabalho” onde os coeficiente são regidos pelo modelo temporal.

$$P[x(t)=x]=P[xu(t)=x|cu(t)=H] \cdot P[cu(t)=H] + P[xu(t)=x|cu(t)=W] \cdot P[cu(t)=W]$$

Isto significa que a qualquer momento o usuário pode estar no estado “casa” ou “trabalho”, então  $P[cu(t)]$  é modelo de distribuição de probabilidade sobre o estado do usuário ao longo do tempo.

O nosso modelo é efetivamente uma mistura de dois estados gaussianas, com estado dependendo do tempo, isso significa que o nosso modelo classifica cada uma dos *check-ins* do usuário com o estado “casa” ou “trabalho”. A parte temporal do modelo governa a transição entre os estados “casa” e “trabalho” e, em seguida, dependendo da localização geográfica do estado do *check-in* é gerado no tempo variando entre as duas variantes na distribuição gaussianas.

**Figura 2:** Modelo de Mobilidade periódica: densidade de probabilidade de localização do usuário ao longo do tempo como movimento do usuário de “trabalho” para “casa”.



A figura 2 mostra a distribuição da localização do usuário ao longo do tempo.

Modelo de Mobilidade periódica e social (PSSM). Referimo-nos ao novo modelo como modelo a inclusão das informações de redes social introduzimos uma outra classificação de *check-in*  $zu(t)$ , onde  $zu(t)=1$  implica que é um *check-in* social e não periódico, e outro  $zu(t)=0$  que é um *check-in* periódico. O modelo de mobilidade PSMM torna-se então:

$$P[x(t)=x]=P[x(t)=x|zu(t)=1] \cdot P[zu(t)=1] + P[x(t)=x|zu(t)=0] \cdot P[zu(t)=0]$$

Onde,  $P[x(t)=x|zu(t)=0]$  é o Modelo de Mobilidade Periódica (PMM).

Nos treinamos o modelo PMM onde nos permite classificar os *check-ins* como “casa”, “trabalho” e “social”. Assim, assumimos que os *check-ins* que não se encaixam no modelo periódico são resultados de atividades sociais (não periódicas). Obtivemos então que 10% a 30% de todos os *check-ins* são classificados como *check-ins* sociais, observamos também que os movimentos periódicos explicam 50% a 70% do comportamento.

#### 4. Análise da Proposta do Artigo sobre previsão de mobilidade usando perfil móvel.

Neste artigo, propomos uma nova abordagem para a previsão de mobilidade baseada na utilização de perfis de mobilidade ou perfil móvel, esta noção se baseia na hipótese de que um utilizador móvel tem tendência regulares de se comporta da mesma maneira. O objetivo de um perfil móvel é pegar comportamentos recorrentes, como ir ou voltar do escritório todos os dias da semana no mesmo horário. À medida que o comportamento do usuário móvel não é único, cada usuário móvel pode ser caracterizado por vários perfis, que geralmente, possui tendência de seguir quando se deslocam em uma área de cobertura de rede. Assim, o objetivo da abordagem é para correlacionar de maneira eficientemente os dados de mobilidade baseado na existência e identificação dos perfis de mobilidade do usuário.

Um modelo de previsão global, pode ser prever a localização usando os padrões de mobilidade do usuário, neste âmbito, modelos de previsão mobilidade com base em padrões de usuário foram propostos, onde temos um servidor contendo todos os perfis de mobilidade (perfil móvel, o caminho mais provável a ser seguido pelo usuário), o processo de previsão consiste em comparar o caminho do usuário atual, com seus caminhos

armazenados na base de dados.

O modelo proposto é interessante porque o itinerário completo está previsto, e não somente a próxima célula. No entanto, eles são limitados, pois todos os dados móveis de usuários são salvos em um único servidor.

O Perfil baseado em Modelo de Previsão de Mobilidade (PMPM) nos propõem aproveita a arquitetura de rede de dois nós. Nesta arquitetura todas as funções de mobilidade e recursos relacionados são assegurados por dois nós principais, *Gateway Enhanced* (aprimorado) e da Estação Base (BS). Tal arquitetura é comparável à de um *Long Term*, evolução da tecnologia (LTE), onde a gestão da mobilidade é descentralizada e as decisões são tomadas pelas entidades mais baixas, sem a necessidade de Core de rede.

A implementação de perfil baseado em Modelo de Previsão de Mobilidade, é feita no equipamento do usuário, onde são salvos os dados de mobilidade associado ao usuário móvel, cada conjunto de dados de mobilidade contém informação relacionada com todas as células atravessadas pelo usuário, juntamente com as sua permanência em células.

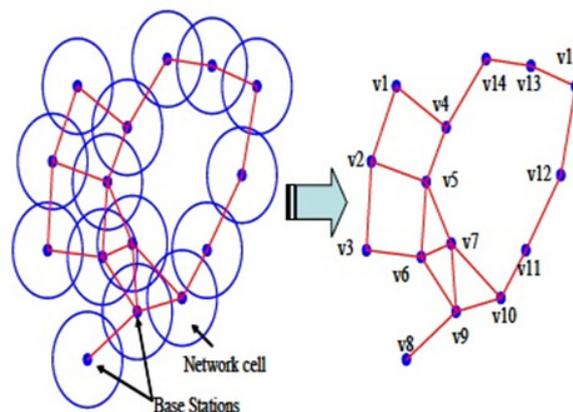


Figura 3: Exemplo de gráfico cobertura

O modelo proposto consiste em duas etapas principais: a etapa de aprendizagem e as etapas de previsão. A etapa de aprendizagem consiste em enriquecer o rastreamento da mobilidade e a lista de perfis móveis do usuário, a fase de predição consiste em identificar a célula seguinte a ser provavelmente visitada pelo usuário, usando uma lista de perfis ou rastreamento de mobilidade senão houver perfis disponíveis para a trajetória.

Em cada previsão, o PMPM informa a estação de base que serve que prepare um *gateway* aprimorado, e a entrega ao

usuário móvel a célula prevista para estação de base. A fim de identificar a célula seguinte a ser provavelmente visitada pelo usuário móvel.

À medida que o método proposto (PMPM) é uma combinação de um modelo de mobilidade previsão usando perfil móvel de usuário e a base de *Markov*. Algoritmo Previsão de Mobilidade (MMPA) dada, quando os perfis de usuário estão disponíveis a PMPM fazer previsões utilizando os perfis, no entanto, se não houver perfis disponíveis é porque ainda não foi criado para aquela trajetória, ou simplesmente não existe, a previsão de mobilidade baseia-se em algoritmos de *Markov* em PMPM. Quando a lista de perfis de usuários detectados é pobre ou apenas não estão completamente disponíveis ainda, o modelo baseado em *Markov* pode ser utilizado para estimar a probabilidade de transição para próxima célula.

A capacidade de aprendizagem permite que o nosso modelo atualizar os caminhos a ser seguido no conjunto de perfis móveis correspondente ao usuário. O modelo é desenvolvido para ser implementado em nível de equipamento do usuário e isto permite que a rede evite quaisquer restrições de escalabilidade quando se considera um número grande de usuários.

Os autores propõem dois modelos de previsão que são baseados em primeira ordem de cadeias de *Markov* e de segunda ordem de cadeias de *Markov*, respectivamente. Os resultados mostram que o modelo baseado em segunda ordem realizando previsões melhores do que as de primeira ordem.

A possibilidade de antever a próxima posição a ser ocupada por um usuário móvel permite a pré-alocação de recursos a ser utilizado pelo usuário móvel, tendo assim *handover* mais eficientes. *Handover* ou *handoff* é o procedimento empregado em rede sem fio para tratar a transição de uma unidade móvel de uma célula para outra de forma transparente ao usuário.

Métodos de modelagem probabilística, estes métodos, utilizam a história da mobilidade e à intensidade do sinal de rádio para prever um grupo de células mais prováveis a ser seguido pelo o usuário móvel, essa informação auxilia na descoberta da direção que o usuário irá tomar e realiza uma predição mais correta das próximas células a serem utilizadas, uma vez que a previsão é feita os recursos são reservados ao usuário em todas as células que pertencem a este grupo.

## 5. Análise dos resultados obtidos

Utilizando dados de localização de redes sociais que possuem aplicativos de localização *on-line*, como *Gowalla* e *Brightkite*, e dados de 2 milhões de usuários de uma operadora de telefonia móveis de um país europeu.

Observamos que as pessoas geralmente se movem periodicamente dentro de uma região limitada, mas ocasionalmente viajam a uma longa distância. As pessoas geralmente são mais propensas a visitar um lugar distante se for as proximidades de um amigo. Assim, talvez surpreendentemente as viagens de curta distância são menos influenciadas pela sua rede social, enquanto se uma pessoa viaja uma longa distância, elas são mais aptas a circular perto de um amigo existente. No geral, achamos que a influência da amizade sobre a mobilidade de uma pessoa é duas vezes mais forte do que a influência da mobilidade sobre a criação de novas amizades. Notamos também semelhanças entre os dados de telefone celular e da rede social baseada na *check-in* de localização. Geralmente, há benefícios e limites para o uso de mobilidade dos amigos para prever a localização de um indivíduo. Achamos que os usuários tem maior probabilidade de fazer *check-in* logo depois de um amigo ter feito um *check-in* no mesmo lugar. Com base nos nossos achados empírico, desenvolvemos um modelo de mobilidade periódica e Social para prever a mobilidade dos indivíduos. Também propusemos uma nova abordagem para a previsão da mobilidade com base em perfis móveis de usuário, com processos Markovianos e frequência de visita por células. Esta abordagem consiste em prever a próxima célula a ser visitada com base nos perfis de usuário extraídos a partir dos dados do histórico de mobilidade do usuário. Se a lista de perfis móveis do usuário não estiver disponível, cadeias de *Markov* ou frequências de visitas por células serão usados de acordo com a disponibilidade da informação necessária. A capacidade de aprendizagem permite que o nosso modelo atualize cada caminho recém-criado no conjunto de perfis móveis correspondente a este usuário. O modelo é desenvolvido para ser implementado no equipamento do usuário e isto permite evitar que a rede tenha quaisquer restrições de escalabilidade quando se considera um número maior dos usuários. A fim de avaliar o desempenho do nosso modelo de previsão, usamos conjuntos de dados reais de redes, os resultados obtidos comprovam que os usuários móveis seguem movimentos padrões semelhantes e a precisão de previsão do nosso

modelo baseado em perfil de previsão atinge valores superiores a 80% quando ele tem tempo suficiente para experimentar comportamentos do usuário.

## 6. Conclusão

Analisando os resultados obtidos do comportamento humano baseado em aplicativos de localização de sites redes sociais, verificou-se que o ser humano experimenta a combinação de movimentos de curto alcance e movimentos peridotíticos que não são influenciados pela sua estrutura de rede social, enquanto os movimentos de longo alcance são mais influenciado, verificou-se também que os movimentos não periódicos são também mais influenciados pela sua rede social.

A fim de avaliar o desempenho do nosso modelo de previsão utilizamos dados de *check-ins* de redes sociais, como *Facebook*, *Foursquare*, *Gowalla* e *Brightkite*, por possuírem uma precisão na localização dos seus *check-ins* e dados de telefone celular, que possui uma melhor resolução temporal. Mesmo que os dados de localização de redes sociais e os dados das torres de celulares sejam diferentes, encontramos padrões comuns de mobilidade humana através dos conjuntos de dados. Com isso mostramos que as redes sociais podem explicar cerca de 10% a 30% do comportamento humano e que o movimento periódico explica de 50% a 70%.

## 7. Referências

[1] Cho, E., Myers, S., and Leskovec, J. (2011). Friendship and Mobility: User Movement In Location-Based Social Networks. In Proc. of KDD'11.

[2] Barth, D, Bellahsene, S. and Kloul, L, (2011), Mobility Prediction Using Mobile User Profiles, IEEE 19th International Symposium

[3] A. Clauset, C. R. Shalizi, and M. E. J. Newman. Power-law distributions in empirical data. *SIAM Review*, 2009.

[4] N. Couldry and A. Mccarthy. *Mediaspace: Place, Scale and Culture in a Media Age* (Comedia). Routledge, Nov. 2003.

[5] D. Crandall, L. Backstrom, D. Cosley, S. Suri, D. Huttenlocher, and J. Kleinberg. Inferring social ties from geographic coincidences. *PNAS*, 2010.

[6] J. Cranshaw, E. Toch, J. I. Hong, A. Kittur, and N. Sadeh. Bridging the gap between physical location and online social networks. In *UbiComp*, pages 119–128, 2010.

[7] N. Eagle and A. Pentland. Eigenbehaviors: Identifying structure in routine. *Behavioral Ecology and Soc.*, 2009.

[8] N. Eagle, A. Pentland, and D. Lazer. Inferring friendship network structure by using mobile phone data. *PNAS*, 2009.

[9] S. Eubank, H. Guclu, V. S. Anil Kumar, M. V. Marathe, A. Srinivasan, Z. Toroczkai, and N. Wang. Modelling disease outbreaks in realistic urban social networks. *Nature*, 2004.

[10] E. Glaeser and M. Kahn. *Sprawl and urban growth*. Handbook of regional and urban economics, 2004.

[11] J. Goldenberg and M. Levy. Distance is not dead: Social interaction and geographical distance in the internet era. *Arxiv*, abs/0906.3202, 2009.

[12] Celtic telecommunication solution. Twinboard Project web site. [Online] Available: <http://www.celticinitiative.org/Projects/TWINBOARD/default.as>

[13] Celtic telecommunication solution. HomesNet Project web site. [Online] Available: <http://www.celticinitiative.org/Projects/HOMESNET/abstract.asp>

[14] The 3rd generation partnership project web site. [Online] Available: <http://www.3gpp.org/LTE>.