

2 Embasamento Teórico

Nesta seção, apresentamos uma breve discussão do estado da arte em sistemas de inferência de atividade de usuários. Os trabalhos encontrados foram analisados e classificados de acordo com os seguintes critérios: natureza do projeto, sensores adotados e processo de aprendizagem.

Com o objetivo de encontrar os principais conceitos e características de sistemas de inferência de atividades de usuários, projetos de natureza distinta foram adicionados a nossa pesquisa. Abaixo, a tabela 1 apresenta os projetos encontrados na área de inferência de atividade de usuário e que serão analisados na seção 2.4.

Tabela 1 - Projetos Correlatos

| # | Projeto |
|----|--------------------------------------|
| 1 | GMT-PD (Xiong et al., 2009) |
| 2 | Xiang et al., 2009 |
| 3 | LifeNet (Singh et al., 2003) |
| 4 | Osmani et al. |
| 5 | ALHMM (Cheng et al., 2010) |
| 6 | UbiFitGarden (Consolvo et al., 2008) |
| 7 | Brunette et al., 2005 (MSB) |
| 8 | Greenfield (Brush et al., 2010) |
| 9 | Bao et al., 2004 |
| 10 | PROACT (Philipose et al., 2004) |
| 11 | Reality Mining (Eagle et al., 2006) |

2.1. Natureza do projeto

Os trabalhos foram agrupados nas seguintes categorias:

- Projetos de Prova de conceito: Os projetos estudados nesta seção exploram abordagens para a inferência de atividades com protótipos ou implementações de prova de conceito.

- Ferramentas/Aplicações: Os projetos estudados nesta seção são ferramentas ou aplicações que atuam na área de inferência de atividades.

2.2. Inferência de atividades baseada em sensores

Sensores são dispositivos que medem, capturam ou detectam informações do mundo real e convertem tal informação em uma representação digital para que a mesma seja capaz de ser interpretada por computadores.

Os sensores possui grande importância em sistemas sensíveis ao contexto porque é a partir deles que os sistemas coletam as informações necessárias para seu funcionamento.

A tabela 2, a seguir, lista os principais tipos de sensores [43]:

Tabela 2 - Tipos de Sensores

| Tipo de Informação de Contexto | Sensores Disponíveis |
|--------------------------------|--|
| Luz | Sensores de cores, sensores infra-vermelho e ultra-violeta |
| Visual | Câmeras |
| Som | Microfone |
| Movimento/Aceleração | Acelerômetros, detectores de movimento, campos magnéticos e sensores angulares |
| Localização | GPS, Torres de Telefonia Móvel |
| Toque | Sensores sensíveis a toque em dispositivos móveis |
| Temperatura | Termômetro |
| Atributos Físicos | Bio-sensores capazes de medir pressão e batimentos cardíacos |

Os principais tipos de sensores serão detalhados nas seções subseqüentes.

2.2.1. Sensores de localização

Devido à recente popularização e ao grande desenvolvimento de sensores de localização, este tipo de sensor é um dos mais utilizados na obtenção de informações de usuário. [31, 42]

Do ponto de vista de localização podemos classificar os sensores em dois grupos:

1. Localização física: são sensores que representam a localização em coordenadas físicas do mundo. Trabalhos calculam esta localização através de sensores: GPS, satélites, intercessões de sinais de torres de telefonia e até dispositivo Bluetooth.
2. Localização simbólica: são sensores que representam a localização de acordo com a semântica do local, isto é, em vez de dizer o usuário está na coordenada 20.000 de latitude e 18.000 de longitude é mais interessante saber que o usuário está em seu escritório. Essa localização pode ser obtida por tabelas que relacionem espaços físicos a espaços lógicos, ou até, por sensores de identificação. Discutiremos sensores de identificação com mais detalhes na seção 2.2.3.

A localização de um usuário pode ser útil para diversas finalidades das quais podemos citar [29]:

1. Aplicativos de escritório: a localização é utilizada para indicar serviços que estejam mais próximos do usuário, como por exemplo impressoras, para aumentar a produtividade.
2. Suporte ao turismo: a localização do usuário pode ser utilizada para informá-lo de pontos turísticos próximos dele para que ele aproveite mais sua viagem.
3. Redes Sociais: a localização de dois “amigos” pode ser útil para que ambos possam marcar um encontro.
4. Conferências: a localização acrescida de informações de interesse do usuário pode ser utilizada para sugerir e facilitar com que o usuário assista a uma apresentação.
5. Sistemas de assistência médica: a localização do paciente pode ser necessária caso seja necessário realizar um atendimento urgente em resposta a caracterização de um quadro de risco.

6. Atividades Domésticas: Pode auxiliar na execução de tarefas domésticas, fornecer entretenimento e ajudar idosos e deficientes em seu cotidiano.

Em adição a lista anterior, os seguintes cenários também podem ser enriquecidos com informações de localização de usuários:

7. Sistemas de ensino: a localização do estudante pode ser utilizada para calcular automaticamente sua frequência em uma disciplina ou alertá-lo que se encontra na sala errada.
8. Transito: a localização de um veículo e seu destino podem ser utilizados para elaboração de rotas que otimizem o caminho a percorrer e evitem congestionamentos.

A figura 1 exibe um exemplo de aplicativo que utiliza informações de localização de usuário.




Figura 1 - Informação de localização

2.2.2. Sensores de movimentação

Assim como dispositivos que captam informações sobre localização, cuja adoção está cada vez mais difundida entre dispositivos de computação móvel, os dispositivos que capturam dados relativos a movimentação, e.g., os

acelerômetros, vem se tornando bastante populares no principais aparelhos comerciais de telefonia e controladores de jogos.

Os acelerômetros medem a inércia de objetos, dessa forma, é possível analisar as forças que atuam sobre eles. Por exemplo, se colocássemos um acelerômetro em um martelo, e em seguida, começássemos a pregar um quadro na parede, o sensor captaria os movimentos descritos pelo martelo.

As informações de movimentação podem ser úteis nos seguintes sistemas:

1. Trânsito: a aceleração do veículo pode ser utilizada para inferir se uma determinada rua está congestionada ou livre. Além disso, a aceleração é também utilizada para o controle e fiscalização de velocidade.
2. Transporte: a aceleração do usuário pode ser utilizada para analisar se este está parado, andando, de carro ou de avião.
3. Interação com objetos: a movimentação de um martelo para cima e para baixo repetidamente é um forte indicativo de que alguém está martelando algo.

A figura 2 exibe um exemplo de aplicação que exibe informações relativas a localização e ao deslocamento do usuário.



Figura 2 - Informações de localização e deslocamento

2.2.3. Sensores de identificação

Os sensores que capturam dados de identificação são interessantes porque já carregam consigo um nível de abstração mais elevado em relação aos demais sensores. Os sensores de identificação atribuem diretamente informações que identifique: o usuário, o local em que o usuário está ou o objeto com o qual o usuário está interagindo.

Estes sensores podem ser bastante úteis em situações em que exijam: (1) diferentes tipos de usuários no sistema com comportamentos distintos como médico e paciente, (2) diferentes tipos de objetos com finalidades distintas como escova e martelo, (3) diferentes tipos de locais com comportamentos particulares como sala de aula e lanchonete.

O tipo de sensor mais utilizado desta categoria é o sensor RFID [53] (Radio-Frequency Identification – Identificação por radio-frequência) que atribui tags de identificação ao elemento a ser identificado.

Por causa da relação de identificação ser uma relação bastante forte, o ato de definir uma identidade a um objeto requer cuidados para que um objeto não seja erroneamente identificado. Considere a seguinte situação: um leitor de identificação baseado em rfid ou Bluetooth se aproxima de um objeto com um chip de identificação, apesar da proximidade, o objeto leitor deve confirmar a interação com objeto apenas se o objeto for realmente tocado pelo usuário.

2.2.4. Sensores de vídeo

A categoria de sensores de vídeo é composta por dispositivos de câmera que filmam e capturam imagens e através de, um pouco de processamento é possível obter informações como histograma, níveis de cores e movimentos, ou muito processamento é possível reconhecer objetos, usuários ou gestos.

No âmbito de inferência de atividade, informações coletadas por câmeras podem ser úteis para, por exemplo: (1) identificar usuários de acordo com seu rosto ou crachá, (2) reconhecer tipos de objetos e analisar se estes foram movimentados no espaço.

Entretanto não existem muitos projetos que trabalhem como câmeras dado que o custo computacional de monitoramento em tempo-real das imagens gravadas pode ser bastante alto.

2.3. Processo de inferência

Nesta seção, descremos e apresentamos as duas principais abordagens para a realização do processo de inferência: inferência baseada em regras e inferência baseada em probabilidades.

- Inferência baseada em regras: Nesta abordagem, um conjunto de regras indica qual o procedimento deve ser realizado em resposta a eventos captados por sensores do sistema. De acordo com esta abordagem, uma atividade é escolhida quando um conjunto de condições é satisfeito para determinado estado. Por exemplo, caso exista uma regra “SE usuário ESTÁ EM um restaurante ENTÃO usuário ESTÁ comendo” e um usuário Y está em um restaurante X é possível inferir, de acordo com esta regra que o usuário Y está comendo.
- Inferência baseada em probabilidades: Diversos trabalhos vêm seguindo esta abordagem uma vez que a abordagem probabilística permite trabalhar com incertezas e ambigüidades [53]. Dessa forma, a atividade que possuir maior probabilidade será eleita no processo de inferência. Podemos citar as três principais abordagens contidas nesta categoria:
 - Redes Bayesianas [35]: são modelos constituídos por um grafo acíclico dirigido no qual os nós representam estados e os arcos representam a probabilidade ou dependência entre estes estados ao longo do eixo temporal.
 - Modelo Oculto de Markov (Hidden Markov Model - HMM) [37]: é um tipo de rede bayesiana no qual apenas são conhecidos os parâmetros alterados pela transição de estados, ou seja, os nós ou estados do grafo não são visíveis ao observador.
 - Campos Aleatórios de Condições (Conditional Random Fields - CRFs) [32]: constituem um grafo não-direcionado no qual os estados ocultos estão associados a uma única variável global que aprecia as observações já realizadas.

2.4. Análise dos projetos

Nesta seção, discutimos projetos de pesquisa relacionados a área de inferência de atividades do usuário. Estes, de modo geral, podem ser agrupados em duas categorias distintas, a saber: Projetos de prova de conceito e Ferramentas. Na próxima seção discutimos cada um em separado e, por fim, apresentamos uma tabela comparativa dos diversos estudos.

2.4.1. Projetos de Prova de Conceito

1. Xiong et al. [53] apresentam seu protótipo de sistema GMT-PD que utiliza sensores RFID para reabilitar pacientes com deficiências cognitivas na execução de suas tarefas do dia-a-dia. Quando o sistema GMT-PD reconhece que uma tarefa está começando a ser executada, o usuário é questionado se necessita de ajuda com a tarefa e se for necessário disponibilizará uma seqüência de passos para completá-la. Como o protótipo apresentado utiliza apenas sensores RFID, o desempenho do mesmo fica sujeito aos problemas de sensores RFID, como por exemplo, ambigüidade que ocorre quando várias atividades podem ser identificadas por um conjunto similar de identificadores RFID.
2. Xiang et al. [52] apresentam um modelo computacional baseado em ontologia e em regras de inferências para representar atividades decompondo-as entre ações e processos. Apesar da abordagem genérica, os autores indicam possíveis cenários concretos em que este modelo poderia ser utilizado como, por exemplo, o uso domiciliar. O modelo proposto pode sofrer com problemas de ambigüidade uma vez que uma ação pode possuir varias ações subseqüentes. Estes problemas podem ser resolvidos ao atribuir pesos diferentes às ações futuras baseadas no histórico de atividades realizadas.
3. Singh et al. [45] apresentam LifeNet, um modelo de dados que representa ações e atividades de pessoas de forma proposicional. LifeNet apresenta cerca de 80.000 proposições com cerca de 415.000 conexões temporais ou atemporais entre elas. Assim, a principal questão do LifeNet é relativa a seu tamanho: positivamente pela quantidade de informação contida no modelo e

negativamente pelo desafio que é trabalhar com o modelo tratando de escalabilidade e desempenho.

4. Osmani et al. [34] apresentam um sistema capaz de reconhecer e monitorar as atividades de um usuário em sua casa através da sua interação com os objetos do ambiente. Sua arquitetura possui os seguintes componentes: (1) Rede de Objetos; (2) Mapa de Atividades que atua como uma rede bayesiana na qual cada ação é conectada a outra ação por um valor probabilístico; e (3) Modulo de Decisões trabalha integrando os outros dois componente. Possui sua inferência baseada exclusivamente através da interação com os objetos do sistema o que faz com que o domínio do sistema seja abordado de forma simplificada dificultando a descoberta de atividades que não dependam de objetos, e.g correr, conversando, que poderiam ser auxiliadas por sensores acelerômetro e microfone respectivamente.

2.4.2.Ferramentas/Aplicação

1. Cheng et al. [12] apresentam sua ferramenta ALHMM que modela as atividades de acordo com Hidden Markov Model e utilizam o algoritmo de Viterbi [49] para gerar a seqüência de maior probabilidade dentre as atividades observadas e o algoritmo de Baum–Welch [03] para diminuir a taxa de erros de inferência ocorridos durante o processo de aprendizagem.
2. Consolvo et al. [14] apresentam o resultado do estudo realizado com o sistema UbiFit Garden que tem como por objetivo estimular a prática de exercícios físicos. O sistema utiliza o dispositivo Mobile Sensing Platform (MSP) [13] que disponibiliza recursos de sensores e de aplicações voltadas para inferência de atividades dos usuários. Um diferencial do sistema UbiFit Garden é que o usuário pode consultar as atividades inferidas e caso discorde da atividade escolhida o usuário pode alterar o registro desta, dessa forma, o sistema disponibiliza meios para correção de erros de inferência.
3. Brunette et al. [10] apresentam uma rede de sensores composta pelos seguintes elementos: (1) Multi-Modal Sensor Board (MSB), uma placa de sensores que captura informações do usuário e as submete a um Hidden Markov Model para o cálculo de inferência;

- (2) iReader, componente que permite que o usuário interaja com os objetos do ambiente através de comunicação RFID seja lendo ou escrevendo as tags do objeto; (3) DisplayMote, interface gráfica de leve utilização que emite avisos, lembretes e listas de serviços disponíveis e possibilita ao usuário responder a estes estímulos e interagir com o sistema. O sistema possui como vantagem o suporte a diversos tipos de sensores no MSB o que possibilita que o mesmo possa se adaptar a diferentes situações e assim ser utilizado em diversas áreas de aplicação.
4. Brush et al. [11] apresentam o sistema Greenfield que possui como objetivo orientar o usuário a percorrer um determinado rota para, por exemplo, encontrar seu carro. Através do avanço no desenvolvimento de sensores é possível decompor um caminho entre distancias percorridas e mudanças de direções. Implementado como um aplicativo da Plataforma Menlo, o sistema Greenfield permite traçar rotas através de diferentes combinações de sensores caso já tenha percorrido o caminho, ou criar um descrição verbal do ambiente. Apesar de o cenário apresentado ser específico do domínio de localização de carros em um estacionamento, a navegação baseada em atividades pode ser aplicada para auxiliar usuários a encontrar um objeto perdido, encontrar pessoas em um ponto de encontro e determinar uma trilha para chegar a um local específico.
 5. Bao et al. [02] apresentam um mecanismo que realiza inferência acerca das atividades de um usuário a partir de informações coletadas de cinco acelerômetros vestidos pelo usuário. Este mecanismo baseia-se na estrutura de arvores de decisões e prevê um conjunto de vinte atividades como, por exemplo: andando, correndo, lendo etc. Por causa da utilização exclusiva dos dispositivos acelerômetros, as informações coletadas limitam-se a frequência de movimentos, entretanto, a adoção de outros tipos de sensores, como por exemplo, sensores de localização e tempo, poderia contribuir para ampliar a área de atuação do sistema que atualmente está limitado a atividades domésticas.
 6. Philipose et al. [36] apresentam seu sistema PROACT composto por três elementos: (1) luva leitora de sinais RFID que permite que os objetos manipulados sejam conhecidos através de tags RFID;

(2) modelo que representa as atividades previstas para o sistema;
 (3) mecanismo que converte o modelo das atividades em uma rede bayesiana dinâmica responsável pelo cálculo da atividade. Assim como o sistema proposto por Osmani et al. [34], PROACT também possui seu processo de inferência completamente dependente da interação com objetos o que torna as representações das informações coletadas mais simples limitando o sistema de perceber atividades em que o usuário não interage com nenhum objeto previsto inicialmente.

7. Eagle et al. [22] apresenta o sistema Reality Mining que possui como objetivo conhecer o comportamento dos usuários, inferir atividades e relacionamentos e identificar tipos de locais. Implementado na plataforma ContextPhone [38], este projeto possui como proposta determinar o comportamento do usuário através dos usuários que o cercam (Comunicação Bluetooth), da sua localização (Comunicação Bluetooth e sinal da operadora do celular) e informações coletadas pelo celular. Um diferencial do sistema Reality Mining é a utilização de informação acerca do relacionamento e interação entre usuários que apesar de pouco abordado nos demais projetos pode ser de grande importância uma vez que a sociedade em volta do usuário dita um conjunto de características e atividades comuns e assim pode ser vista como informação de contexto.

2.5. Tabela Comparativa

A tabela 3, a seguir, apresenta os projetos estudados e classificados de acordo com os seguintes critérios: natureza do projeto, sensores adotados e processo de aprendizagem.

Tabela 3 - Análise de Projetos de Inferência de Atividades

| # | Projeto | Tipo de Sensores | Processo de Inferência | Natureza do Projeto |
|---|-----------------------------|------------------|------------------------|------------------------------|
| 1 | GMT-PD (Xiong et al., 2009) | Sensores RFID | Baseado em regras | Projeto de prova de conceito |
| 2 | Xiang et al., 2009 | Nenhum | Baseado em | Projeto de |

| | | | | |
|----|--------------------------------------|--|----------------------------------|------------------------------|
| | | | regras | prova de conceito |
| 3 | LifeNet (Singh et al., 2003) | Nenhum | Baseado em regras | Projeto de prova de conceito |
| 4 | Osmani et al. | Nenhum | Rede Bayesiana | Projeto de prova de conceito |
| 5 | ALHMM (Cheng et al., 2010) | Nenhum | Hidden Markov Model | Ferramenta |
| 6 | UbiFitGarden (Consolvo et al., 2008) | Acelerômetro, barômetro, higrômetro, termômetro, microfone e bussola | Conditional random fields (CRFs) | Ferramenta |
| 7 | Brunette et al., 2005 (MSB) | Acelerômetro, barômetro, higrômetro, termômetro, microfone e bussola | Hidden Markov Model | Ferramenta |
| 8 | Greenfield (Brush et al., 2010) | Acelerômetro, barômetro e bussola | Nenhum | Ferramenta |
| 9 | Bao et al., 2004 | Acelerômetro | Arvore de decisão | Ferramenta |
| 10 | PROACT (Philipose et al., 2004) | Sensores RFID | Rede Bayesiana | Ferramenta |
| 11 | Reality Mining (Eagle et al., 2006) | Bluetooth | Hidden Markov Model | Ferramenta |