

Uma proposta de modelo para reconhecimento de intenções em ambientes *outdoor* a partir de dados de mobilidade

Rogério Avellar¹

¹Instituto de Computação – Universidade Federal Fluminense (UFF)
Niterói – RJ – Brasil

ravellar@gmail.com

Abstract. *When performing an activity, the user is always doing it with some intention. Current intent-recognition models generally focus on indoor and controlled environments, requiring prior instrumentation of both the environment and people. In this way, this work aims to present a model for intention recognition in environments heavily outdoors only by information of the trajectories and other contextual information that can be extracted from it. The recognition was evaluated through classifiers in which it was shown that, from this pilot model, it's possible to make some inferences about the intentions of people's daily lives.*

Resumo. *Ao realizar uma atividade, o usuário está sempre a realizando com alguma intenção. Os modelos atuais para reconhecimento de intenções geralmente aplicam-se em ambientes indoor e controlados, o que exige uma instrumentação prévia tanto do ambiente como das pessoas. Desta forma, este trabalho tem como objetivo apresentar um modelo para reconhecimento de intenções em ambientes fortemente outdoors apenas por informações das trajetórias e de outras informações contextuais que a partir dela poderão ser extraídas. O reconhecimento foi avaliado através de classificadores no qual foi mostrado que, a partir deste modelo piloto, é possível realizar algumas inferências acerca das intenções do cotidiano das pessoas.*

1. Introdução

Cotidianamente as pessoas estão realizando algum tipo de atividade. Mesmo fazendo parte ou não da rotina diária da pessoa, elas são sempre executadas segundo uma intenção do usuário. Por exemplo, o fato da pessoa caminhar até a cozinha e segurar um copo pode estar associada a algumas intenções como beber ou lavar. Analogamente, a saída do usuário do local de trabalho as 12h pode estar fortemente associada à intenção de se alimentar. Desta forma, as intenções podem ser definidas como um estado mental que representa um compromisso de realizar uma ação ou ações no futuro [Lee et al. 2015]. Uma vez que estas intenções sejam reconhecidas, novos tipos de serviços podem ser disponibilizados de modo a facilitar ou colaborar com o dia-a-dia do usuário.

O **reconhecimento de intenções** é o processo de tornar-se ciente das intenções de um agente de modo a identificar o objetivo geral das ações executadas [Heinze 2004]. Os modelos de reconhecimento de intenções buscam principalmente realizar esta tarefa para domínios específicos e ambientes *indoor* [Liu et al. 2014] devido a facilidade de instrumentação tanto das pessoas como dos ambientes. Como esta facilidade não

se reflete nos ambientes *outdoors*, outras fontes de informações precisam ser exploradas para que estas intenções possam ser reconhecidas. A trajetória t externa de um usuário pode ser representada por uma sequência espaço-temporal de pontos ($traj_i = \{(x_1, y_1, t_1), \dots, (x_t, y_t, t_t)\}$), onde x , y e t representam respectivamente a latitude, longitude e o instante que a informação foi obtida. Durante uma trajetória do usuário, a proximidade dele com alguns Pontos de Interesse (Point of Interest - POI) pode dar indícios das possíveis intenções pretendidas por ele, no entanto, é necessário ainda que outras informações como o horário e categoria do POI também sejam consideradas para que a intenção seja selecionada adequadamente.

Sendo assim, este trabalho tem como objetivo apresentar um modelo piloto e compacto para reconhecimento de intenção *outdoor* a partir de dados coletados pelo GPS e outras informações contextuais que possam ser extraídas a partir desta trajetória. Espera-se que seja possível reconhecer as intenções de movimentação dos usuários a partir deste modelo.

O trabalho está organizado da seguinte forma: na seção a seguir são apresentados os trabalhos relacionados ao assunto de reconhecimento de intenções e atividades *outdoor*; na seção 3 o modelo é descrito juntamente com os conceitos à ele relacionados; na seção 4 é apresentado como o experimento foi realizado desde o desenvolvimento do aplicativo até a criação da base de dados; na seção 5 analisaremos os resultados encontrados onde também algumas alternativas serão apresentadas; e, ao final, são apresentadas as conclusões do trabalho juntamente com alguns trabalhos futuros.

2. Trabalhos Relacionados

O reconhecimento de intenções tem sido utilizado em diversas áreas como robótica [Aarno and Kragic 2008], tecnologias assistivas [Shen et al. 2013] e segurança [Kelley et al. 2012]. As intenções variam conforme o domínio de aplicação e o tipo de informações coletadas. A seguir serão destacados alguns trabalhos referentes ao reconhecimento de intenções e sobre reconhecimento de atividades por trajetórias uma vez que pretendemos estender os modelos realizar o reconhecimento de intenções em ambientes *outdoor*.

No trabalho de Ge [Ge and Xu 2014] a rotina diária de uma pessoa foi utilizada para inferir 3 tipos de intenções domésticas (lendo livros, assistindo tv e fazendo café da manhã). Cada intenção foi modelada como uma sequência de atividades aliada a localização indoor (Markov Chains) onde foi necessário utilizar sensores anexados ao corpo e ao ambiente para realizar este monitoramento.

A utilização de *object affordances* é um recurso comumente utilizado nos modelos de reconhecimento uma vez que as possíveis ações de serem realizadas com objetos podem estar associadas à intenção do usuário. A proposta apresentada em [Yu et al. 2015] realiza o reconhecimento de intenções através da cooperação entre modelos estáticos (*object affordances*) e dinâmicos (movimento corporal). Estas informações são obtidas a partir do processamento de imagens e processadas numa rede neural de forma que fossem inferidas as intenções de "lendo livro", "derramando achocolatado", "bebendo", "comendo", "telefonando". No trabalho de Liu [Liu et al. 2014] as intenções foram modeladas como os próprios *affordances* de objetos. Para isso, uma rede bayesiana foi elaborada de modo a mesurar as correlações entre os *affordances* e informações contextuais para

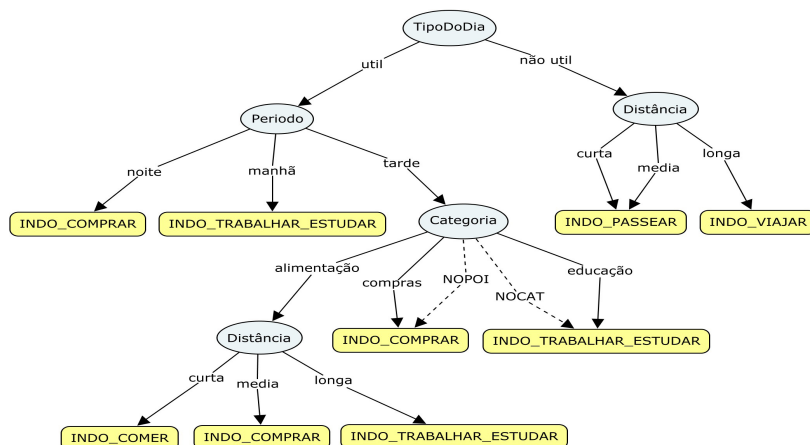


Figura 1. Modelo de reconhecimento de intenções outdoors.

que as intenções de "beber", "lavar", "transferir", "abrir" e "fechar" fossem inferidas.

No que tange ao reconhecimento de atividades por trajetórias, uma das principais informações consideradas pelos modelos são as proximidade com os POI e as características dos mesmos. No trabalho de Huang [Huang et al. 2010], diversos aspectos como tamanho, fama e categoria dos POI foram utilizados para determinar a atividade do usuário. Inclusive, dependendo dos horários do dia, cada categoria poderia influenciar mais ou menos na determinação das atividades de *Jantar*, *Compras*, *Entretenimento e Outros*. Em [Furletti et al. 2013], as distâncias e da densidade dos tipos de atividades são considerados para se realizar um cálculo das probabilidades da atividade realizada, onde nem sempre o POI mais próximo determinará o tipo de atividade. Os tipos de atividades (*Serviços*, *Alimentação*, *Compras Rotineiras*, *Compras*, *Educação e Lazer*) foram definidos segundo as categorias do Google Places e do OpenStreetMaps. Já em [Boukhechba et al. 2015], a descoberta de atividades baseou-se na exploração de *tags* do OpenStreetMaps. A partir do POI mais próximo, realiza-se uma consulta a base do OSM para se obter as tags referentes àquela localização e ao consultar a taxonomia proposta atribui-se a atividade. As atividades desta taxonomia foram: *Education*, *Sustenance*, *Transportation*, *Financial*, *Healthcare*, *Entertainment-Arts-Culture*.

3. Modelo proposto

O modelo proposto é um projeto piloto para reconhecimento de intenções (IR-Model) de pessoas a partir de trajetórias de ambientes *outdoor*. Neste modelo, qualquer tipo de informação pessoal não deveria ser considerada de modo que ele se torne abrangente e compatível com plataformas onde estas informações não estejam disponíveis (privacidade do usuário, contexto da aplicação, etc). Desta forma, apenas as informações contextuais como as *categorias dos POI*, *período do dia*, *tipo do dia* e *distância percorrida* foram as *features* utilizados para realizar o processo de reconhecimento. Sua modelagem iniciou-se por uma observação breve do comportamento de 4 voluntários (que não pertenciam ao conjunto dos experimentos) e sucessivos refinamentos foram conduzidos através do senso comum de especialistas. A Figura 1 apresenta uma visão geral deste modelo.

Como se pode observar, o reconhecimento das intenções inicia-se pelo tipo do dia, onde o dia *útil* refere-se aos dias da semana e *não útil* aos finais de semana e feriados.

Esta informação contextual distingue principalmente as atividades de rotina das atividades esporádicas e de lazer. Dependendo da distância já percorrida pelo usuário, as intenções reconhecidas pelos dias *não úteis* são as de *INDO PASSEAR* e *INDO VIAJAR*. A primeira foi sugerida para trajetórias de escopo menor e até feitas dentro das próprias viagens do usuário e a segunda geralmente para o traslado entre cidade/municípios. As distâncias foram discretizadas em **curta** para valores entre 0m e 299m, **média** para valores entre 300m e 999m, e **longa** para valores acima de 1Km.

As informações contextuais como período do dia, categoria dos POI e a própria distância percorrida serão necessários para reconhecer as intenções dos dias *úteis*. O período do dia pode assumir 3 tipos de valores: *manhã* (6h as 11h59), *tarde* (12h as 17h59) e *noite* (18h as 0h). As intenções *INDO COMPRAR* e *INDO TRABALHAR/ESTUDAR* serão reconhecidas respectivamente pelos períodos *noite* e *manhã*. O intuito delas é distinguir quando se trata de uma atividade momentânea ou que faz parte da rotina do usuário. No caso do período ser *tarde*, a variável Categoria dos POI é responsável por realizar o refinamento de diversas outras intenções. Neste modelo, consideramos 3 tipos de categorias: *Alimentação*, *Compras* e *Educação*. Foram consideradas também as possibilidades de não haver POIs próximos aos pontos p_i da trajetória do usuário (*NOPOI*) ou da categoria associada ao POI não pertecer à uma das que descrevemos (*NOCAT*).

No caso da categoria ser *Alimentação*, a distância é novamente requisitada para determinar as intenções de *INDO COMER*, *INDO COMPRAR* e *INDO TRABALHAR/ESTUDAR*. As categorias de *Compras*, *Educação*, *NOPOI* e *NOCAT*, servirão para reconhecer as intenções de *INDO COMPRAR*, *INDO TRABALHAR/ESTUDAR*, *INDO COMPRAR* e *INDO TRABALHAR/ESTUDAR* respectivamente. Analogamente aos modelos de reconhecimento *indoor*, estas intenções podem então serem consideradas como *local affordances* já que eles representam os tipos de ações a serem feitas pelo usuário nestes ambientes.

Conforme será apresentado posteriormente, este modelo de reconhecimento de intenções (IR-Model) foi validado com dados de trajetórias reais. Além disso, também o comparamos com outros algoritmos de classificação comumente empregados para classificações sobre o comportamento dos usuários por meio de *10-fold cross-validation*.

4. Experimentos

Para realização dos experimentos um aplicativo de smartphone foi desenvolvido pelos autores para realizar a aquisição de trajetórias reais de pessoas além de permitir que os próprios usuários rotulassem suas atividades de maneira livre e espontânea (sem qualquer tipo de taxonomia previamente definida). O aplicativo (figura 2) foi desenvolvido na plataforma Android¹ e coletava a localização a cada 3 minutos, no entanto, a rotulação das atividades poderia ser feita a qualquer instante. O aplicativo era executado como serviço (*background*) e não interferia nas demais atividades do aparelho. Caso o usuário não atualizasse as informações dentro de um intervalo de 30 minutos, o aplicativo enviava uma notificação para deixá-lo ciente desta situação.

Participaram do experimento um total de 10 voluntários com idades entre 25 e 40 anos, de ambos os sexos, durante uma semana. Dos 10 voluntários, selecionamos 6

¹<https://developer.android.com/index.html>

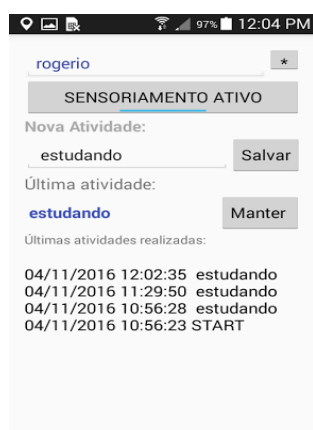


Figura 2. Aplicativo de coleta de dados.

Tabela 1. Classificação das subcategorias dos POI.

Categorias	Subcategorias
Alimentação	bakery, bar, cafe, food, restaurant
Compras	book_store, clothing_store, convenience_store, department_store, electronics_store, furniture_store, grocery_or_supermarket, hardware_store, home_goods_store, jewelry_store, pet_store, pharmacy, shoe_store, shopping_mall, store, travel_agency
Educação	library, school, university

voluntários que completaram um mínimo de 10 horas de anotações diárias de pelo menos 1 dia. Os dados brutos coletados por este aplicativo consistia na *data, hora, latitude, longitude e atividade rotulada*.

Uma fase de pré-processamento manual foi conduzida de modo a retirar alguns dados ruidosos como os pontos da trajetória onde as coordenadas de latitude e longitude não foram capturadas, e também para identificar e clusterizar os pontos onde o usuário permaneceu sem movimentação (stop). Em seguida, um processo de enriquecimento semântico [Parent et al. 2013] foi conduzido sobre estes registros onde, para cada p_i da trajetória, foram adicionadas cada uma das variáveis do modelo anteriormente descrito. Para as informações referentes às distâncias e categorias dos POI foi utilizada a API do Google Places². Um raio de 75m foi estabelecido para identificação dos POI mais próximos tendo as subcategorias do Google Places classificadas segundo apresentado na tabela 1.

Aplicamos o modelo proposto somente sobre os registros de movimentação do usuário pois consideramos que nos instantes de deslocamento a pessoa ainda está tentando atingir um objetivo. Além disso, estas condições também tornam os resultados consonantes com os tipos de intenções anteriormente modeladas (ex: indo comer, indo trabalhar, etc). De um total de 1329 pontos de movimentação na trajetória, foram utilizados 552 registros onde ficou explícita a rotulação do usuário em relação a atividade que estaria sendo realizada. Os algoritmos de classificação foram selecionados considerando a estrutura - hierárquica - do modelo e também os que comumente são utilizados na literatura para atividades e intenções *indoor* [Liu et al. 2014] [Kim et al. 2014]. A distribuição

²<https://developers.google.com/places/>




Figura 3. Intenções (A-Indo Comer, B-Indo Trabalhar/Estudar, C-Indo Comprar, D-Indo Passear, E-Indo Viajar).

Data	HoraAdquiridê	Lng	Lat	AtividadeRotulada	TipoDia	Periodo	Distancia	Categoria
04/11/16	14:26:04	-41.31965504	-21.75658292	A caminho do trabalho	util	tarde	curta	ALIMENTACAO
08/11/16	07:36:35	-41.32853356	-21.75179533	indo para aula UFF	util	manha	curta	EDUCACAO
10/11/16	08:54:36	-41.31887807	-21.7573265	indo indo aplicar prova	util	manha	longa	ALIMENTACAO
12/11/16	18:31:19	-43.2207934	-22.9099895	indo para o Rio	naoutil	noite	longa	ALIMENTACAO
15/11/16	09:34:50	-43.25577853	-22.91676047	Saindo para o AquaRio	naoutil	manha	curta	ALIMENTACAO
04/11/16	14:16:28	-41.32858814	-21.75196391	A caminho do trabalho	util	tarde	curta	COMPRAS

Figura 4. Exemplo de registros da trajetória com atividades rotuladas.

das intenções rotuladas pelos usuários está apresentada na figura 3, e alguns exemplos não consecutivos destes dados estão exibidos na Figura 4.

5. Análise dos resultados

A figura 5 apresenta o resultado do reconhecimento das intenções pelo modelo proposto. No geral, podemos ver que o modelo de reconhecimento de intenção proposto (IR-Model) obteve um desempenho superior às demais técnicas. Apesar do resultado estar ligeiramente acima dos 55%, isto mostra que a partir deste modelo piloto já é possível reconhecer as intenções sem qualquer outro tipo de informação sobre o perfil da pessoa. Além disso, como será mostrado mais adiante, alguns resultados individuais passaram dos 68% de acurácia. Num cenário de mundo aberto onde as pessoas podem realizar qualquer tipo de atividade a qualquer instante do dia, este reconhecimento já é um bom ponto de partida ao discernir as possíveis intenções do usuário.

Quanto as intenções, observamos que o modelo funcionou de forma satisfatória para *INDO TRABALHAR/ESTUDAR*. O resultado não foi superior pois algumas intenções foram classificadas equivocadamente como *INDO COMPRAR* (e vice-versa) devido ao fato de que durante o trânsito para seus locais de trabalho/estudo o dispositivo não identificou os POI mais próximos (NOPOI) ou passaram por regiões centrais onde a densidade de lojas e comércio é maior. Como alternativa a nível de aplicação para escolha da categoria

IR-Model					RandomForest (RF)					BayesNet (BN)					← classified as:	
a	b	c	d	e	a	b	c	d	e	a	b	c	d	e		F-Measure
1	14	27	18	11	16	12	23	8	12	14	9	23	14	11	0.269	a = INDO COMER
5	125	35	4	0	1	109	55	2	2	0	117	48	4	0	0.650	b = INDO TRABALHAR ESTUDAR
2	64	76	11	3	11	68	67	8	2	8	65	70	10	3	0.464	c = INDO COMPRAR
0	0	6	44	20	10	0	13	30	17	10	0	5	35	20	0.464	d = INDO PASSEAR
0	0	0	18	68	4	0	0	14	68	1	0	0	18	67	0.717	e = INDO VIAJAR
Accuracy: 56.78%					Accuracy: 52.53%					Accuracy: 54.89%						

Figura 5. Resultados dos reconhecimento das intenções

IR: user1						IR: user2						IR: user3						← classified as: a = INDO COMER b = INDO TRABALHAR ESTUDAR c = INDO COMPRAR d = INDO PASSEAR e = INDO VIAJAR
a	b	c	d	e	F-Measure	a	b	c	d	e	F-Measure	a	b	c	d	e	F-Measure	
0	0	2	2	2	0.000	0	4	0	5	1	0.000	0	3	1	7	6	0.000	
2	30	10	0	0	0.817	0	32	0	4	0	0.821	3	12	17	0	0	0.444	
0	1	12	1	1	0.615	0	6	4	0	0	0.571	0	7	2	2	1	0.125	
0	0	0	3	7	0.261	0	0	0	9	2	0.621	0	0	0	12	3	0.667	
0	0	0	7	33	0.795	0	0	0	0	0	0.000	0	0	0	0	0	0.000	
Accuracy: 68.75%						Accuracy: 67.16%						Accuracy: 34.21%						

IR: user4						RF: user5						IR: user6						← classified as: a = INDO COMER b = INDO TRABALHAR ESTUDAR c = INDO COMPRAR d = INDO PASSEAR e = INDO VIAJAR
a	b	c	d	e	F-Measure	a	b	c	d	e	F-Measure	a	b	c	d	e	F-Measure	
0	0	5	0	0	0.000	0	0	6	0	0	0.000	1	7	13	4	2	0.071	
0	11	2	0	0	0.917	0	8	0	0	0	0.516	0	32	6	0	0	0.571	
0	0	0	0	0	0.000	2	15	14	0	0	0.549	0	35	44	8	1	0.561	
0	0	0	0	0	0.000	0	0	0	7	4	0.483	0	0	6	13	4	0.542	
0	0	0	0	0	0.000	0	0	0	11	35	0.824	0	0	0	0	0	0.000	
Accuracy: 61.11%						Accuracy: 62.74%						Accuracy: 51.14%						

Figura 6. Resultados individuais do processo de reconhecimento.

ria do POI mais próximo, pode-se utilizar o trabalho de [Furletti et al. 2013] que seleciona o POI segundo a distância e a densidade de categorias numa área.

Se por um lado no IR-Model a intenção de *INDO COMER* obteve um desempenho ruim, tanto na RandomForest(RF) como na BayesNetwork(BN) esta intenção obteve sucesso em algumas de suas classificações. Ao analisarmos com mais detalhes os comportamentos dos usuários, apesar de existirem muitos registros associados à categoria de Alimentação do POI, observamos que muito dos usuários também realizam este tipo de atividade dentro dos seus domicílios e que não é possível de se obter diretamente pelas API dos sistemas georeferenciados. Como alternativa, poderia se levar em consideração algumas informações sobre as regiões [Furtado et al. 2013] ou predição de locais [Preoiuc-Pietro and Cohn 2013] para atribuição da categoria de alimentação.

As intenções de *INDO VIAJAR* e *INDO PASSEAR* tiveram um desempenho bem interessante em todos os mecanismos de reconhecimento. Isto pode ser extremamente valioso para os tipos de aplicações que buscam identificar turistas ou moradores da região. No nosso caso, conseguimos reconhecê-las independente do perfil ou qualquer outra informação particular das pessoas [Abbasi et al. 2015]. Ao verificarmos a base de teste dos experimentos observamos que um total de 5 cidades distintas foram visitadas, além de haver passeios explícitos dos próprios usuários dentro das cidades (ex: *userC* rotulou: ”<’Dando uma voltinha com amor - 16:11:33 - 15/11/16>’”).

A figura 6 apresenta o resultado do processo de reconhecimento de forma individual. Podemos observar que alguns resultados foram bem superiores do que o reconhecimento geral (ex: 68.75% e 67.16%). Por outro lado, o usuário 3 obteve um resultado bastante insatisfatório. Ao analisarmos os registros desta pessoa, verificamos que tanto o seu lugar de estudo como de trabalho acontecem sem horários definidos e próximas a um grande centro comercial onde existem muitos restaurantes na proximidade. Neste caso, podemos considerar este usuário como um *outlier*.

6. Conclusão

Este trabalho apresentou uma proposta de modelo para reconhecimento de intenções para ambientes *outdoors* como alternativa aos modelos atuais que são dedicados a domínios específicos e ambientes *indoor*. Durante as análises mostramos que é possível reconhecer

algumas intenções com uma boa acurácia. Além disso, também foi mostrado algumas alternativas que podem ser feitas a nível de aplicação para que os resultados dos experimentos possam ser incrementados.

Como trabalhos futuros, o rotulamento das atividades ocorrerá por meio de um conjunto pré-definido configurado no aplicativo e será adicionado notificações com base na distância a fim de evitar o esquecimento ou rotulações tardia. Novas coletas de dados também serão conduzidas a fim de generalizar melhor o comportamento dos usuários e também englobar uma diversidade maior de intenções.

No modelo serão incluídos os outros tipos de categorias como Entretenimento, Saúde e Transporte e conseqüentemente novas intenções segundo os *local affordances*. A inclusão de novos parâmetros como *tempo decorrido* desde a última atividade e *distância diária* que mede a trajetória desde a primeira atividade até o instante atual também poderão colaborar para uma melhoria dos resultados (ex: *INDO COMER*).

Após finalizar alguns procedimentos referente à privacidade das informações, esta base de dados será disponibilizada para uso público. Até o momento, não havia sido identificada uma base de dados pública, de pedestres, no qual as informações fossem rotuladas em tempo real pelos próprios usuários.

Referências

- Aarno, D. and Kragic, D. (2008). Motion intention recognition in robot assisted applications. *Robotics and Autonomous Systems*, 56(8):692–705.
- Abbasi, A., Rashidi, T. H., Maghrebi, M., and Waller, S. T. (2015). Utilising location based social media in travel survey methods: bringing twitter data into the play. In *Proceedings of the 8th ACM SIGSPATIAL International Workshop on Location-Based Social Networks*, page 1. ACM.
- Boukhechba, M., Bouzouane, A., Bouchard, B., Gouin-Vallerand, C., and Giroux, S. (2015). Online recognition of people’s activities from raw gps data: semantic trajectory data analysis. In *Proceedings of the 8th ACM International Conference on Pervasive Technologies Related to Assistive Environments*, page 40. ACM.
- Furletti, B., Cintia, P., Renso, C., and Spinsanti, L. (2013). Inferring human activities from gps tracks. In *Proceedings of the 2nd ACM SIGKDD International Workshop on Urban Computing*, page 5. ACM.
- Furtado, A. S., Fileto, R., and Renso, C. (2013). Assessing the attractiveness of places with movement data. *Journal of Information and Data Management*, 4(2):124.
- Ge, Y. and Xu, B. (2014). Elderly personal intention recognition by activity and context recognition in smart home. In *2014 9th International Conference on Computer Science & Education*.
- Heinze, C. (2004). *Modelling intention recognition for intelligent agent systems*. PhD thesis, The University of Melbourne, Australia.
- Huang, L., Li, Q., and Yue, Y. (2010). Activity identification from gps trajectories using spatial temporal pois’ attractiveness. In *Proceedings of the 2nd ACM SIGSPATIAL International Workshop on Location Based Social Networks*, pages 27–30. ACM.

- Kelley, R., Tavakkoli, A., King, C., Ambardekar, A., Nicolescu, M., and Nicolescu, M. (2012). Context-based bayesian intent recognition. *IEEE Transactions on Autonomous Mental Development*, 4(3):215–225.
- Kim, Y., Pereira, F. C., Zhao, F., Ghorpade, A., Zegras, P. C., and Ben-Akiva, M. (2014). Activity recognition for a smartphone based travel survey based on cross-user history data. In *Pattern Recognition (ICPR), 2014 22nd International Conference on*, pages 432–437. IEEE.
- Lee, D.-G., Lee, K.-H., and Lee, S.-Y. (2015). Implicit shopping intention recognition with eye tracking data and response time. In *Proceedings of the 3rd International Conference on Human-Agent Interaction*, pages 295–298. ACM.
- Liu, R., Zhang, X., and Li, S. (2014). Use context to understand user’s implicit intentions in activities of daily living. In *2014 IEEE International Conference on Mechatronics and Automation*, pages 1214–1219. IEEE.
- Parent, C., Spaccapietra, S., Renso, C., Andrienko, G., Andrienko, N., Bogorny, V., Damiani, M. L., Gkoulalas-Divanis, A., Macedo, J., Pelekis, N., et al. (2013). Semantic trajectories modeling and analysis. *ACM Computing Surveys (CSUR)*, 45(4):42.
- Preoțiuc-Pietro, D. and Cohn, T. (2013). Mining user behaviours: a study of check-in patterns in location based social networks. In *Proceedings of the 5th Annual ACM Web Science Conference*, pages 306–315. ACM.
- Shen, B., Li, J., Bai, F., and Chew, C.-M. (2013). Motion intent recognition for control of a lower extremity assistive device (lead). In *2013 IEEE International Conference on Mechatronics and Automation*, pages 926–931. IEEE.
- Yu, Z., Kim, S., Mallipeddi, R., and Lee, M. (2015). Human intention understanding based on object affordance and action classification. In *2015 International Joint Conference on Neural Networks (IJCNN)*, pages 1–6. IEEE.