

Modelo de Reconhecimento de Atividades Baseados em dados de GPS e contexto de trajetórias

Igor da Penha Natal¹

¹Instituto de Computação – Universidade Federal Fluminense (UFF)

Niterói – RJ – Brasil

inatal@ic.uff.br

Abstract. *The problem of activity recognition has been explored in many ways by a range of researchers today. The use of sensors of the most diverse types has been fundamental so that this problem can be solved improving an effectiveness of the recognition. Smartphones offer a range of sensors (GPS, Accelerometer, Gyro, etc.) that can be used to provide data for this type of problem. The work proposed here aims to bring a new model of recognition of activities based on data captured by GPS. The model is based on information characterized as speed, distance between points and duration of the trajectory. The model aims to recognize 7 types of activities: Car dislocation, Walking and Bus, Studying / Working, Eating, Leisure and Sleeping. The model was tested and had approximately 78 % accuracy.*

Resumo. *O problema de reconhecimento de atividades tem sido bastante explorado de diversas formas por uma gama de pesquisadores da atualidade. O uso de sensores dos mais diversos tipos tem sido fundamental para que este problema possa ser resolvido melhorando a efetividade do reconhecimento. Os Smartphones oferecem uma gama de sensores (GPS, Acelerômetro, Giroscópio, etc) que podem ser utilizados para fornecer dados para este tipo de problema. O trabalho aqui proposto, visa trazer um novo modelo de reconhecimento de atividades baseados em dados capturados pelo GPS. O modelo se baseia em informações caracterizadas pelas trajetórias dos usuários como: velocidade, distância entre os pontos e duração da trajetória. O modelo visa reconhecer 7 tipos de atividades, que são: Deslocamento de carro, Deslocamento andando, Deslocamento de ônibus, Estudar/trabalhar, Comer, Lazer e dormir. O modelo foi testado e teve aproximadamente 78% de acerto*

1. Introdução

Reconhecimento de atividades tem sido um tema bastante explorado no campo da pesquisa de computação ubíqua, juntamente com a popularização da utilização de sensores acoplados aos *Smartphones* (acelerômetro, giroscópio, GPS, etc). Diversos estudos são voltados para reconhecer atividades com dados destes sensores ([Difrancesco et al. 2016], [Hung et al. 2014] e [Huang et al. 2013]) e outros trabalhos procuram entender os dados produzidos por usuários de *Smartphones* durante o uso contínuo do dispositivo ([Zhou et al. 2016], [Shafique and Hato 2016] e [Shin et al. 2015]).

A possibilidade de ter de uma pessoa através de sensores não invasivos, se tornam cada vez mais interessantes, visando que as pessoas sentem um certo receio de ter sensores

ligados ao seu corpo ou de compartilhar suas informações diretamente. O uso de dados de sensores dos *Smartphones* tem sido aplicado aos mais diversos tipos de aplicações: monitoramento, saúde, reconhecimento de atividade, etc [Huang et al. 2013]).

O problema de reconhecimento de atividades está sendo bastante explorado pela literatura e um dos principais desafios é saber de quais sensores e quais dados devem ser coletados para refinar o reconhecimento automático de atividades. Os sensores mais comuns são GPS e acelerômetro [Hung et al. 2014].

Visando o problema de reconhecimento de atividades, o trabalho aqui proposto busca utilizar apenas dados advindos dos GPS, enriquecidos com a inferência de velocidade, distância entre pontos, duração de trajetórias para reconhecer atividades em qualquer tipo de ambiente. O modelo apresentado é um modelo piloto para reconhecimento de atividades através de dados de GPS e contexto de trajetória.

Na Seção 2, são apresentados os trabalhos relacionados ao tema de reconhecimento de atividades e entendimento de dados. Na Seção 3, é descrito o modelo formulado e utilizado no trabalho. Na Seção 4, é apresentado como o experimento foi conduzido, descrevendo a coleta de dados e a base de dados utilizada. Na seção 5, é apresentada uma discussão sobre os resultados obtidos. E, por fim, na Seção 6, são apresentadas as conclusões do trabalho e os trabalhos futuros.

2. Trabalhos Relacionados

Os trabalhos apresentados nesta seção são referentes ao entendimento dos dados coletados dos diversos sensores dos *Smartphones* (GPS, acelerômetro, giroscópio, etc) e também são apresentados trabalhos que usam estes dados para o reconhecimento de atividades.

O trabalho desenvolvido por [Zhou et al. 2016] tem como objetivo analisar e entender dados de acelerômetro e GPS para detectar como o usuário está se locomovendo. O modelo RF (*Random Forest*) foi utilizado como base do trabalho para classificar automaticamente os dados em diferentes modos de locomoção. A avaliação foi feita com dados de 12 pessoas, coletados durante 6 dias. Os tipos de locomoção reconhecidas são: andando, correndo, andando de bicicleta, em um veículo e parado. Os resultados apresentados mostraram um bom desempenho tanto para ambientes *indoor* e *outdoor*.

O trabalho de [Shafique and Hato 2016] usa os dados coletados dos sensores do *Smartphone* para extrair características para a classificação do tipo de transporte que o usuário se encontra. Os autores fizeram o experimento monitorando 15 pessoas durante um mês na cidade Kobe (Japão). O algoritmo utilizado foi o (*Random Forest*) e as classes reconhecidas são: andando, bicicleta, carro, ônibus, trem e metrô. O trabalho apresentou uma metodologia para para coleta de dados de acelerômetro e GPS levando em consideração diferentes frequências de coleta de dados e também medindo o custo computacional do algoritmo.

O foco do trabalho [Shin et al. 2015]) é detectar o modo de transporte de pessoas através do uso do acelerômetro. Os autores utilizam os conceitos de segmentação de trajetória e da separação entre segmentos de meios de transportes diferentes. Os dados foram coletados em Zurique (Suíça), com 395 amostras de 30 usuários. O trabalho focou na detecção dos seguintes meios de transporte: Carro, trem e ônibus. Os autores acreditam que a incorporação de informações de tipo de local combinadas com o trabalho

deles, podem impactar em muitos fenômenos impulsionados pela mobilidade humana e aumentar a consciência das pessoas em relação a comportamento, planejamento urbano e modelagem baseada em agentes.

O trabalho de [Difrancesco et al. 2016] utiliza dados do GPS e POIs (*Points of Interest - Pontos de Interesse*) para reconhecer atividades de pacientes com esquizofrenia em ambiente *outdoor*, os pacientes possuem um diário para registrar suas atividades, dois métodos foram implementados para o reconhecimento de atividades, um baseado no tempo (5, 6, 8 e 10 minutos) e outro baseado na densidade (raio de 50 metros), por fim utilizaram enriquecimento semântico para classificar os tipos de lugares e as atividades associadas a eles. As atividades reconhecidas são vinculadas a áreas de funcionamento social (atividades sociais, atividades recreativas, esportes, etc), sendo que cada área tem atividades específicas (academia, cinema, teatro, trabalhando, etc).

O trabalho de [Hung et al. 2014] utiliza acelerômetro e giroscópio de *Smartphones* para reconhecer atividades físicas (sentado, andando, deitado, andando, subindo escadas e descendo escadas). Os autores extraíram *features* dos dois sensores e perceberam que o giroscópio oferece dados mais satisfatórios nas atividades dinâmicas (andando, subindo escadas e descendo escadas). Foram usados três algoritmos para classificação das atividades, são eles, *Support Vector Machine* (SVM), J48 e Regressão Logística).

O trabalho de [Huang et al. 2013]) trata de reconhecimento de atividades através de dados do GPS, considerando a trajetória do usuário. O estudo se preocupou em tratar com melhor acurácia atividades menos frequentes. As atividades que podem ser reconhecidas são: Em casa, no trabalho, visitando amigos, shopping, jantar fora, ir ao teatro, buscar alguma coisa ou alguém e entretenimento. A abordagem apresentada pelos autores baseia-se em uma função de custo baseado no tempo para melhorar a precisão das atividades com poucos registros. A função foi implementada em cima de um HMM (*Hidden Markov Model*).

O trabalho de [Boukhechba et al. 2016] desenvolveu uma abordagem para otimizar o consumo de energia de *Smartphones* no reconhecimento de atividades *outdoor*. Os autores apresentam um modelo online, que associa as atividades humanas significativas usando um algoritmo que agrupa incrementalmente os movimentos do usuário em diferentes tipos de atividades. Para otimizar o consumo da bateria, o algoritmo se comporta de forma variável com base no comportamento do usuário e a bateria restante. O método para reconhecimento de atividades usa dados do GPS e faz o reconhecimento de POIs em tempo real. A abordagem foi testada em duas bases de dados e tiveram resultados eficazes para inferir a atividade sem esgotar os recursos do telefone.

O principal diferencial do modelo aqui proposto é tentar reconhecer as atividades das pessoas independente do ambiente (*indoor* ou *outdoor*) com dados advindos do GPS e enriquecidos através dos contextos de período do dia, tipo do dia, velocidade média do trajeto, duração do trajeto e distância relativa ao ponto anterior, o modelo é descrito na próxima seção.

3. Modelo

O modelo proposto é um estudo piloto que busca reconhecer atividades através de segmentos de trajetórias coletadas do GPS, unindo informações relacionadas a velocidade

média dos trajetos, duração do segmento, distância para o ponto anterior, período do dia e tipo do dia, independente da atividade ser em um ambiente *indoor* ou *outdoor*.

As variáveis usadas serão descritas a seguir: *Vel_Media_Traj* é a velocidade média de toda a trajetória da pessoa em Km/H, *Dist_Ponto_Ant* é a distância do ponto atual dentro da trajetória para o ponto anterior em metros, *Dur_Traj* é a duração total da trajetória em minutos, a *Data* é o dia da semana e *HoraIni* e *HoraFim* é a hora do dia que iniciou/terminou a atividade.

O modelo baseia-se em regras seguindo 6 variáveis para chegar até o reconhecimento da atividade. Todas as variáveis foram discretizadas para que fosse possível criar regras mais gerais em cima delas. A forma de discretização com os possíveis valores das variáveis são descritas na tabela 1.

Table 1. Variáveis, Faixa de valores e Discretização.

Variáveis	Faixa de valores	Discretização
Vel_Media_Traj (x)	$x = 0$ (Km/H)	NULA
	$0 \leq x < 10$ (Km/H)	Baixa
	$10 \leq x < 40$ (Km/H)	Media
	$x \geq 40$ (Km/H)	Alta
Dist_Ponto_Ant (x)	$x < 400$ (m)	Pequena
	$x \geq 400$ (m)	Grande
Dur_Traj (x)	$x < 30$ (min)	Curta
	$x \geq 30$ (min)	Longa
Data	Segunda-Feira	Util
	Terça-Feira	Util
	Quarta-Feira	Util
	Quinta-Feira	Util
	Sexta-Feira	Util
	Sábado	Nao_Util
	Domingo	Nao_Util
	Feriado	Nao_Util
HoraIni/HoraFim	00:00 até às 05:29 (horas)	Madrugada
	05:30 até às 11:59 (horas)	Manha
	12:00 até às 17:59 (horas)	Tarde
	18:00 até às 23:59 (horas)	Noite

O modelo foi gerado para reconhecer 7 tipos de atividades que foram separadas em 2 grupos, atividades de deslocamento (Carro, ônibus e andando) e atividades estáticas (Comer, Lazer, Trabalhar/Estudar e Dormir), destacadas na tabela 2.

Table 2. Grupos de Atividades.

Atividades de Deslocamento	Atividades Estáticas
Deslocamento Andando	Comer
Deslocamento de Carro	Lazer
Deslocamento de Ônibus	Trabalhar/Estudar
	Dormir

A árvore de condições do modelo pode ser vista na Figura 1, onde são apresentados os atributos e seus possíveis valores determinando qual a atividade está sendo feita no

nó folha. O modelo tem regras que podem utilizar apenas um atributo para determinar a atividade (Se Vel_Media_Traj for igual a Alta, a atividade é DESL_CARRO), ou também utilizando quatro atributos (Se Vel_Media_Traj for igual a NULA e Dur_Traj for igual Longa e Data for igual a Util e HoraIni for igual a Madrugada, a atividade é DORMIR).

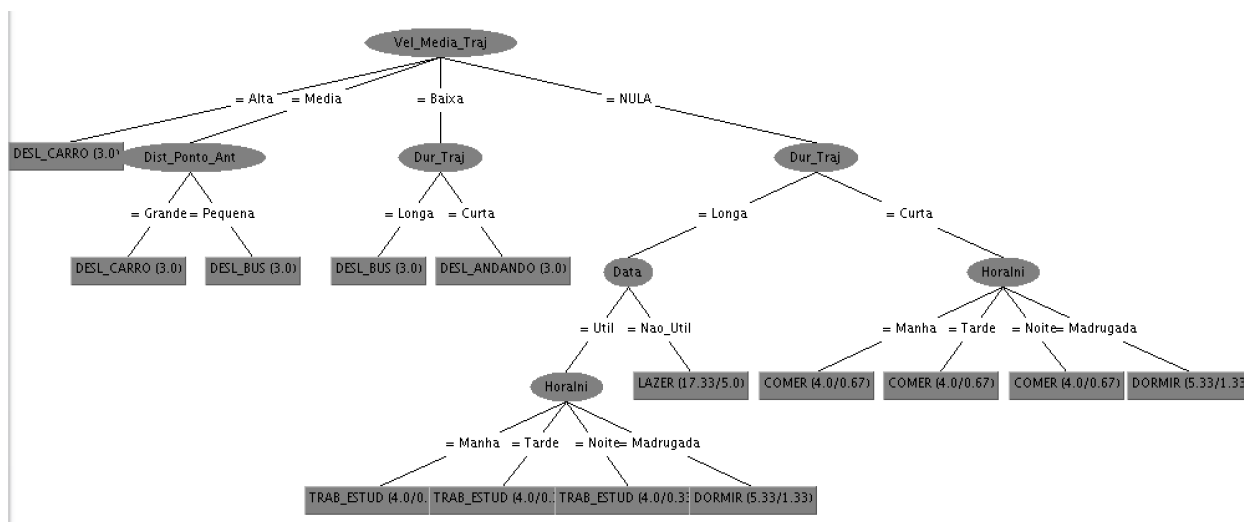


Figure 1. Modelo Proposto.

4. Experimento

O primeiro passo para a realização do experimento foi coletar os dados do GPS, estes dados foram coletados através de um aplicativo desenvolvido pelos autores para *Smart-phones* com a plataforma Android, a plataforma foi escolhida com base na análise do perfil dos voluntários. O aplicativo coletava os dados do GPS (Longitude e Latitude), a data e a hora do sistema, um identificador do usuário e a atividade realizada (caso o usuário preenchesse o rótulo), a interface do aplicativo é apresentada na Figura 2, onde na parte superior tinha a identificação do usuário, embaixo o botão para ativar o sensoriamento, embaixo um rótulo para o usuário registrar a atividade e um botão para salvar, um botão para manter, caso após 30 minutos o usuário continuasse na mesma atividade e na parte inferior um feedback dos registros do usuário. O aplicativo captava os dados a cada 3 minutos, sendo que o usuário a qualquer momento poderia rotular a atividade que estava fazendo.

O experimento piloto foi conduzido com a participação de 10 voluntários, com idades entre 25 e 40 anos, de ambos os sexos, durante 7 dias. Os dados utilizados foram de 5 usuários, já que por problemas tecnológicos os dados dos outros 5 vieram sem informações suficientes. Os dados sofreram um pré-processamento, no qual houve um enriquecimento para a construção de uma base de dados robusta, inferindo as distâncias, velocidade, duração, dia e período da atividade, como podem ser vistos na tabela 3. O experimento ficou com 351 registros e os testes foram feitos utilizando o software WEKA.

O modelo foi testado usando a base de dados completa e comparado em relação ao algoritmo Random Florest (RF), que foi o algoritmo mais utilizado pelos trabalhos correlatos apresentados na seção anterior, na próxima seção são mostrados os resultados e uma breve análise entre eles.



Figure 2. Interface do aplicativo de coleta de dados.

Table 3. Dados Tratados.

Data	HoraIni	HoraFim	Dist_Ponto_Ant	Dur_Traj	Vel_Media_Traj	ATIVIDADE
Util	Noite	Noite	Pequena	Curta	Media	DESL_CARR O
Util	Manha	Manha	Pequena	Curta	Media	DESL_BUS
Util	Manha	Manha	Pequena	Curta	Media	DESL_BUS

5. Resultados

Os resultados do trabalho são em função do modelo proposto em relação ao algoritmo RF (Random Forrest). A Figura 3 mostra os resultados e a matriz de confusão do modelo proposto em cima da base de teste. Onde foi possível obter aproximadamente 80% de acerto.

O algoritmo RF foi utilizado com *Cross-Validation de 10 folds* e obteve os resultados da Figura 4, obtendo 90% de acerto .

Em comparação com os resultados da RF, o modelo apresentado teve 10% a menos de acertos, o que totaliza 37 acertos a menos. Nas atividades de deslocamento os acertos foram de 206 acertos e 29 erros com o modelo e no RF foram de 231 acertos e 4 erros e nas atividades estáticas foi de 74 acertos e 42 erros com o modelo e no RF 86 acertos e 30 erros. O modelo proposto conseguiu se aproximar do algoritmos já consolidado e com muitas referências RF na detecção de atividades estáticas, mostrando assim, que propondo melhorias para ele, poderá se equiparar a algoritmos já consolidados (RF, SVM e J48).

6. Conclusão e Trabalhos Futuros

O trabalho propôs um novo modelo de reconhecimento de atividade baseado em informações do GPS e com uso do contexto do período do dia, data, velocidade, duração e distância entre pontos em um trajetória. Para um estudo inicial os resultados foram razoáveis, pois houve um número de acerto próximo ao do RF.

Como trabalhos futuros, os autores visam explorar outra gama de sensores para a

```

  a  b  c  d  e  f  g  <-- classified as
127 18  0  0  0  0  0 | a = DESL_CARRO
  2 48  0  0  0  0  0 | b = DESL_BUS
  0  9 31  0  0  0  0 | c = DESL_ANDANDO
  0  0  0  0  1  0  0 | d = DORMIR
  0  0  0  0 10  8  0 | e = LAZER
  0  0  0  0  8 43  7 | f = TRAB_ESTUD
  0  0  0  0  9  9 21 | g = COMER

=== Summary ===

Correctly Classified Instances      280      79.7721 %
Incorrectly Classified Instances    71      20.2279 %
Kappa statistic                    0.7361
Mean absolute error                 0.0642
Root mean squared error             0.2284
Relative absolute error             25.5257 %
Root relative squared error         62.7657 %
Total Number of Instances          351

```

Figure 3. Resultados Modelo.

```

=== Confusion Matrix ===

  a  b  c  d  e  f  g  <-- classified as
145  0  0  0  0  0  0 | a = DESL_CARRO
  4 46  0  0  0  0  0 | b = DESL_BUS
  0  0 40  0  0  0  0 | c = DESL_ANDANDO
  0  0  0  0  0  1  0 | d = DORMIR
  0  0  0  0  8  3  7 | e = LAZER
  0  0  0  0  0 51  7 | f = TRAB_ESTUD
  0  0  0  0  5  7 27 | g = COMER

=== Summary ===

Correctly Classified Instances      317      90.3134 %
Incorrectly Classified Instances    34      9.6866 %
Kappa statistic                    0.8707
Mean absolute error                 0.0268
Root mean squared error             0.1203
Relative absolute error             12.3929 %
Root relative squared error         36.66 %
Total Number of Instances          351

```

Figure 4. Resultados Random Forest.

coleta de dados, de modo a refinar o reconhecimento das atividades e também explorar novas variáveis, para que seja formulado o modelo mais robusto e com melhor precisão. Outra proposta é aumentar a cobertura de atividades.

References

- Boukhechba, M., Bouzouane, A., Bouchard, B., Guin-Vallerand, C., and Giroux, S. (2016). Energy optimization for outdoor activity recognition. *Journal of Sensors*, 2016.
- Difrancesco, S., Fraccaro, P., van der Veer, S. N., Alshoumr, B., Ainsworth, J., Bellazzi, R., and Peek, N. (2016). Out-of-home activity recognition from gps data in schizophrenic patients. pages 324–328.
- Huang, W., Li, M., Hu, W., Song, G., Xing, X., and Xie, K. (2013). Cost sensitive gps-based activity recognition. In *Fuzzy Systems and Knowledge Discovery (FSKD), 2013 10th International Conference on*, pages 962–966. IEEE.

- Hung, W.-C., Shen, F., Wu, Y.-L., Hor, M.-K., and Tang, C.-Y. (2014). Activity recognition with sensors on mobile devices. In *2014 International Conference on Machine Learning and Cybernetics*, volume 2, pages 449–454. IEEE.
- Shafique, M. A. and Hato, E. (2016). Travel mode detection with varying smartphone data collection frequencies. *Sensors*, 16(5):716.
- Shin, D., Aliaga, D., Tunçer, B., Arisona, S. M., Kim, S., Zünd, D., and Schmitt, G. (2015). Urban sensing: Using smartphones for transportation mode classification. *Computers, Environment and Urban Systems*, 53:76–86.
- Zhou, X., Yu, W., and Sullivan, W. C. (2016). Making pervasive sensing possible: Effective travel mode sensing based on smartphones. *Computers, Environment and Urban Systems*, 58:52–59.