

**UNIVERSIDADE FEDERAL DE SANTA MARIA  
CENTRO DE TECNOLOGIA  
PROGRAMA DE PÓS-GRADUAÇÃO EM INFORMÁTICA**

**MODELO PARA PREDIÇÃO DE AÇÕES E  
INFERÊNCIA DE SITUAÇÕES DE RISCO EM  
AMBIENTES SENSÍVEIS AO CONTEXTO**

**DISSERTAÇÃO DE MESTRADO**

**Alfredo Del Fabro Neto**

**Santa Maria, RS, Brasil**

**2015**

# **MODELO PARA PREDIÇÃO DE AÇÕES E INFERÊNCIA DE SITUAÇÕES DE RISCO EM AMBIENTES SENSÍVEIS AO CONTEXTO**

**Alfredo Del Fabro Neto**

Dissertação apresentada ao Curso de Mestrado Programa de Pós-Graduação em Informática (PPGI), Área de Concentração em Computação, da Universidade Federal de Santa Maria (UFSM, RS), como requisito parcial para obtenção do grau de **Mestre em Ciência da Computação**

**Orientadora: Prof<sup>a</sup>. Dra. Iara Augustin**

**Santa Maria, RS, Brasil**

**2015**

Del Fabro Neto, Alfredo

Modelo para predição de ações e inferência de situações de risco em ambientes sensíveis ao contexto / por Alfredo Del Fabro Neto. – 2015.

74 f.: il.; 30 cm.

Orientadora: Iara Augustin

Dissertação (Mestrado) - Universidade Federal de Santa Maria, Centro de Tecnologia, Programa de Pós-Graduação em Informática, RS, 2015.

1. Modelo Hiperespaço Análogo ao Contexto. 2. Reconhecimento de Atividades Humanas. 3. Activity Project. 4. Middleware. 5. Situation-awareness. I. Augustin, Iara. II. Título.

---

© 2015

Todos os direitos autorais reservados a Alfredo Del Fabro Neto. A reprodução de partes ou do todo deste trabalho só poderá ser feita mediante a citação da fonte.

E-mail: [alfredodfn@redes.ufsm.br](mailto:alfredodfn@redes.ufsm.br)

**Universidade Federal de Santa Maria  
Centro de Tecnologia  
Programa de Pós-Graduação em Informática**

A Comissão Examinadora, abaixo assinada,  
aprova a Dissertação de Mestrado

**MODELO PARA PREDIÇÃO DE AÇÕES E INFERÊNCIA DE  
SITUAÇÕES DE RISCO EM AMBIENTES SENSÍVEIS AO CONTEXTO**

elaborada por  
**Alfredo Del Fabro Neto**

como requisito parcial para obtenção do grau de  
**Mestre em Ciência da Computação**

**COMISSÃO EXAMINADORA:**

**Iara Augustin, Dra.**  
(Presidente/Orientadora)

**Roseclea Duarte Medina, Dra. (UFSM)**

**Luiz Angelo Steffemel, Dr. (URCA)**

Santa Maria, 31 de Julho de 2015.

## AGRADECIMENTOS

Agradeço à minha família, em especial minha Mãe, Luci, meu Pai, Valmor, minha Irmã, Roberta, minha prima, Luisa e meu afilhado, Bernardo. Meu muito obrigado por estarem ao meu lado nos momentos cruciais, pelo carinho, compreensão e pelo suporte incondicional na realização do Mestrado.

Agradeço à minha orientadora, Prof<sup>a</sup>. Dra. Iara Augustin, pela liberdade e confiança na realização desta dissertação, pelos ensinamentos e incentivos que motivaram a publicação de trabalhos com resultados relevantes na área.

Agradeço ao Professor e amigo Dr. João Carlos D. Lima pela disponibilidade, por todos os ensinamentos nos momentos de dúvida e pela impecável condução desta dissertação.

Agradeço aos meus amigos e colegas do Grupo de Sistemas de Computação Móvel, em especial aos amigos Bruno Romero de Azevedo e Rafael Boufleuer, pelas incansáveis discussões sobre o rumo desta pesquisa e pelo auxílio na realização desta dissertação. Mas gostaria de agradecer principalmente pela amizade e motivação nos momentos difíceis.

Agradeço ao Professor e amigo Celio Trois, grande incentivador na realização do Mestrado, e aos demais colegas de docência do Colégio Técnico Industrial de Santa Maria (CTISM).

Agradeço aos meus amigos, João, Rafael, Thales, Vasco e Matheus pelo apoio, pela amizade e pelos momentos de descontração e contribuição intelectual em infindáveis discussões sobre a vida, o universo e tudo mais.

Agradeço à CAPES (Coordenação de Aperfeiçoamento de Pessoal de Nível Superior) pela concessão da bolsa durante todo o período de realização deste Mestrado.

Por fim, agradeço a todos que de alguma forma contribuíram para a realização desta dissertação, aos professores e funcionários do Programa de Pós-Graduação em Informática da Universidade Federal de Santa Maria.

*“É muito melhor lançar-se em busca de conquistas grandiosas, mesmo expondo-se ao fracasso, do que alinhar-se com os pobres de espírito, que nem gozam muito nem sofrem muito, porque vivem numa penumbra cinzenta, onde não conhecem nem vitória, nem derrota.”*

— THEODORE ROOSEVELT

# RESUMO

Dissertação de Mestrado  
Programa de Pós-Graduação em Informática  
Universidade Federal de Santa Maria

## MODELO PARA PREDIÇÃO DE AÇÕES E INFERÊNCIA DE SITUAÇÕES DE RISCO EM AMBIENTES SENSÍVEIS AO CONTEXTO

AUTOR: ALFREDO DEL FABRO NETO

ORIENTADORA: IARA AUGUSTIN

Local da Defesa e Data: Santa Maria, 31 de Julho de 2015.

A popularização de sensores de baixo custo e de dispositivos móveis permitiu diversos avanços nas pesquisas da área de computação ubíqua e pervasiva. Com a captura dos dados contextuais providos pelos sensores acoplados a estes dispositivos é possível obter informações do estado do usuário e do ambiente, e dessa forma mapear a relação entre ambos. Uma das possíveis abordagens para mapear essas relações são as atividades executadas pelo usuário, que inclusive são parte constituinte do próprio contexto. Entretanto, mesmo que as atividades humanas possam causar danos físicos, não há muita discussão na academia de como a computação ubíqua poderia avaliar esse risco relacionado a elas. Neste sentido, o projeto *Activity Project* objetiva determinar situações de risco no momento da realização de atividades desempenhadas por pessoas em um ambiente sensível ao contexto, através de um *middleware* sensível ao contexto que considera o risco nas ações que compõe uma atividade e o desempenho do usuário enquanto executa uma atividade. Esta dissertação tem por objetivo especificar a camada Gerência de Atividades do *middleware* proposto para o *Activity Project*, cujo objetivo é tratar as questões referentes à predição de ações e atividades e a detecção de situações de risco em ações. O modelo desenvolvido para tratar a composição das atividades e a predição das mesmas baseia-se na Teoria da Atividade, enquanto que o risco em ações é determinado pelas mudanças no contexto fisiológico do usuário, modeladas através do modelo Hiperespaço Análogo ao Contexto. Nos testes realizados os modelos desenvolvidos superaram as propostas encontradas até o momento para a predição de ações com uma precisão de 78,69%, bem como para a determinação de situações de risco com uma precisão de 98,94%, demonstrando a eficácia da solução proposta.

**Palavras-chave:** Modelo Hiperespaço Análogo ao Contexto. Reconhecimento de Atividades Humanas. Activity Project. Middleware. Situation-awareness.

# ABSTRACT

Master's Dissertation  
Post-Graduate Program in Informatics  
Federal University of Santa Maria

## **A MODEL FOR ACTION PREDICTION AND RISK SITUATION INFERENCE IN CONTEXT-AWARE ENVIRONMENTS**

**AUTHOR: ALFREDO DEL FABRO NETO**

**ADVISOR: IARA AUGUSTIN**

Defense Place and Date: Santa Maria, March 31<sup>st</sup>, 2015.

The availability of low cost sensors and mobile devices allowed many advances in research of ubiquitous and pervasive computing area. With the capture of contextual data provided by the sensors attached to these devices it is possible to obtain user state information and the environment, and thus map the relationship between them. One approach to map these relationships are the activities performed by the user, which also are part of the context itself. However, even that human activities could cause injuries, there is not much discussion in the academy of how ubiquitous computing could assess the risk related to them. In this sense, the Activity Project aims to determine the risk situations related to activities performed by people in a context aware environment, through a middleware that considers the risk in the actions that composes an activity and the user performance while performing an activity. This thesis aims to specify the Activity Manager middleware layer proposed for the Activity Project, whose goal is to address issues relating to the prediction of actions and activities and the detection of risk situation in the actions performed by an user. The model developed to address the composition and prediction of activities is based on the Activity Theory, while the risk in actions is determined by changes in the physiological context of the user caused by the actions performed by itself, modeled through the model named Hyperspace Analogous to Context. Tests were conducted and developed models outperformed proposals found for action prediction, with an accuracy of 78.69%, as well as for risk situations detection, with an accuracy of 98.94%, showing the efficiency of the proposed solution.

**Keywords:** Risk Situation Detection. Action Prediction. Activity Prediction. Context Awareness. Activity Theory..

## LISTA DE FIGURAS

Figura 2.1 – Contexto atual do usuário ( $c^{usuário}$ ) e contexto gerado a partir de ação ( $c^{usuário'}$ ) Fonte: Adaptado de Rasch (2013). . . . .	25
Figura 2.2 – Teoria da Atividade Histórico-Cultural (TAHC). Fonte: Adaptado de Kuutti (1996). . . . .	25
Figura 2.3 – Taxonomia de Contexto. Fonte: Adaptado de Mikalsen e Koffod-Petersen (2004). . . . .	27
Figura 2.4 – Fluxo de Dados para fase de treinamento e teste em sistemas de RAH. Fonte: Adaptado de Lara e Labrador (2013). . . . .	29
Figura 2.5 – Exemplo da modelagem de uma ADL. Fonte: Adaptado de Naeem et al. (2007). . . . .	32
Figura 4.1 – Arquitetura do middleware para detecção de situações de risco. Fonte: do Autor. . . . .	43
Figura 5.1 – Arquitetura da camada Gerência de Atividades. Fonte: do Autor. . . . .	49
Figura 5.2 – Exemplo de mudanças no estado do usuário. Fonte: Adaptado de Rasch (2013). . . . .	54
Figura 5.3 – Funcionamento da proposta de detecção de situações de risco. Fonte: do Autor. . . . .	55
Figura 5.4 – Exemplo do método para o reconhecimento de atividade baseado na TA. Fonte: do Autor. . . . .	57
Figura 6.1 – Protótipo utilizado para captura dos dados sensores de Acelerômetro e Giroscópio do dispositivo Android. Fonte: do Autor. . . . .	61
Figura 6.2 – Comparativo entre as propostas de predição de ações. Fonte: do Autor. . . . .	63
Figura 6.3 – Comparativo entre as propostas de detecção de situação de risco em ações. Fonte: do Autor. . . . .	64

## LISTA DE TABELAS

Tabela 2.1 – Aspectos básicos de uma atividade e o seu relacionamento com a Taxonomia de Conhecimento Contextual: Fonte: Adaptado de Kofod-Petersen e Cassens (2006). . . . .	26
Tabela 2.2 – Grupos de atividades em Sistemas de Reconhecimento de Atividades Humanas. Fonte: Adaptado de Lara e Labrador (2013). . . . .	28
Tabela 3.1 – Comparação entre propostas para inferência de ações e atividades. Fonte: Adaptado de Lara e Labrador (2013). . . . .	37
Tabela 3.2 – Comparação entre propostas para detecção de situações de risco. Fonte: Adaptado de Lara e Labrador (2013). . . . .	41
Tabela 6.1 – Número de ocorrências das atividades presentes no Aruba Dataset. Fonte: Cook (2011). . . . .	60
Tabela 6.2 – Número de ocorrências das ações presentes no dataset GMob. Fonte: do Autor. . . . .	61
Tabela 6.3 – Precisão dos algoritmos de aprendizagem executados no dataset GMob. Fonte: do Autor. . . . .	62
Tabela 6.4 – Comparativo entre as propostas de predição de ações. Fonte: do Autor. . . . .	62
Tabela 6.5 – Comparativo entre as propostas de detecção de situação de risco em ações. Fonte: do Autor. . . . .	63
Tabela 6.6 – Resultados do modelo proposto para detecção de situações de risco. Fonte: Adaptado de Lara e Labrador (2013). . . . .	65
Tabela 6.7 – Resultados do modelo proposto para predição de ações. Fonte: Adaptado de Lara e Labrador (2013). . . . .	66

## LISTA DE ABREVIATURAS E SIGLAS

ADL	Activity of Daily Living
AMB	Ambulation Activities
API	Application Program Interface
ACC	Accelerometer
CRF	Conditional Random Fields
DA	Daily Activities
ECG	Electrocardiogram
FD	Frequency-domain Features
GYR	Gyroscope
GMob	Grupo de Sistemas de Computação Móvel
GPS	Global Positioning System
HAC	Hiperespaço Análogo ao Contexto
IRQ	Interquartile Range
LAB	Laboratory controlled experiment
MAD	Mean Absolute Deviation
MNL	Monolithic classifier
MPL	Maximum Pattern Length
MQTT-S	Message Queuing Telemetry Transport for Sensor Networks
NAT	Naturalistic experiment
PC	Personal Computer
RMS	Root Mean Square
SMA	Signal Magnitude Area
SPIDER	Scanning, Predicting, Identifying, Deciding, Executing, Response
SPC	User-specific Classifier
SRK	Skill, Rule and Knowledge
SVM	Support Vector Machines
TA	Teoria da Atividade
TAHC	Teoria da Atividade Histórico-Cultural
TD	Time-domain Features
TW	Time Window
UML	Unified Modeling Language
XML	eXtensible Markup Language

## SUMÁRIO

<b>1 INTRODUÇÃO</b> .....	14
<b>1.1 Contextualização do tema de pesquisa</b> .....	14
<b>1.2 Delimitação</b> .....	16
<b>1.3 Pergunta de Pesquisa</b> .....	17
<b>1.4 Objetivos</b> .....	17
<b>1.5 Organização do Trabalho</b> .....	18
<b>2 FUNDAMENTAÇÃO TEÓRICA</b> .....	19
<b>2.1 Computação Ubíqua e Pervasiva</b> .....	19
<b>2.2 Computação Sensível ao Contexto</b> .....	20
<b>2.3 Classificação de Modelos de Contexto</b> .....	22
<b>2.4 Hiperespaço Análogo ao Contexto (HAC)</b> .....	23
<b>2.5 Teoria da Atividade</b> .....	24
2.5.1 Teoria da Atividade e o Reconhecimento de Atividade .....	26
2.5.2 Reconhecimento de Atividades Humanas .....	27
2.5.3 Composição das atividades.....	30
<b>2.6 Situation Awareness</b> .....	32
<b>2.7 Gerência de Risco</b> .....	33
<b>3 TRABALHOS RELACIONADOS</b> .....	34
<b>3.1 Método de comparação</b> .....	34
<b>3.2 Abordagens utilizadas na predição de ações e atividades</b> .....	36
<b>3.3 Abordagens utilizadas na detecção de situações de risco</b> .....	38
<b>4 ACTIVITY PROJECT</b> .....	42
<b>4.1 Contextualização</b> .....	42
<b>4.2 Arquitetura proposta</b> .....	42
4.2.1 Camadas Normalização de Dados Brutos e Estado dos Sensores .....	44
4.2.2 Camada Gerência de Atividades .....	44
4.2.3 Camada Classificador SRK .....	45
4.2.4 Camada Analisador de Risco .....	46
4.2.5 Fluxo de dados .....	46
<b>5 MODELO PARA INFERÊNCIA DE SITUAÇÕES DE RISCO EM AÇÕES</b> .....	48
<b>5.1 A camada Gerência de Atividades</b> .....	48
5.1.1 Reconhecimento de ações .....	50
5.1.2 Inferência da próxima ação do usuário .....	51
5.1.3 Inferência do Risco em Ações .....	52
5.1.3.1 Exemplo de análise de mudança de contexto .....	53
5.1.3.2 Exemplo de Funcionamento do risco em ações.....	54
5.1.4 Detecção e Predição de Atividade .....	56
<b>6 RESULTADOS</b> .....	59
<b>6.1 Datasets utilizados</b> .....	59
6.1.1 Dataset Aruba .....	59
6.1.2 Dataset GMob.....	60
<b>6.2 Avaliação da classificação de ações</b> .....	60
<b>6.3 Avaliação da predição de ações</b> .....	62
<b>6.4 Avaliação da situação de risco em ações</b> .....	63
<b>6.5 Avaliação da predição de atividades</b> .....	64

<b>6.6 Comparação com os trabalhos relacionados .....</b>	<b>65</b>
<b>7 CONSIDERAÇÕES FINAIS.....</b>	<b>67</b>
<b>7.1 Trabalhos futuros .....</b>	<b>68</b>
<b>7.2 Publicações .....</b>	<b>68</b>
<b>REFERÊNCIAS .....</b>	<b>70</b>

# 1 INTRODUÇÃO

Neste capítulo é introduzida a contextualização do tema de pesquisa, bem como a justificativa e a relevância do trabalho. Posteriormente, a delimitação do tema é definida e o escopo do presente trabalho é apresentado. Em sequência, os objetivos deste trabalho são expostos, juntamente com as principais contribuições alcançadas. Por último, é descrito como o restante do trabalho está organizado.

## 1.1 Contextualização do tema de pesquisa

O aumento da disponibilidade de sensores de baixo custo, bem como a consolidação de tecnologias de dispositivos móveis possibilitou o avanço de pesquisas na área de Computação Ubíqua e Pervasiva. Atualmente, os dispositivos móveis estão equipados com sensores que permitem capturar diversos dados capazes de representar o estado do usuário e do ambiente. Além disso, o surgimento de dispositivos vestíveis e a popularização de sensores fisiológicos e ambientais, propiciaram o acesso a uma grande quantidade de atributos para representar o estado do usuário. Como exemplos temos os medidores do nível de oxigênio do sangue, de frequência cardíaca, de pressão sanguínea, dentre outros, os quais podem estar presentes de maneira não intrusiva em *smartwatches* (PASCOE, 2006). Estes avanços na área de *hardware* e *software* contribuirão para a criação de ambientes inteligentes que auxiliam o usuário em diferentes tarefas de seu interesse.

Existem diversos domínios de aplicação para estes ambientes inteligentes, tais como: casas inteligentes, capazes de recomendar serviços ao usuário de acordo com o perfil de comportamento e usabilidade; sistemas de segurança, para monitorar atividades suspeitas; sistemas esportivos, para monitorar o desempenho dos atletas e sistemas de *healthcare*, para o monitoramento da saúde de pacientes, dentre outros.

Exemplos de trabalhos atuais, e que tem chamado atenção da comunidade acadêmica, são os trabalhos que lidam com o domínio de aplicação de sistemas de *healthcare*, e em específico com a detecção de queda em idosos (DAVARI; AYDIN; ERDEM, 2013)(EL-BENDARY et al., 2013)(WANG et al., 2014). De fato, na medida em que envelhece, o ser humano naturalmente fica com a saúde enfraquecida, processo este proeminente no público idoso devido a problemas como sedentarismo, insônia, osteoporose, etc. Combinando esses fatores com os fatores externos ao usuário, como piso úmido, baixa iluminação, grande quantidade de escadas,

dentre outros, o risco de dano físico pode aumentar. Em especial, as atividades físicas humanas possuem um risco de dano associado para as pessoas que as realizam, e existem diversas situações onde o risco pode ser significativo: variações no ambiente (por exemplo, caminhar em um piso molhado), a própria condição física das pessoas (por exemplo, idosos com doenças físicas degenerativas tentando locomover-se), comportamento arriscado (por exemplo, caminhar em casa a noite, com as luzes apagadas), dentre outros.

Portanto, é requisito para um sistema computacional para *healthcare* possuir a capacidade de detectar situações arriscadas em atividades humanas, de forma a antecipar os riscos envolvidos e prevenir ou atenuar os danos causados ao usuário. Neste sentido, o projeto *Activity Project* foi proposto com o intuito de estudar as atividades humanas e as suas relações com o contexto, de forma a prover informação relevante para que diversas aplicações de domínios de aplicação distintos possam utilizar-se desses dados para disponibilizar serviços de valor agregado para o usuário. Exemplos são os sistemas de recomendação, sistemas de *healthcare*, sistemas que utilizem processos de tomada de decisão, dentre outros. O *Activity Project* utiliza a estratégia de *middleware* para disponibilizar tais serviços, cuja arquitetura foi concebida com base em modelos cognitivos e comportamentais para determinar situações de risco. O *middleware* é composto por cinco camadas, que operam desde a obtenção dos dados de contexto dos sensores, até as camadas de mais alto nível, como análise de ações e atividades (camada *Gerência de Atividades*), análise de desempenho de atividades (camada *Classificador SRK*), e análise final de situação de risco (camada *Analizador de Risco*).

Entretanto, para detectar as situações de risco é necessário compreender como o usuário interage com o ambiente. Assim, os sistemas tornam-se cientes do usuário e podem fornecer os serviços de forma personalizada. Ou seja, devem ser capazes de acessar os dados de contexto necessários para caracterizar uma situação em que os usuários estão inseridos. O contexto pode ser definido como “qualquer informação que pode ser utilizada para caracterizar a situação de uma entidade” (ABOWD et al., 1999), seja a entidade uma pessoa, lugar ou objeto. A partir destes dados, os sistemas podem ficar conscientes sobre o usuário e fornecer os serviços de forma adequada.

Com o intuito de fornecer melhores serviços, um ambiente inteligente deve ser capaz de detectar o que o ocupante está fazendo em termos de atividades (MOCANU; FLOREA, 2011). Ou seja, é necessário que o sistema capture a forma com que o usuário interage com o ambiente por meio da análise da execução de atividades. Portanto, a detecção de atividades é um ponto

crucial neste tipo de ambiente, visto que é parte constituinte do contexto no qual o usuário está inserido (LU; FU, 2009; CRISPIM-JUNIOR; BREMOND; JOUMIER, 2012).

Neste sentido, a detecção de situações de risco provenientes de uma atividade sendo desempenhada apresenta papel igualmente importante, uma vez que, além de permitir a obtenção de informação contextual sobre a situação do usuário enquanto executa uma atividade, ela permite determinar a qualidade da interação entre o usuário e o ambiente. Além disso, a detecção de situações de risco possibilita que a própria informação contextual seja aperfeiçoada de forma a estabelecer um ciclo, onde cada atividade desempenhada pelo usuário aprimora o entendimento do contexto pessoal e a relação do mesmo com o ambiente (MOCANU; FLOREA, 2011).

Este trabalho apresenta um modelo para determinar situações de risco baseado nas ações que o usuário executa, e permite capturar o comportamento normal do usuário e inferir a probabilidade de risco das próximas ações a serem executadas. Dessa forma, é possível evitar ou diminuir os danos causados ao usuário. Para tanto, foi necessário desenvolver um modelo para representar ações e atividades, baseado na Teoria da Atividade (VYGOTSKY, 1980) e no modelo contextual Hiperespaço Análogo ao Contexto (RASCH, 2013). Já a determinação de situações de risco foi realizada através do monitoramento dos dados de contexto fisiológico do usuário enquanto o mesmo realiza uma atividade. Dessa forma, foi possível associar uma situação a cada ação ou atividade realizada pelo usuário. O modelo desenvolvido foi incorporado à camada *Gerência de Atividades* que integra o *middleware* para detecção de situações de risco do projeto *Activity Project*.

## 1.2 Delimitação

Esta dissertação não tem como objetivo o desenvolvimento de um produto para detecção de situações de risco em ambientes inteligentes, mas sim o desenvolvimento de protótipos capazes de validar os modelos e conceitos apresentados neste trabalho.

É importante deixar claro que a detecção de situações de risco em sistemas ubíquos é um tema que atraiu pouca atenção dos pesquisadores na última década, sendo pouco explorado frente as propostas para detecção de atividades. Visto que o problema de pesquisa não possui material bibliográfico consolidado e está em fase de descoberta e sedimentação de conhecimento, esta pesquisa caracteriza-se por ter um caráter exploratório, onde têm por objetivo proporcionar maior entendimento de um determinado problema. Para Wazlawick (2009), a pes-

quisa exploratória é realizada em áreas em que há pouco conhecimento científico sistematizado ou acumulado.

### 1.3 Pergunta de Pesquisa

O presente trabalho concentra-se em responder a seguinte pergunta de pesquisa: Como detectar situações de risco considerando o modelo comportamental do usuário baseado nas ações realizadas por ele em um ambiente sensível ao contexto?

Para responder a pergunta de pesquisa, o presente trabalho utilizou-se de estudos bibliográficos para entender as principais necessidades da área e encontrar pontos específicos ainda não sedimentados. Para solucionar a pergunta de pesquisa, utilizou-se métodos probabilísticos para inferir, com base na ação corrente, qual será a próxima ação executada. De posse desta informação, o sistema compara o contexto atual do usuário com o contexto futuro do usuário. Se o contexto gerado estiver fora dos limites determinados para o usuário em questão, pode-se determinar que a situação futura é de risco.

Para modelar o comportamento do usuários e as operações sobre o contexto, o presente trabalho baseia-se nas ações executadas pelos usuários. Para tanto, utiliza-se a Teoria da Atividade (TA) para modelar as atividades e ações, bem como os relacionamentos destas com o indivíduo e o ambiente em si. Para capturar os dados de contexto que serão utilizados no modelo construído com a Teoria da Atividade e executar as operações de contexto necessárias para analisar contextos futuros, utiliza-se o modelo de Hiperespaço Análogo ao Contexto (HAC). Espera-se que com a combinação do modelo de predição, da modelagem de atividades e da análise de contextos futuros seja possível determinar situações de risco antes que elas ocorram, evitando ou diminuindo danos causados aos usuários.

### 1.4 Objetivos

A presente dissertação faz parte do projeto *Activity Project*, desenvolvido no Grupo de Sistemas de Computação Móvel (GMob) da Universidade Federal de Santa Maria, cujo objetivo é determinar situações de risco na realização de atividades em um ambiente sensível ao contexto. Neste sentido, foi proposto um *middleware* para detecção de riscos, que será apresentado em detalhes na Seção 4.2. Esta dissertação concentra-se em apresentar um modelo para especificar a camada *Gerência de Atividades* e as relações necessárias com as camadas

### *Classificador SRK e Analisador de Risco.*

As principais contribuições desta dissertação são: (i) a inferência de situações de risco, sendo de grande importância para as áreas de *healthcare*, monitoramento, segurança e sistemas de recomendação em geral. Além disso, permite acrescentar informação relevante sobre a situação do próprio usuário, podendo ser utilizado para fornecer informação contextual para enriquecer o contexto de um usuário em outras aplicações; e (ii) a predição de ações e atividades, já que modelos que permitam prever as ações dos usuários são úteis em diversos domínios de aplicação, como de segurança, militar, definição de perfis, padrões de acesso, autenticação implícita, etc.

## **1.5 Organização do Trabalho**

O restante deste trabalho está organizado da seguinte maneira: no Capítulo 2 a fundamentação teórica utilizada na elaboração da proposta é apresentada. O Capítulo 3 enumera os trabalhos analisados com esta dissertação, e ao final, uma breve comparação é realizada entre essas propostas. O Capítulo 4 explica o projeto *Activity Project* e o *middleware* para detecção de situações de risco proposto. Logo após, o Capítulo 5 discorre sobre o modelo proposto nesta dissertação, fazendo uma relação com os conceitos utilizados, para então, apresentar a solução encontrada. O Capítulo 6 apresenta o estudo de caso realizado para validar o modelo proposto, bem como uma comparação com os trabalhos apresentados no Capítulo 3. Por fim, o Capítulo 7 registra as considerações finais sobre o trabalho, as contribuições e sugestões para trabalhos futuros.

## 2 FUNDAMENTAÇÃO TEÓRICA

Este capítulo está estruturado em sete seções. Na primeira seção são apresentados os conceitos de Computação Ubíqua e pervasiva. Na Seção 2.2, os aspectos relacionados à Computação Sensível ao Contexto são abordados e na Seção 2.3 são apresentadas as classificações dos modelos de contextos. Estes tópicos são apresentados para situar o leitor quanto aos modelos utilizados neste trabalho: o modelo Hiperespaço Análogo ao Contexto, explicado na Seção 2.4 e a Teoria da Atividade, apresentada na Seção 2.5. Na sequência, a fundamentação teórica é concluída com a abordagem de conceitos de consciência da situação na Seção 2.6 e algumas considerações sobre o processo de gerenciamento de risco na Seção 2.7.

### 2.1 Computação Ubíqua e Pervasiva

As bases da Computação Ubíqua fundamentam-se no artigo *The Computer for the 21st Century*, de autoria de Mark Weiser, que define o termo como a integração de diversas tecnologias no ambiente ao qual os usuários realizam suas atividades diárias. Para Weiser, essas tecnologias “desapareceriam”, incorporando-se aos objetos do cotidiano até ficarem indistinguíveis destes, de forma integrada e onipresente (WEISER, 1991).

Nesta visão, os dispositivos computacionais e as questões técnicas relacionadas a eles ficam em segundo plano, dando espaço para que as tarefas executadas tornem-se o objetivo central de atenção da cognição do usuário. Ou seja, o usuário utilizaria a tecnologia de forma transparente para realizar suas atividades cotidianas independente da tecnologia empregada. Isto é um contraponto à situação atual, onde o usuário deve explicitamente gerenciar o computador, ao invés de investir tempo e recurso na tarefa que está executando. Weiser deixa clara a sua visão para Computação Ubíqua quando explicita que “o desafio é criar um novo tipo de relacionamento de pessoas e computadores, em que o computador teria que assumir a liderança ao tornar-se melhor em sair do caminho, para que as pessoas pudessem tratar apenas sobre suas vidas” (WEISER, 1993).

Embora a popularização dos dispositivos móveis (*smartphones, tablets*) e sensores de baixo custo tenham proporcionado a criação de cenários similares aos propostos por Weiser, estes dispositivos por si só estão distantes da visão de onipresença da Computação Ubíqua. A razão para isso é que a forma de interação entre os aparatos tecnológicos e os seres humanos

ainda demandam tempo para que o usuário aprenda a manusear novas tecnologias, e essa forma de manuseio influencia como o usuário realiza determinada atividade. Portanto, os dispositivos tecnológicos ainda determinam como diversas atividades são executadas, e fazem com que o usuário necessite se adequar ao modo como os dispositivos operam.

Devido a estas dificuldades, o termo Computação Pervasiva é melhor adequado para referir-se a “uma visão de computação futura onde o poder computacional estará disponível em qualquer lugar [...]” (AUGUSTIN, 2004). Assim, uma variedade de dispositivos móveis e estáticos reagem ao ambiente e coordenam-se entre si para auxiliar o usuário na realização de tarefas. Portanto, um ambiente pervasivo é mais próximo das tecnologias atuais e possibilita aplicabilidade imediata, uma vez que existem diversos dispositivos e sensores de baixo custo disponíveis no mercado que atendem a essa definição formal.

A Computação Pervasiva é caracterizada por um ambiente saturado com capacidade de computação e de comunicação integradas com as atividades do usuário (SATYANARAYANAN, 2001), permitindo de forma transparente suportar a execução destas. Para atingir este objetivo, é necessário que os sistemas acessem os dados do contexto em que as entidades são inseridas. Um sistema que utiliza informações de contexto para agir e reagir à modificações do ambiente de forma transparente ao usuário é chamado de Sistema Sensível ao Contexto (SCHILIT; ADAMS; WANT, 1994).

## **2.2 Computação Sensível ao Contexto**

Segundo Bauldauf et al. (2007), sistemas sensíveis ao contexto são aqueles capazes de “adaptarem suas operações ao contexto atual sem a intervenção explícita do usuário e, portanto, visam aumentar a usabilidade e eficácia, tendo em conta o contexto ambiental”. Para tanto, esses sistemas devem definir um atributo de contexto para fornecer os serviços personalizados. O atributo de contexto mais utilizado para isso é a localização, mas diversas abordagens tem utilizado outros atributos, principalmente atributos ambientais. Em razão da falta de uniformização de quais atributos definem o contexto, muitos pesquisadores tentaram encontrar sua própria definição.

A primeira definição de contexto, proposta por Schilit e Theimer (1994), descreve o contexto como a localização, as identidades de pessoas próximas, objetos e alterações a esses objetos. Entretanto, este tipo de definição pode limitar o que é uma aplicação sensível ao contexto devido a definição explícita dos atores. Já Brown (1996) propõe uma definição

abrangente, que define contexto como os elementos do ambiente do usuário que o computador conhece. Esta definição é coerente, mas sofre com falta de expressividade, pois não fornece informação suficiente para determinar, por exemplo, quais entidades compõem um sistema sensível ao contexto, e não limita o escopo de análise das informações contextuais, que nesta definição, pode ser qualquer informação. Outra definição, bastante utilizada por pesquisadores da área, é a provida por Abowd et al. (1999), que define contexto como

qualquer informação que possa ser usada para caracterizar a situação de uma entidade. Uma entidade é uma pessoa, lugar ou objeto que é considerado relevante para a interação entre um usuário e uma aplicação, incluindo o usuário e a aplicação.

A definição proposta por Abowd et al. (1999) é abrangente suficiente para englobar diversas entidades, mas ao mesmo tempo limita o escopo de análise à entidades consideradas “relevantes para a interação entre um usuário e uma aplicação”, limitando a análise do contexto ao domínio da aplicação em questão.

É importante deixar claro que não somente aspectos externos aos sujeitos devem ser analisados, mas também aspectos internos, como o aspecto emocional do usuário. Rantanen e Levinthal (2005) afirmam que mudanças no desempenho de tarefas são derivadas de sobrecarga mental, e que essa sobrecarga mental possui uma relação negativa com o desempenho de uma tarefa, ou seja, o estado interno do usuário influencia diretamente as atividades que este executa e como as executa. Gustavsen (2002) classifica contexto em duas dimensões distintas: externa e interna. A dimensão externa faz referência a informações contextuais que podem ser capturadas por sensores, por exemplo, temperatura, umidade, pressão do ar, entre outros. Já a dimensão interna é especificada pelo usuário ou inferida através do monitoramento das interações do usuário, isto é, dos seus objetivos, tarefas, estado emocional, dentre outros.

Da mesma forma que Gustavsen (2002), Nardi et al. (1996) afirmam que o contexto é externo, envolvendo artefatos e outras pessoas, e interno, envolvendo objetos e objetivos específicos. De fato, o contexto não pode ser entendido como um simples conjunto de fatores externos, visto que as habilidades e escolhas das pessoas são “resultado de processos históricos e específicos de desenvolvimento em que uma pessoa é alterada” e que “a relação específica entre pessoas e artefatos, consubstanciado na noção de Teoria da Atividade, está no centro de qualquer definição de contexto, ou atividade” (GUSTAVSEN, 2002). Assim, a Teoria da Atividade (explicada em detalhes na Seção 2.5) propõe que a atividade em si é parte do contexto, e que o contexto é construído através da realização de uma atividade que envolve pessoas e artefatos, pois os sujeitos, consciente e deliberadamente, geram contextos (atividades), em parte,

através de seus próprios objetivos.

Portanto, existem diversas formas de caracterizar contexto, e diversas definições que variam conforme o campo de estudo. Conforme Mostefaoui et al. (2004), o contexto tem fundamentações em diversas áreas, como literatura, filosofia, linguística, e é bastante intuitivo, podendo ser utilizado por diversas áreas conforme o interesse. Para este trabalho, utiliza-se a definição de Abowd et al. (1999), conjuntamente com a definição da Teoria da Atividade, onde as ações realizadas pelos sujeitos são parte integrante do contexto, e desencadeiam mudanças contextuais (esse processo é melhor explicado na seção 2.4).

### 2.3 Classificação de Modelos de Contexto

Strang e Linnhoff-Popien (2004) classificam modelos de contexto em seis categorias diferentes de acordo com as estruturas de dados que são usadas para a troca de informação contextual:

- **Modelos chave-valor:** estrutura de dados mais simples encontrada. Foi utilizada por Schilit et al. (1994) nos primeiros sistemas sensíveis ao contexto. Neste modelo, cada atributo de contexto representa uma chave, que contém valores associados;
- **Modelos de esquema de marcação:** estrutura de dados hierárquica composta por rótulos de marcação contendo atributos e conteúdo. A maioria das abordagens utilizam arquivos XML (*eXtensible Markup Language*) para troca de dados entre as entidades do sistema. Tanto este modelo, quanto modelos chave-valor, são bastante utilizados em *frameworks*, onde os serviços são descritos normalmente como uma lista de atributos chave-valor;
- **Modelos Gráficos:** utilizam técnicas de modelagem gráfica para modelar o contexto. Um exemplo é a modelagem UML (*Unified Modeling Language*), que possui diagramas gráficos de modelagem apropriados para modelar o contexto. Esse tipo de modelo de contexto é especialmente útil para arquiteturas de gerenciamento de contexto baseadas em modelos entidade-relacionamento;
- **Modelos orientados a objetos:** tem por objetivo empregar os principais benefícios de abordagens orientadas à objetos, ou seja, reusabilidade e encapsulamento. Assim, os detalhes do processamento do contexto são encapsulados e os acessos as informações de contexto acontecem através de interfaces apropriadas;

- **Modelos baseados em lógica:** neste tipo de modelo, o contexto é definido como fatos, expressões e regras. Assim, informações contextuais são adicionadas, atualizadas ou deletadas de acordo com fatos, ou inferidas das regras presentes no sistema. Comum a sistemas baseados em regras, esse tipo de modelo possui um alto grau de formalismo. Ao mesmo tempo, o sistema deve encontrar uma forma de aprender novas regras, para que as atuais não fiquem defasadas;
- **Modelos baseados em ontologia:** o objetivo central desses modelos é projetar o contexto utilizando conceitos e inter-relações naturais dos seres humanos em estruturas de dados processáveis por computadores.

Através da análise de Strang e Linnhoff-Popien (2004), em modelos chave-valor não existem esquemas ou definições de intervalo disponível a ser verificado para um atributo, tornando a avaliação parcial uma tarefa difícil. Entretanto, entende-se que esses limiares são definidos dependendo do domínio de aplicação a ser utilizado. Por exemplo, para a construção de uma aplicação de *healthcare*, é possível consultar estudos da área médica que já definiram diversos limiares do que é considerado um valor normal para determinadas patologias. Ademais, o próprio conceito de contexto implica em sistemas adaptativos, que justamente personalizam limiares de acordo com o usuário. Strang e Linnhoff-Popien (2004), discorrem que os modelos baseados em pares chave-valor são vantajosos do ponto de vista da simplicidade na perspectiva de gestão de risco e erro, e que a aplicabilidade para ambientes ubíquos existentes é um ponto forte deste tipo de abordagem de modelagem de contexto, razões pelas quais serão utilizadas neste trabalho.

## 2.4 Hiperespaço Análogo ao Contexto (HAC)

Uma vez que este trabalho utiliza a definição de contexto de Abowd et al. (1999), conjuntamente com a Teoria da Atividade, é de interesse capturar as mudanças de contexto causadas, visto que, no paradigma da Teoria da Atividade, uma ação do usuário provoca mudanças no contexto. Portanto, optou-se por utilizar o modelo de contexto denominado Hiperespaço Análogo ao Contexto (*Hyperspace Analogue to Context – HAC*) (RASCH, 2013), um modelo de contexto do tipo chave-valor, que define diversas operações matemáticas para lidar com o contexto. Em específico, permite analisar, dentre diversas dimensões, quais as que sofrem mudanças no decorrer do tempo. Esse requisito é essencial para a proposta deste trabalho.

O modelo HAC utiliza múltiplas dimensões para caracterizar o contexto, com valores que podem variar entre limiares pré-definidos. Assim, se um valor estiver fora do limiar para um atributo de contexto, uma ação pode ser tomada. Isso pode ser realizado devido à sintaxe bem definida e as operações que permitem lidar com os dados de contexto. É importante deixar claro que o HAC define a sintaxe dos dados, ou seja, um modelo de contexto, e como recuperar esses dados. Entretanto, é função da arquitetura que o utiliza, determinar as ações a serem realizadas se determinado valor for encontrado.

A principal vantagem do modelo para este trabalho é a possibilidade de capturar as mudanças de contexto ocasionadas por uma ação. Dessa forma, é possível armazenar os registros das mudanças de contexto para cada ação executada por um usuário, e com base nessas mudanças e no histórico do usuário, determinar se o contexto resultante é um contexto de risco para o perfil do usuário.

Um exemplo de funcionamento do modelo HAC é apresentado na Figura 2.1. Nela, é apresentado um contexto que representa o contexto atual do usuário, e uma mudança de contexto. O contexto do usuário é representado através de pares chave-valor, da seguinte forma:  $c^{usuario} = \{location : kitchen, kitchen\_window : closed, kitchen\_blinds : open, radio : ch2, outside\_temp : -14, kitchen\_temp : 22\}$ . No exemplo apresentado na Figura 2.1, o usuário desliga o rádio, que estava no canal (*ch2*). A mudança de contexto para esta ação é, portanto,  $\Delta c = \{radio : off\}$ , gerando o novo contexto  $c^{usuario'} = \{location : kitchen, kitchen\_window : closed, kitchen\_blinds : open, \mathbf{radio:off}, outside\_temp : -14, kitchen\_temp : 22\}$ . Simular estas mudanças de contexto permite analisar cenários que ainda não aconteceram, no intuito de prever probabilisticamente se uma determinada ação levará o usuário para uma situação de risco de acordo com o contexto  $c^{usuario'}$  gerado.

Este trabalho utiliza as mudanças de contexto para inferir se determinada alteração de um atributo de contexto pode causar uma mudança de contexto futura que é prejudicial ao usuário, ou seja, se uma mudança de contexto o coloca em uma situação de risco.

## 2.5 Teoria da Atividade

A base da Teoria da Atividade está disposta em artigos escritos por Vygotski (VYGOTSKY, 1980) e Leont'ev (LEONT'EV, 1974) (LEONT'EV, 1978). Como o próprio nome diz, na Teoria da Atividade, a unidade de análise é a atividade. Para melhor compreender o que é uma atividade e sua relação com o usuário e o ambiente, o presente trabalho utiliza a

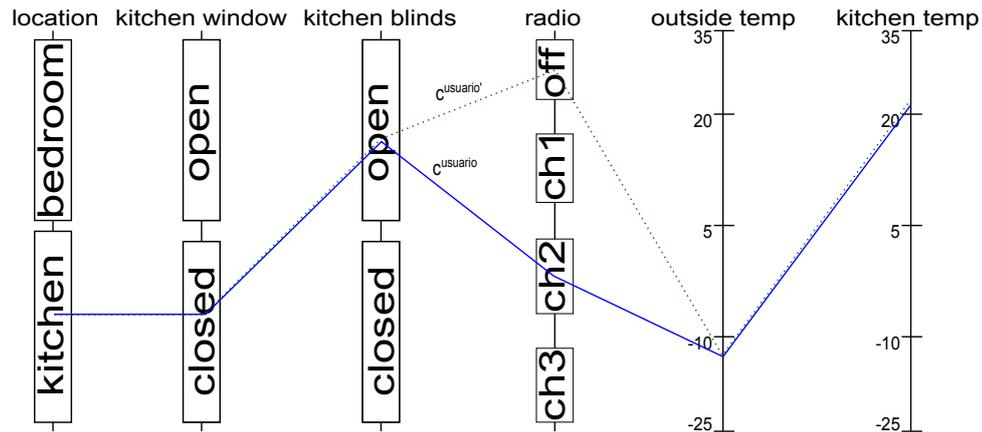


Figura 2.1 – Contexto atual do usuário ( $c^{usuario}$ ) e contexto gerado a partir de ação ( $c^{usuario'}$ )  
 Fonte: Adaptado de Rasch (2013).

abordagem descrita por Kuutti (1996) para representar o relacionamento entre os componentes da Teoria da Atividade. Na Teoria da Atividade, uma atividade é composta por ações, que são unidade atômicas, ou seja, não podem ser divididas em mais ações. Por exemplo, a atividade *tomar banho* pode ser decomposta em diversas ações, como: retirar as roupas no banheiro, entrar na banheira, ligar o chuveiro, etc. É importante notar que ações podem ocorrer de forma concorrente e intercalada, o que permite a detecção de múltiplas atividades concorrentemente.

A noção básica da Teoria da Atividade é de que o sujeito está participando em uma atividade porque ele quer atingir um objetivo específico. O seu interesse está centrado sobre o objeto de uma atividade que ele quer utilizar e/ou modificar a fim de alcançar um resultado esperado. A interação entre o sujeito e o objeto é mediado por artefatos, ou ferramentas. Dessa forma, um triângulo básico de sujeito, objeto e mediação por artefatos é criado, e apresentado na Figura 2.2.

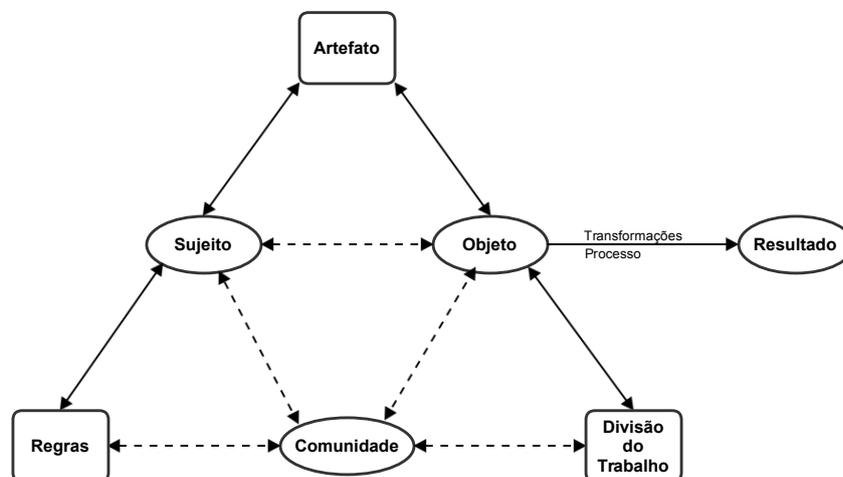


Figura 2.2 – Teoria da Atividade Histórico-Cultural (TAHC). Fonte: Adaptado de Kuutti (1996).

Embora o modelo da Teoria da Atividade permita o reconhecimento de atividades, ele não contempla todos os componentes que influenciam esse reconhecimento. O sujeito também possui contextos sociais e culturais que devem ser levados em consideração na mediação com a comunidade em que ele está inserido. Por esse motivo, a Teoria da Atividade Histórico Cultural (TAHC – *Cultural Historical Activity Theory*), apresentada na Figura 2.2, abrange a componente comunidade mediada por regras e divisão do trabalho. Essas duas abordagens complementares (AT e TAHC) já foram utilizadas para modelar o contexto e avaliar situações em ambientes pervasivos (KOFOD-PETERSEN; CASSENS, 2006). Os resultados mostraram-se promissores na modelagem geral das atividades e situações, e na identificação de tarefas interligadas a situações, artefatos e fontes de informação.

### 2.5.1 Teoria da Atividade e o Reconhecimento de Atividade

Em razão da dificuldade de representar os conceitos da Teoria da Atividade computacionalmente, a taxonomia de contexto proposta e apresentada na Figura 2.3, proporciona uma visão pragmática da construção dos artefatos e incorpora aos sistemas sensíveis ao contexto os conceitos gerais da Teoria da Atividade e da Teoria da Atividade Histórico-Cultural (MIKALSEN; KOFOD-PETERSEN, 2004). Dessa forma, os componentes da TAHC podem ser relacionados com a taxonomia de conhecimento contextual, como apresentado na Tabela 2.1.

Tabela 2.1 – Aspectos básicos de uma atividade e o seu relacionamento com a Taxonomia de Conhecimento Contextual: Fonte: Adaptado de Kofod-Petersen e Cassens (2006).

<b>Aspecto TAHC</b>	<b>Categoria</b>
Sujeito	Contexto Pessoal
Objetivo	Contexto Tarefa
Comunidade	Contexto Espaço-Temporal
Mediação de Artefatos	Contexto Ambiental
Mediação de Regras de Mediação	Contexto Tarefa
Mediação de Divisão de Trabalho	Contexto Social

A literatura dispõe de variadas teorias para modelagem de contexto. Dentre elas estão os Modelos de Ação Situados (*Situated Action Models*) (LAVE, 1988) e a Cognição Distribuída (*Distributed Cognition*) (FLOR; HUTCHINS, 1991). Embora os modelos tenham méritos, Nardi et al. (1996) demonstrou que a Teoria da Atividade é o *framework* mais robusto para estudos de contexto em termos de compreensão e engajamento de questões difíceis sobre consciência, intencionalidade e histórico. Uma vez que a arquitetura utilizada no *Activity Pro-*

*ject* (ver seção 4 para entender o funcionamento da arquitetura) incorpora diretamente atributos mentais, optou-se pela utilização da Teoria da Atividade para modelagem contextual, juntamente com o modelo HAC, para captura e operação sobre os dados do contexto e as mudanças de contexto.

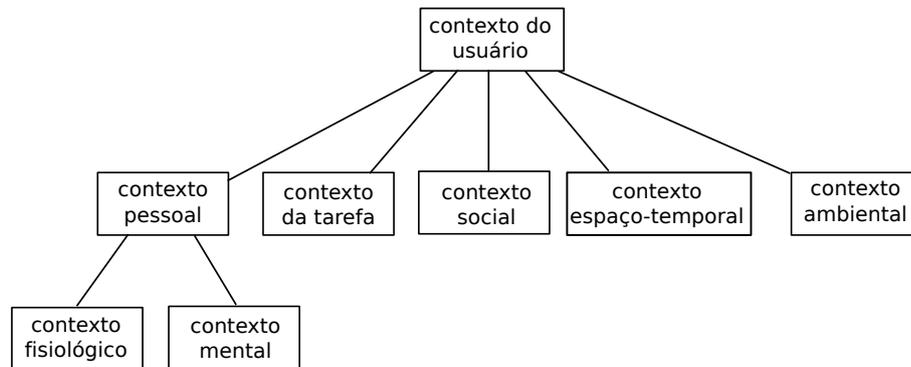


Figura 2.3 – Taxonomia de Contexto. Fonte: Adaptado de Mikalsen e Koffod-Petersen (2004).

### 2.5.2 Reconhecimento de Atividades Humanas

O fornecimento de informações precisas sobre as atividades e o comportamento das pessoas pode ser de grande importância na Computação Pervasiva. Um exemplo é a utilização no processo de tomada de decisão, que pode ser personalizada para cada indivíduo ou para um grupo de indivíduos, ou para fornecer informações contextualizadas, ou para agir proativamente, dentre outras possibilidades. De fato, atualmente o reconhecimento de atividades tem se tornado de grande interesse, não só para a comunidade acadêmica, mas para o setor empresarial. Comercialmente, a Google incorporou ao sistema operacional Android uma biblioteca capaz de reconhecer atividades realizadas pelo usuário<sup>1</sup>, e mais recentemente, utilizou essa biblioteca na criação de uma API (*Application Program Interface*) para monitorar dados de ginástica, o Google Fit<sup>2</sup>, demonstrando a aplicabilidade real do reconhecimento de atividades.

Reconhecer atividades humanas e comportamentos tem sido um importante tópico em sistemas pervasivos. O reconhecimento de atividades humanas pretende observar ações relacionadas com o intuito de obter um entendimento de que tipo de atividade ou rotina os sujeitos observados realizam em um determinado intervalo de tempo (YURUR; LIU; MORENO, 2014). Fornecer informações precisas sobre dados históricos relevantes de reconhecimento de atividades humanas pode ajudar indivíduos a terem um melhor conhecimento da situação (JOVANOV;

<sup>1</sup> <http://developer.android.com/training/location/activity-recognition.html>

<sup>2</sup> <https://developers.google.com/fit/>

MILENKOVIC, 2011).

Lara e Labrador (2013) apresentam um extensivo estudo sobre o reconhecimento de atividades humanas, desde princípios de projeto de sistemas até métodos de avaliação. O presente trabalho utiliza os conceitos apresentados pelos autores na escolha das técnicas utilizadas para o desenvolvimento da proposta, uma vez que os autores apresentam uma metodologia para a avaliação de sistemas de reconhecimento de atividades humanas.

Segundo Lara e Labrador (2013), diversos atributos de contexto tem sido levados em consideração para reconhecer atividades e diversas técnicas são empregadas. Para os autores, devido às questões de privacidade, pervasividade e complexidade, sistemas baseados em sensores vestíveis são mais adequados do que sistemas baseados em análise de imagens. Neste sentido, os autores relatam que a maioria dos sensores utilizados são para medir atributos relacionados ao movimento do usuário (por exemplo, acelerômetro e GPS), variáveis do ambiente (por exemplo, temperatura e umidade), ou sinais fisiológicos (frequência cardíaca e eletrocardiograma).

Lara e Labrador (2013) ainda propõem uma classificação em grupos de atividades humanas baseados nos principais trabalhos da literatura. A Tabela 2.2 apresenta a classificação proposta.

Tabela 2.2 – Grupos de atividades em Sistemas de Reconhecimento de Atividades Humanas. Fonte: Adaptado de Lara e Labrador (2013).

<b>Grupo</b>	<b>Atividades</b>
Locomoção	Caminhar, correr, sentar, deitar, subir ou descer escadas.
Transporte	Dirigir ônibus, ciclismo, dirigir carro.
Uso de Telefone	Mensagem de texto, chamada telefônica.
Atividades Diárias	Comer, beber, trabalhar no computador, assistir TV, ler.
Exercício/Ginástica	Remo, levantamento de peso, caminhada nórdica.
Militar	Rastejar, ajoelhar, abrir porta.
Parte Superior do Corpo	Mastigação, fala, mover a cabeça.

Sistemas de reconhecimento de atividades, geralmente, requerem duas fases distintas, isto é, uma fase de treinamento e uma fase de avaliação ou teste (LARA; LABRADOR, 2013). A fase de treinamento requer um conjunto de dados (*dataset*) de séries temporais dos atributos utilizados para cada sujeito que realiza uma atividade. Os dados brutos são divididos em janelas de tempo para processar a extração de características (*feature extraction*) e filtrar informações relevantes. Após isso, métodos de aprendizagem são utilizados para gerar um modelo de reconhecimento de atividade baseado no *dataset* resultante do processo de extração de característi-

cas. Na fase de avaliação, os dados são coletados durante uma janela de tempo para permitir a extração de características. O resultado desse processamento é avaliado sob a perspectiva do modelo treinado anteriormente, gerando um identificador para a atividade desempenhada. Portanto, a precisão na detecção de uma atividade está diretamente relacionada à qualidade do modelo treinado. A Figura 2.4 sumariza os componentes envolvidos neste processo.

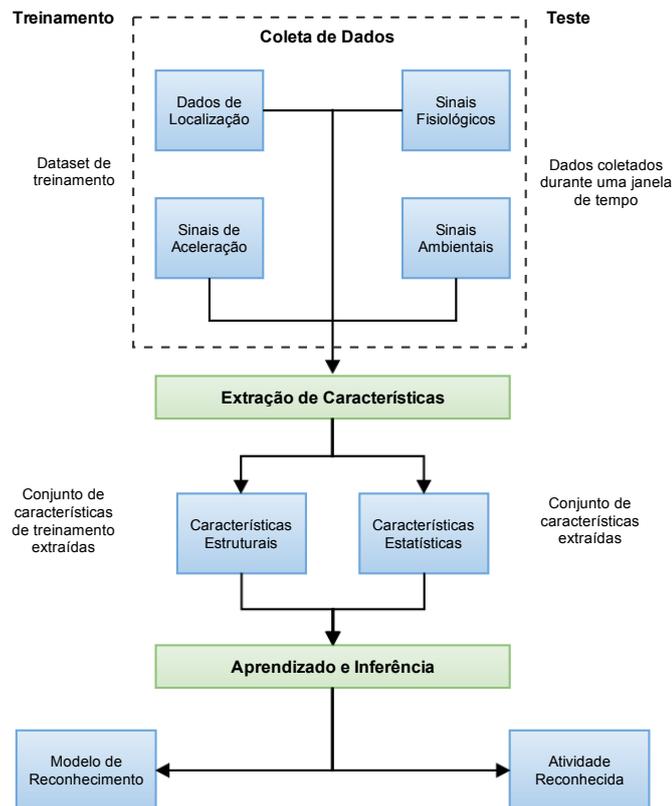


Figura 2.4 – Fluxo de Dados para fase de treinamento e teste em sistemas de RAH. Fonte: Adaptado de Lara e Labrador (2013).

Formalmente, a extração de características pode ser classificada em duas categorias: estatística e estrutural. Os métodos estatísticos utilizam características quantitativas dos dados para extrair características, enquanto os métodos estruturais baseiam-se na inter-relação entre os dados.

A técnica a ser utilizada no processo de extração varia de acordo com a classificação do atributo em questão. Lara e Labrador (2013) classificam os atributos e sensores em quatro tipos: atributos ambientais (temperatura, humidade, nível de áudio, etc), aceleração (acelerômetros triaxiais, não exaustivo), localização (GPS, não exaustivo) e sinais fisiológicos (frequência cardíaca, frequência respiratória, temperatura da pele, ECG, etc.). Para tratar dados de atributos de aceleração são comumente utilizados métodos como: média aritmética, média quadrática

(*Root Mean Square* – RMS), desvio padrão, variância, desvio absoluto médio (*Mean Absolute Deviation*). Para a extração de atributos ambientais como altitude, humidade e temperatura, é aconselhável a análise no domínio do tempo, enquanto que para luz e pressão barométrica, ambos os domínios, tempo e frequência, são utilizados. Já para os sinais fisiológicos, mais precisamente os sinais vitais, os autores classificaram quatro tipos de funções (linear, polinomial, exponencial e senoidal), sendo a função polinomial a que melhor descreve sinais fisiológicos como frequência cardíaca, frequência respiratória, entre outros.

Para o processo de reconhecimento de atividade, uma abordagem possível são as técnicas de aprendizagem de máquina (*machine learning*) para a construção dos padrões a serem descritos. Existem diversas técnicas que podem ser utilizadas, como árvores de decisão, métodos bayesianos, redes neurais e máquina de suporte de vetores (*Support Vector Machines* – SVM), entre outras.

### 2.5.3 Composição das atividades

Para modelar contextualmente uma atividade, o presente trabalho utiliza a Teoria da Atividade, um conceito bastante abstrato da psicologia, que foi incorporado aos sistemas computacionais através da adoção da Taxonomia de Conhecimento Contextual (KOFOD-PETERSEN; CASSENS, 2006). Para a Teoria da Atividade, uma atividade é composta de uma ou mais ações realizadas por um usuário. Entretanto, a forma com que essas ações são relacionadas e compostas computacionalmente não é definida.

Portanto, para a modelagem do ponto de vista sistêmico, é necessário definir por quais ações uma atividade é composta, e como essas ações se relacionam entre si. Por exemplo, é necessário saber se determinada atividade necessita que as ações que a compõe devem ser executadas em uma certa ordem, ou se podem ser executadas independentemente. Neste sentido, Naeem et al. (2007) propuseram um modelo hierárquico de atividades para ADLs, que permite decompor as ADLs (*Activity of Daily Living*) em diferentes modelos, compostos por tarefas simples, como “ligar a luz”, ou complexas como “café da manhã”. Baseado neste modelo, o presente trabalho propôs um sistema de detecção de atividades bastante semelhante, utilizando a ideia de planos hierárquicos de atividades, bem como a ideia de ordem de execução. Uma vez que esse modelo atende aos requisitos teóricos dispostos na Teoria da Atividade, ele será utilizado para descrever a composição das atividades em ações, bem como o relacionamento entre elas.

A modelagem hierárquica proposta pelos autores é baseada nas atividades diárias dos indivíduos, mas pode ser estendida para qualquer sistema que defina uma atividade como uma composição de ações. No modelo hierárquico proposto por Naeem et al. (2007), o nível mais baixo da hierarquia das ADLs consiste dos componentes responsáveis pela captura dos eventos de sensores dentro de casa. O segundo nível é a identificação de tarefas ou ações. O processo de identificação de tarefas mapeia cada evento do sensor disponível no ambiente para as tarefas possíveis que são associados com o evento do sensor. Por exemplo, o sensor “açucareiro” pode ser associado as seguintes tarefas: “fazer o café” ou “fazer o chá”.

Nos níveis mais elevados existem objetivos e subobjetivos da pessoa que está sendo monitorada. Cada (sub) objetivo corresponde a uma ADL, de modo que a atividade ou tarefa que compõe a atividade pode ser pensada como um objetivo de menor nível. O número de níveis acima do nível de identificação da tarefa (associação dos sensores a uma tarefa específica) depende da complexidade da atividade. Desta forma, as ADLs podem ser aninhadas dentro de outras ADLs, e atividades podem ser compostas de tarefas e subatividades.

As ADLs podem ocorrer em paralelo com outras ADLs ou ter outras restrições temporais. Para tanto, elas são elaboradas em uma linguagem de representação de planos hierárquica, denominada Asbru (MIKSCH; SHAHAR; JOHNSON, 1997), específica de tarefas e orientada a intenção, inicialmente projetada para modelar diretrizes clínicas. Na linguagem Asbru, uma ADL pode ser classificada como obrigatória ou opcional. Se uma ADL possui ações classificadas como obrigatórias, estas ações devem ser executadas antes da ADL ser rotulada como executada. Se for opcional, então a ação não precisa ser necessariamente executada para uma atividade ser reconhecida.

Além disso, subobjetivos podem ser ordenados de muitas maneiras. As mais comuns são sequenciais (em ordem rigorosa), paralelo (executadas simultaneamente), em qualquer ordem (mas apenas um subobjetivo pode ser executado em um momento) e não ordenado (executado sem sincronização). A Figura 2.5 apresenta um exemplo da modelagem da atividade “Tomar Café da Manhã”, onde é possível notar a composição da ADL por diversas subatividades, que por sua vez são compostas de ações. Por último, cabe ressaltar os atributos de ordem e obrigatoriedade relacionados a cada subatividade que compõe uma ADL. Dessa forma, fica intuitivo decidir quando uma atividade foi detectada, e principalmente, como ela é composta e a forma com que é executada pelo usuário.

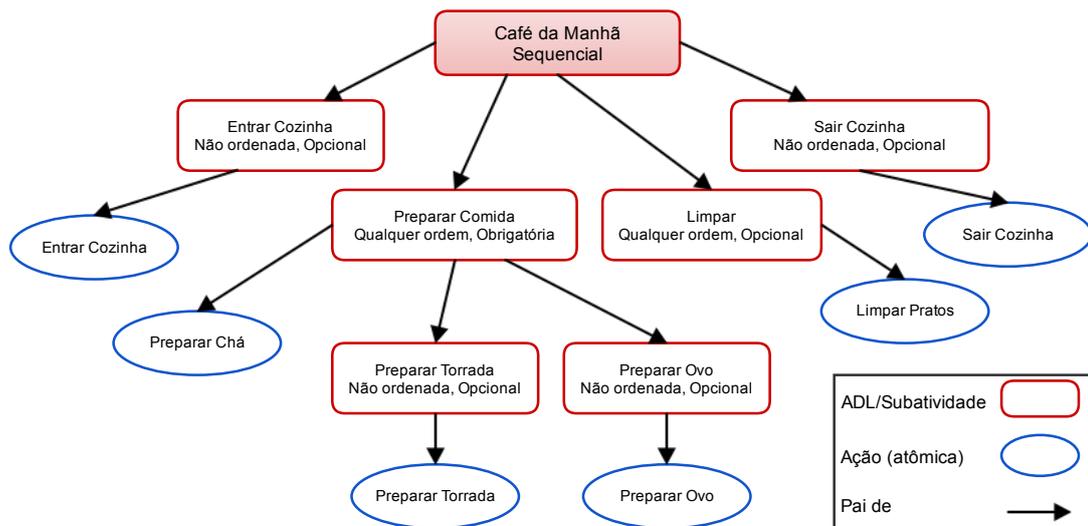


Figura 2.5 – Exemplo da modelagem de uma ADL. Fonte: Adaptado de Naeem et al. (2007).

## 2.6 Situation Awareness

Endsley (1995), define Consciência da Situação (*Situation Awareness*) como

a percepção dos elementos no ambiente dentro de um volume de espaço e tempo, a compreensão dos seus significados, e a projeção dos seus estados em um futuro próximo.

O modelo de Endsley (1995) possui três camadas: percepção, compreensão e projeção. A camada percepção reconhece toda a informação necessária sobre o meio ambiente. A camada compreensão interpreta a informação percebida, a fim de compreender o estado atual do ambiente. A camada de projeção usa o conhecimento do estado atual do ambiente para prever o seu futuro Estado.

Para Feng et al. (2009), Consciência da Situação e Consciência do Contexto são conceitos complementares. Enquanto a Consciência da Situação foca na modelagem do ambiente do usuário para ajudá-lo a estar ciente da situação atual, Consciência do Contexto é sobre explorar o contexto de um usuário e ajudar o usuário a ter uma maior interação com o sistema, de forma a ativamente mudar o comportamento do sistema de acordo com o contexto ou situação atual (FENG; TENG; TAN, 2009).

Neste sentido, Kofod-Petersen et al. (2009) propõem uma arquitetura Consciente da Situação, onde na camada de percepção (correspondente ao modelo de Endsley), o contexto descreve a informação que é perceptível no mundo, chamados de Contexto Situacional. Conforme Nwiabu et al. (2011), a Consciência da Situação pode utilizar o contexto do usuário para fornecer a informação relevante sobre o ambiente no processo de raciocínio.

## 2.7 Gerência de Risco

A gerência de risco em si é uma área ampla, e envolve diversos aspectos, como avaliação do risco, controle do risco, identificação, análise, priorização, mapeamento, resolução, dentre diversos outros fatores (RASMUSSEN, 1997). Trata-se de uma área bastante complexa, onde diversos modelos foram criados baseadas nas demandas de diversas áreas do conhecimento. Portanto, é importante situar quais aspectos o presente trabalho irá abordar.

Um recente *framework* proposto para gerência de situações de risco é o SPIDER (*Scanning, Predicting, Identifying, Deciding, Executing, Response*) (FISHER; STRAYER, 2014). O *framework* SPIDER delimita diversos processos necessários para detectar e prevenir uma situação de risco, adequando-se a proposta deste trabalho, e portanto, torna-se útil para situacionar quais processos de gerência de risco o presente trabalho aborda.

O objetivo do SPIDER é gerenciar o risco de acidentes automobilísticos de acordo com a situação do motorista. Para tanto, a Consciência da Situação do motorista é utilizada para refletir o modelo mental dinâmico do ambiente de condução e a dependência dos processos psicológicos deste.

Os autores definem diversos processos para o gerenciamento de risco, que envolvem a Varredura (*Scanning*) do ambiente de condução, Prevendo (*Predicting*) e antecipando riscos, a Identificação (*Identifying*) de perigos potenciais à medida que ocorrem, a Decisão (*Deciding*) sobre uma ação e a Execução (*Executing*) de uma Resposta (*Response*) apropriada (SPIDER). Assim, o presente trabalho trata somente das fases de Varredura, Identificação e Previsão, ou Predição, de situações de risco, delegando às aplicações que utilizam o *middleware* proposto neste trabalho a Decisão, Execução e Resposta às situações de risco.

O processo de varredura refere-se à capacidade de captura das informações contextuais do ambiente, alcançadas através de sensores e redes de sensores sem fio que interagem entre si. Essas informações contextuais são usadas por componentes que utilizam técnicas capazes de reconhecer padrões de dados (por exemplo, reconhecer atividades) e identificar perigos potenciais. Para o reconhecimento destes perigos potenciais é necessário que estes sistemas sejam capazes de prever estes riscos, de forma a evitar que eles aconteçam. No contexto deste trabalho, é necessário prever as atividades realizadas por um usuário, e assim inferir se esta atividade pode ou não causar algum tipo de risco para o usuário.

### 3 TRABALHOS RELACIONADOS

O reconhecimento de atividades tem se tornado uma característica importante em ambientes inteligentes, à medida que permite capturar aspectos relacionados ao comportamento do usuário para detectar situações de emergência e prevenir danos. Isto permite aos sistemas adotarem uma abordagem pró-ativa para evitar que os usuários sejam expostos a situações de risco, que podem envolver diversos fatores, internos e externos aos usuários, como por exemplo, variações dos atributos ambientais (temperatura, chuva, vento, etc), o próprio desempenho do usuário para realizar uma atividade (voltar a caminhar após uma operação), comportamentos arriscados (caminhar a noite com as luzes apagadas), dentre outros. Em suma, existem situações de risco relacionadas com diversos atributos de contexto, e diversas abordagens existentes na literatura lidam com este problema.

#### 3.1 Método de comparação

Lara e Labrador (2013) definiram uma série de critérios comparativos para sistemas de reconhecimento de atividades humanas. Uma vez que sistemas de detecção de risco estão diretamente relacionados ao reconhecimento de atividades, e os trabalhos apresentados neste seção são referentes a ADLs ou similares, estes mesmos critérios foram utilizadas para comparar as propostas analisadas neste capítulo. Cada um dos critérios são apresentados a seguir:

- **Atividades:** representa o grupo de atividade que cada proposta aborda. Neste caso, as propostas apresentadas são agrupadas em atividades diárias (DA), como comer, beber e assistir TV, e de locomoção (AMB), como caminhar, correr e sentar;
- **Sensores:** apresenta os tipos de sensores que foram utilizados no cenário em questão. São exemplos, sensores de movimento, acelerômetros (ACC), vídeo, entre outros;
- **Intrusividade:** representa o grau de intrusividade da abordagem proposta, que pode ser baixo, médio ou alto. Um grau de intrusividade é classificado como baixo quando o não causa modificações na forma como os usuários executam determinada atividade, ou, quando não expõe o usuário a situações constrangedoras (por exemplo, câmeras que filmam a intimidade do usuário). Esse nível de intrusividade caracteriza-se por dispositivos que estão comumente com o usuário, por vontade própria deste, e em diversos ambientes

sociais, ou seja, já estão incorporados ao comportamento do indivíduo. Um nível de intrusividade é considerado médio quando o dispositivo utilizado para realizar a captura de dados não está incorporado a vida diária do indivíduo. Esses equipamentos não impactam de forma drástica na forma de executar uma atividade, e requerem apenas algumas adequações por parte do indivíduo, ou adequações nos equipamentos que o indivíduo utiliza. Exemplos são sensores colocados em equipamentos de proteção individual, que necessitam com que o trabalhador modifique sensivelmente a sua forma de realizar uma atividade. Por último, um grau de intrusividade alto é caracterizado por sensores que modificam drasticamente a forma de realização de uma atividade, ou que, afetam questões relacionadas a privacidade do usuário. São exemplos clássicos, aqueles baseados em câmeras que efetuam monitoramento de atividades;

- **ID:** refere-se ao dispositivo onde os dados foram agregados, sendo que PC refere-se a um dispositivo central, e Nodo refere-se a um elemento de uma rede de sensores sem fio.
- **Experimento:** faz referência ao local e procedimento a que a abordagem proposta foi submetida. LAB refere-se a testes em laboratórios, que podem ser em ambientes simulados, por exemplo um *software* específico para simulação, e em ambiente real, ou seja, com a utilização de sensores em ambiente controlado. NAT refere-se a testes em ambientes naturalísticos, ou seja, com a presença de usuários reais que utilizaram o sistema sem a ajuda ou controle comumente utilizados em ambientes controlados (por exemplo, informar o usuário como uma atividade deve ser realizada);
- **Flexibilidade:** refere-se ao projeto dos sistemas para reconhecimento de atividade. Basicamente, os autores classificam-nos em monolíticos (MNL), isto é, um modelo flexível o suficiente para contemplar diferentes usuários, ou específico do usuário (SPC), onde o modelo é treinado e testado com os dados do usuário que utilizará o sistema;
- **Extração:** refere-se aos domínios que podem ser utilizados para a extração de características dos dados dos sensores. Isso pode ser feito no domínio do tempo (TD), com técnicas como média, desvio padrão, variância, dentre outros, ou no domínio da frequência (FD), através da Transformada de Fourier ou Transformada Discreta de Cosseno;
- **Aprendizagem:** é referente as técnicas utilizadas para os algoritmos de detecção de atividades. Técnicas baseadas em Regras referem-se àquelas cujos dados são comparados a

regras que determinam se esses dados satisfazem determinada assinatura de uma regra. Já as técnicas identificadas como SMA utilizam o método estatístico SMA (*Signal Magnitude Area*) para detectar atividades. As técnicas baseadas em gramática utilizam alguma forma de gramática para definir como uma atividade deve ser detectada. Por último, alguns trabalhos podem utilizar a técnica de FP-Tree para detectar atividades;

- **Precisão:** é a métrica padrão mais utilizada para medir o desempenho geral de propostas para o reconhecimento de atividade e detecção de situações de risco. A precisão é calculada de acordo com a Equação 3.1, onde: TP (*true positive*) refere-se as emergências que foram detectadas corretamente; TN (*true negative*) refere-se as situações que, corretamente, não foram detectadas como emergência; FP (*false positive*) refere-se as situações normais que foram erroneamente detectadas como de emergência; e, FN (*false negative*), que refere-se as situações de emergência não detectadas.

$$Precisão = \frac{TP + TN}{TP + TN + FP + FN} \quad (3.1)$$

### 3.2 Abordagens utilizadas na predição de ações e atividades

Um aspecto bastante importante na detecção de situações de risco é a capacidade de detectá-las antes que ocorram. Desta forma, técnicas de predição de ações e atividades devem ser empregadas para permitir que sistemas possam tomar as medidas adequadas para evitar danos ao usuário.

Gil-Quijano e Sabouret (2010) apresentam uma proposta para predição de atividades domésticas em uma casa inteligente. O objetivo dos autores é prever as atividades executadas para adaptar o comportamento de aplicações da casa do usuário, a fim de corrigir o comportamento dos aparelhos da casa e preparar os cômodos para receber as pessoas em condições mais confortáveis.

A proposta de predição de atividades baseia-se na construção de um grafo para cada ocupante a partir da análise estatística das atividades executadas pelo ocupante. Os nós do grafo representam as tarefas, enquanto que as arestas representam a sequência de execução entre duas tarefas. Cada aresta possui uma probabilidade de execução da sequência. Esta probabilidade é calculada como a razão entre o número de vezes que a sequência foi realizada pelo ocupante e o número de vezes que o ocupante realizou a tarefa inicial na mesma aresta. Como cada tarefa

é realizada num dado ambiente, usando o grafo de atividade, os autores conseguem prever o próximo deslocamento no grafo a partir da tarefa atual.

Fatima et al. (2013) também apresentam um modelo para predição de ações. A ideia básica é prever a próxima ação a partir do conjunto de atividades que ocorrem em conjunto. Para o processo de aprendizagem de previsão ação, os dados necessários são extraídos do padrão de comportamento do usuário na execução rotineira de suas ações. Este padrão compreende a identificação do conjunto de ações que ocorrem frequentemente juntas. Na abordagem proposta, os autores consideram sequências de 8 a 10 atividades para prever a ação seguinte, através do algoritmo *Conditional Random Fields* (CRF), um modelo probabilístico discriminativo e generativo para identificar as sequências através da probabilidade condicional. A Tabela 3.1 apresenta o resultado comparativo dessas duas propostas.

Tabela 3.1 – Comparação entre propostas para inferência de ações e atividades. Fonte: Adaptado de Lara e Labrador (2013).

<b>Crítérios</b>	(GIL-QUIJANO; SABOURET, 2010)	(FATIMA et al., 2013)
<b>Atividades</b>	DA	DA
<b>Sensores</b>	Temp., switch e movimento	Temp., switch e movimento
<b>Intrusividade</b>	baixo	baixo
<b>ID</b>	PC	PC
<b>Experimento</b>	LAB(real)	LAB(real)
<b>Flexibilidade</b>	SPC	SPC
<b>Extração</b>	TD	TD
<b>Aprendizagem</b>	Grafos	CRF
<b>Precisão</b>	61,28%	73,44%

É possível notar que as propostas utilizam critérios bastante semelhantes, sendo que as únicas diferenças são as técnicas de aprendizagem adotadas, bem como o *dataset*. Nesse caso, a proposta de Fatima et al. (2013) obteve uma precisão superior. A diferença é que a técnica de CRF adotada por Fatima et al. (2013) considera os padrões de execução das dez últimas ações anteriormente executadas pelo usuário para cada ação atual em análise, enquanto o algoritmo de grafos considera a porcentagem de execução de cada ação baseada na ação atual.

Já a presente dissertação também adota uma abordagem de predição baseada na análise de padrões frequentes encontrados no histórico do usuário para determinar a próxima ação. A principal diferença é o algoritmo empregado, que considera uma janela variável para busca de padrões frequentes para cada ação executada. Dessa forma, o algoritmo busca no histórico do usuário todos os padrões que aconteceram dentro de uma janela pré-definida, e determina a próxima ação baseada no padrão com maior número de ocorrências.

### 3.3 Abordagens utilizadas na detecção de situações de risco

Dalal et al. (2005) propuseram um dos primeiros trabalhos sobre detecção de emergência em atividades cotidianas (*Activity of Daily Living – ADL*). A proposta dos autores permite a detecção de anomalias baseada na análise dos padrões dos dados e a detecção de possíveis condições de emergência. Para tanto, os autores utilizam uma abordagem de classificação baseada em regras. Os dados dos sensores são enviados para um servidor que executa os algoritmos para detecção de condições de emergência e para detecção de atividades.

A análise de condições de emergência são realizadas através de regras do tipo IF A AND/OR B THEN C, de forma que todas as condições de emergência devem ser cadastradas. Além disso, o sistema somente detecta que uma situação de emergência aconteceu, mas não permite antever essa situação. Os testes realizados pelos autores consideram a análise de determinadas atividades (usar o banheiro, tomar banho, número de vezes de acordar e dormir, e refeições) para detectar os padrões de comportamento e avaliar os indivíduos com base no desvio do comportamento padrão semanal do usuário. Ou seja, o sistema analisa se o usuário realizou atividades diferentes em determinado dia da semana. Os autores conseguiram identificar quatro quedas, mas não informaram parâmetros de precisão para dar condições de comparar o modelo.

Curone et al. (2010) propuseram um sistema de classificação de situações de emergência, como bombeiros e socorristas da Defesa Civil. Os operadores são equipados com dois sensores nas roupas de proteção, um acelerômetro e um sensor ECG (eletrocardiograma). O sistema é composto por um classificador capaz de reconhecer diversos estados do usuário que correspondem a diversas atividades cotidianas, em tempo real. O classificador recebe como parâmetros cinco características extraídas dos sensores: frequência cardíaca média do operador, variação da frequência cardíaca ao longo do último minuto de atividade, inclinação do tronco, intensidade do movimento e frequência do passo. Os dados são processados a cada cinco segundos localmente, e enviados a uma estação remota responsável por executar o algoritmo e classificar o estado do usuário.

O classificador atribui estes sinais para nove classes de diferenciação entre certas atividades físicas (caminhada, corrida, movendo-se no local), intensidades (intensos, suaves, ou em repouso) e posturas (deitado, em pé). Dessa forma, combinações dessas classes são ou não identificadas como perigosas (por exemplo, "sujeito imóvel deitado" pode ser identificado como

situação perigosa). O classificador classifica as atividades do operador em: posição vertical, tronco ou braços em movimento, andar, caminhada intensa, correr, movimentos estacionários intensos (por exemplo, levantamento de peso), descansando depois de intensos movimentos, deitado imóvel e movendo-se deitado. Essas atividades foram mapeadas para contemplar diversas situações que socorristas podem enfrentar durante um salvamento. Testes foram conduzidos em laboratório, e o sistema apresentado obteve cerca de 88,8% de precisão na classificação das atividades.

Mocanu e Florea (2011) desenvolveram um modelo para reconhecimento de ADLs e detecção de emergências. A detecção de emergências é realizada através de uma gramática livre de contexto com o auxílio de ontologia para modelar atividades. Os autores consideram quatro tipos de emergências e as classificam em: emergência de duração, para atividades com uma duração maior que a usual; emergência de contexto, para atividades que são realizadas em um lugar considerado errado; emergência de horário incomum, para atividades que são realizadas em um horário divergente do normal; emergência de ordem não natural, para atividades que são realizadas em uma ordem não comum para o sujeito sendo monitorado.

Para detectar se uma emergência ocorre, os quatro atributos (duração, local, hora do dia, ordem de atividades) são comparados com um programa diário que cada usuário possui. Esse programa descreve todas as atividades que o usuário normalmente realiza. Qualquer diferença entre o que está sendo executado e o que está no programa diário gera uma emergência. Os autores utilizaram um ambiente simulado para as atividades ler, assistir TV e lanchar e simularam as emergências de contexto, duração e horário do dia. As métricas utilizadas para detecção de emergências foram a precisão e robustez do modelo, com valores de 91,75% e 95,65%, respectivamente.

Wang et al. (2014) propõe uma abordagem distribuída que emprega os recursos de computação e armazenamento de nós de sensores espalhados pelo ambiente para detectar a atividade anormal em ambientes inteligentes equipados com redes de sensores sem fio. No trabalho, uma atividade é definida como a combinação de trajetória e duração, e uma atividade anormal é definida como a atividade que desvia suficientemente das atividades normais.

Para detectar se uma atividade é normal ou anormal, primeiramente, os padrões normais de atividades são extraídos a partir dos dados originais e introduz os algoritmos de compressão para reduzir o número de padrões de atividade mineradas. Em segundo lugar, ele armazena os padrões extraídos em cada nó de acordo com o mecanismo de armazenamento. O presente

trabalho não tem por interesse analisar mecanismos de armazenamento, de forma que é necessário somente compreender que, para detectar anormalidades, os padrões de atividades normais precisam ser armazenados nos diversos nós. Por último, a detecção da atividade anormal é realizada utilizando o algoritmo de detecção distribuído.

Para a detecção de atividades anormais, é necessário determinar o comportamento normal do indivíduo. Os autores utilizam a técnica de mineração de padrões frequentes para mineração os padrões de atividades normais, considerando a duração e a trajetória. Assim, se a frequência de um conjunto de itens, que é uma atividade neste caso, exceder o limite mínimo definido, é uma atividade normal. Caso contrário, a atividade será detectada como anormal. Em um ambiente simulador por *software*, também de autoria de Wang et al. (2014), a precisão foi de 96,2%. Para testes em ambiente real, o valor de precisão não foi fornecido pelos autores.

O resultado da comparação dos trabalhos apresentados para detectar situações de risco é apresentado na Tabela 3.2. Ao analisar a tabela, é possível notar que a proposta de Wang et al. (2014) é a única a considerar um ambiente distribuído para determinar situações de risco. As demais propostas efetuam todo o processamento de forma centralizada. Quanto a intrusividade, a proposta de Mocanu e Florea (2011) é a única considerada alta, pois utiliza sensores de vídeo para a detecção de situações de risco, o que pode causar desconforto por parte dos usuários. A proposta de Curone et al. (2010) é considerada média, pois utiliza alguns sensores de monitoramento acopladas em um *smartphone*, e as propostas de Dalal et al. (2005) e de Wang et al. (2014) são consideradas baixas, uma vez que utilizam dados de sensores acoplados no ambiente e que não possuem relação com o usuário.

As propostas de Curone et al. (2010) e Mocanu e Florea (2011) utilizam métodos de extração no domínio do tempo e frequência, enquanto que a proposta de Dalal et al. (2005) e a proposta de Wang et al. (2014) utilizam apenas métodos de extração no domínio do tempo. Quanto a flexibilidade, todas as propostas são específicas para o usuário do sistema. Em contraponto, cada um dos trabalhos utilizam técnicas diferentes de aprendizagem.

Por último, é possível observar que o trabalho de Wang et al. (2014) obteve o melhor resultado de precisão na detecção de situações de risco. Os autores conseguiram detectar 96,2% das emergências para atividades diárias, utilizando apenas sensores de movimento. Entretanto, por considerar apenas a trajetória e a duração das atividades, não é possível determinar o estado do usuário enquanto realiza determinada atividade. Neste sentido, somente a proposta de Mocanu e Florea (2011) é capaz de detectar emergências considerando os sinais vitais dos usuários,

Tabela 3.2 – Comparação entre propostas para detecção de situações de risco. Fonte: Adaptado de Lara e Labrador (2013).

<b>Crítérios</b>	(DALAL et al., 2005)	(CURONE et al., 2010)	(MOCANU; FLOREA, 2011)	(WANG et al., 2014)
<b>Atividades</b>	DA	AMB	DA	DA
<b>Sensores</b>	Temp., switch e movimento	ACC, ECG	Video	movimento
<b>Intrusividade</b>	baixo	medio	alto	baixo
<b>ID</b>	PC	PC	PC	Nodo
<b>Experimento</b>	NAT	LAB(real)	LAB (sim.)	LAB (sim.,real)
<b>Flexibilidade</b>	SPC	SPC	SPC	SPC
<b>Extração</b>	TD	TD e FD	TD e FD	TD
<b>Aprendizagem</b>	Regras	SMA	Gramática	FP-Tree
<b>Precisão</b>	–	88,8%	91,75%	96,2%

ou seja, se os mesmos sofrem alguma alteração significativa.

De fato, considerar as condições fisiológicas pertinentes a cada indivíduo são importantes no momento de detectar uma situação de emergência, pois dessa forma, pode-se considerar as aptidões de cada usuário e como o usuário reagiu a mudanças no ambiente. Da mesma forma que Mocanu e Florea (2011), esta dissertação utiliza o contexto fisiológico para detectar se o usuário está em situação de risco. Entretanto, as propostas anteriores somente realizam a detecção de situações de risco no momento exato em que elas acontecem, permitindo que os sistemas atuem somente de forma reativa, uma vez que a situação de risco já está em curso. Esta dissertação diverge das propostas anteriores para detecção de situações de risco na medida em que propõe a inferência das situações de risco, possibilitando que o sistema atue de forma pró-ativa para evitar riscos ao indivíduo.

Para tanto, é necessário prever as ações e atividades que serão executadas, e com base nas ações e atividades e no histórico de execução para cada usuário, determinar as mudanças que essas ações e atividades acarretam no contexto do usuário. Essa é outra característica que difere dos trabalhos anteriores. Uma vez que é necessário sempre atuar sobre ações e atividades futuras, é necessário também, prever o estado futuro do contexto. Combinando a predição das ações e atividades, com a predição do contexto futuro após sua execução, foi possível notar que a proposta deste trabalho obteve resultados expressivos para a detecção de situações de risco, com precisão de 98,94%, e para a predição de ações, com precisão de 78,79%. Esses resultados são apresentados em detalhes no Capítulo 6.

## 4 ACTIVITY PROJECT

Este capítulo apresenta uma breve contextualização do projeto *Activity Project*, que visa estudar as atividades desempenhadas pelos usuários em um ambiente pervasivo. Em seguida, é apresentado o *middleware* desenvolvido para detecção de situações de risco, bem como uma visão geral de cada camada que o compõe. Ao final, o fluxo de dados para detecção de situações de risco é apresentado, com o intuito de esclarecer como cada camada do modelo comunica-se com as demais.

### 4.1 Contextualização

O *Activity Project* é um projeto desenvolvido no contexto do Grupo de Sistemas de Computação Móvel (GMob), com o intuito de determinar situações de risco no momento da realização de atividades desempenhadas por pessoas em um ambiente sensível ao contexto. A concepção do sistema surgiu da ideia de aplicação em sistemas de *healthcare*, focado na detecção de quedas em pessoas idosas. Entretanto, com o decorrer das pesquisas, percebeu-se que a análise de situações de risco possui potencial de pesquisa e aplicabilidade real em diversos cenários de usos, que variam de atividades cotidianas a atividades militares e de segurança. Neste sentido, optou-se pela proposta de um *middleware* independente de domínio de aplicação, que pudesse ser utilizado para determinação de situações de risco para diversas atividades humanas.

O projeto visa estudar a atividade humana e as suas relações com o contexto, de forma a fornecer informação relevante para que diversas aplicações possam utilizar-se desses dados para fornecer serviços de precisão para o usuário, como por exemplo, serviços de recomendação, serviços de *healthcare*, dentre outros. Uma primeira abordagem conceitual foi desenvolvida e definiu-se um modelo em cinco camadas (DEL FABRO NETO et al., 2013).

### 4.2 Arquitetura proposta

A arquitetura desenvolvida para o *middleware* proposto (Figura 4.1) foi inspirada no *framework* conceitual baseado em camadas para sistemas sensíveis ao contexto proposto por Baldauf et al. (2007). O modelo de *framework* escolhido justifica-se pela separação dos componentes de sensoriamento, processamento e gerenciamento de dados contextuais de forma bem definida. Além disso, este modelo fornece as vantagens de extensibilidade e reusabilidade

dos sistemas. Portanto, o *middleware* proposto para o *Activity Project* estende a arquitetura de Baldauf et al. (2007) e incorpora o modelo da Teoria da Atividade e do modelo Habilidade, Regras e Conhecimento (*Skill, Rule & Knowledge – SRK*) para permitir a detecção de situações de risco baseada nas características do usuário, no comportamento e no desempenho deste enquanto executa atividades.

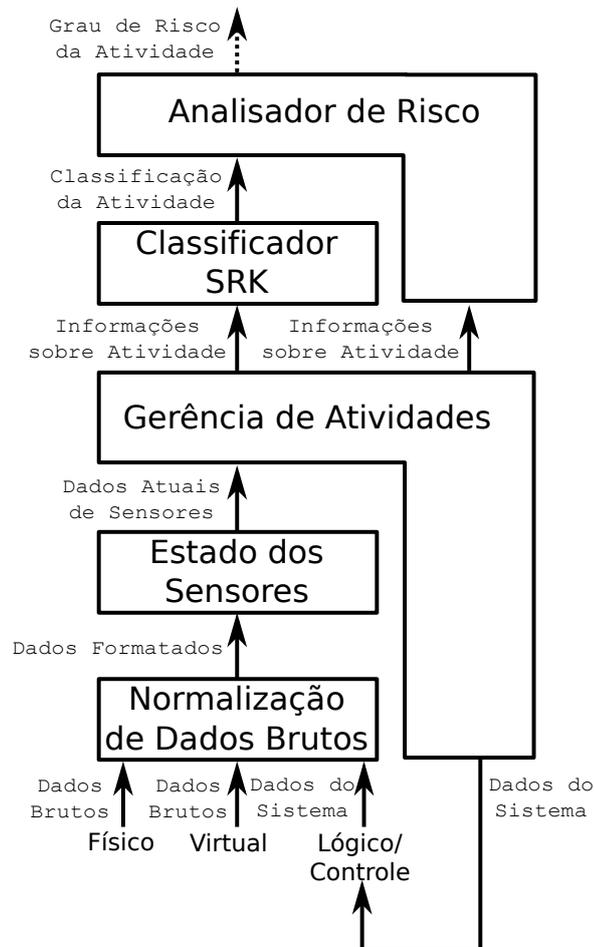


Figura 4.1 – Arquitetura do middleware para detecção de situações de risco. Fonte: do Autor.

O *middleware* apresentado na Figura 4.1 é composto de cinco camadas: *Normalização de Dados Brutos*, *Estado dos Sensores*, *Gerência de Atividades*, *Classificador SRK*, e *Analisador de Risco*. As camadas *Normalização de Dados Brutos* e *Estado dos Sensores* correspondem a camada de sensoriamento do modelo de Baldauf et al. (2007), as camadas *Gerência de Atividades* e *Classificador SRK* correspondem à de processamento, e a camada *Analisador de Risco* engloba tanto processamento, quanto gerenciamento de dados, por fazer a interconexão com clientes que utilizam o *framework*. As principais características de cada uma dessas camadas são discutidas nas próximas seções deste capítulo.

#### 4.2.1 Camadas Normalização de Dados Brutos e Estado dos Sensores

O principal objetivo da camada *Normalização de Dados Brutos* é agregar os dados brutos provenientes de diversos tipos de sensores (físicos, virtuais e lógicos), bem como formatar esses dados para algum padrão bem definido, por exemplo, o padrão *Message Queuing Telemetry Transport for Sensor Networks* (MQTT-S) (HUNKELER; TRUONG; STANFORD-CLARK, 2008) (INDULSKA et al., 2003). Esta camada obtém informação não somente de sensores físicos e virtuais, mas também de sensores lógicos, que são alimentados pelo próprio sistema. Portanto, o sistema pode incorporar informações que já passaram por algum processo de classificação ou semântica de camadas superiores. A agregação de informações de contextos já processadas permite ao sistema realizar análises mais precisas sobre os dados.

A camada *Estado dos Sensores* obtém os dados dos sensores formatados e armazena-os para prover para as camadas superiores as últimas mudanças relevantes nos valores de cada sensor de forma padronizada. Para tanto, cada atividade do sistema busca por eventos de mudança de valores de sensores, o qual é desencadeado quando um ou mais valores de sensores modificarem seu estado. A fim de reduzir a quantidade de eventos desencadeados, uma vez que um sensor pode mudar o seu estado com uma pequena variação nos valores e de forma muito frequente (por exemplo, sensores de temperatura), o sistema pode definir uma porcentagem mínima necessária de mudanças no estado de cada sensor para um evento ser acionado.

#### 4.2.2 Camada Gerência de Atividades

A camada *Gerência de Atividades* possui duas funções principais: detectar ações e atividades, e associar a cada uma das ações uma situação de risco que a represente. O processo de detecção de ações acontece através de técnicas de classificação de aprendizagem de máquina. Já a detecção de atividades ocorre através baseada no modelo da Teoria da Atividade, apresentado no Capítulo 2, ou seja, se determinado conjunto de ações for executado. Como o objetivo do *middleware* é detectar situações de risco, as ações e atividades são também inferidas, baseadas em um modelo de predição de ações. Por isso, além da detecção da atividade que realmente ocorreu, o modelo realiza uma inferência da provável próxima ação ou atividade a ser executada, de forma que o sistema atue antes que um dano possa ser causado ao usuário do sistema.

A segunda funcionalidade refere-se à associação de uma situação de risco a uma ação.

A cada uma das ações cadastradas no sistema, a camada *Gerência de Atividades* é responsável por associar uma situação de risco baseada no contexto de tarefa e no contexto fisiológico do usuário, conforme a taxonomia de contexto proposta por Mikalsen et al. (2004). Essas informações serão enviadas a camada *Analisador de Risco*, que fará a inferência da situação final de risco baseada conjuntamente nos dados de desempenho do usuário, provenientes da camada *Classificador SRK*. Como a camada *Gerência de Atividades* é o foco desta dissertação, ela será explicada detalhadamente no Capítulo 5.

#### 4.2.3 Camada Classificador SRK

A camada *Classificador SRK* é responsável por determinar o desempenho do usuário enquanto executa uma atividade. O desempenho é determinado através da classificação da atividade em uma habilidade, regra ou conhecimento, baseada no trabalho proposto por Rasmussen (1983), da seguinte forma:

- Habilidade: atividades que o ator desenvolve rotineiramente sem atenção ou controle consciente, como andar com muletas;
- Regras: atividades que necessitam de atenção ou controle consciente, como desviar de um buraco enquanto caminha com muletas;
- Conhecimento: atividades em que todas as opções para tentar resolver uma tarefa através de rotinas baseadas em habilidades e regras não são possíveis, não aplicáveis ou não funcionam. Um exemplo de atividade classificada como conhecimento é a primeira tentativa de caminhar com muletas.

O *framework* SRK permite classificar o desempenho do sujeito enquanto realiza uma atividade. Essa classificação leva em consideração o contexto mental do usuário, como nível de atenção, *stress*, carga cognitiva empregada, dentre outros. Ademais, ele permite mapear o comportamento do sujeito, uma vez que uma atividade classificada como Habilidade pode ser reclassificada como Regra, e vice-versa, dependendo do desempenho do usuário no decorrer do tempo. A análise realizada por esta camada utiliza dados históricos da camada *Gerência de Atividades* e seus próprios dados históricos para determinar a qual classificação uma atividade pertence. Essa classificação depende de diversos atributos mentais, da frequência de realização, e duração de uma atividade. Uma vez que não é o foco do presente trabalho, o funcionamento

desta camada é descrito superficialmente, apenas para possibilitar ao leitor o entendimento geral do *middleware* desenvolvido para o *Activity Project*.

#### 4.2.4 Camada Analisador de Risco

Por último, a camada *Analisador de Risco* recebe a atividade classificada pelo *classificador SRK* e determina a situação final de risco levando em consideração as situações de risco identificadas pelo *Gerência de Atividades* (contexto fisiológico e de tarefa), conjuntamente com o desempenho do usuário (contexto mental) enquanto realiza uma atividade. Essa camada relaciona os dois atributos resultantes das duas camadas para identificar uma situação de risco. Isso é necessário, pois, por exemplo, uma ação que sempre foi executada pelo usuário e identificada como situação rotineira pelo *Gerência de Atividades*, pode ser uma situação de risco se o nível de atenção do usuário identificado pelo *Classificador SRK* for baixo. Portanto, essas regras de associação devem ser realizadas por essa camada.

#### 4.2.5 Fluxo de dados

O fluxo de dados do *middleware* é sumarizado a seguir (Figura 4.1):

- O sistema recebe os dados brutos de diversos sensores (físicos, virtuais e lógicos);
- Os dados são agregados, uma vez que podem vir de diferentes fontes;
- Os dados formatados mais recentes provenientes dos sensores são mantidos na camada *Estado dos Sensores*, que pode ser consultada pela camada *Gerência de Atividades*;
- A camada *Gerência de Atividades* solicita os dados atuais dos sensores para reconhecer uma ação e então prever se a próxima ação a ser executada será ou não uma situação de risco.
- A camada *Gerência de Atividades* solicita a ação atual para detectar uma atividade;
- A camada *Classificador SRK* recebe a atividade detectada e classifica-a de acordo com o sujeito;
- Por último, a camada *Analisador de Risco* recebe a classificação proveniente do *Classificador SRK* para a atividade sendo analisada e associa com a situação desta atividade

determinada pela camada *Gerência de Atividades* para inferir a situação de risco final da atividade.

Dessa forma, a contribuição do *middleware* está nas camadas superiores, que permitem associar situações a cada uma das ações e atividades, bem como considerar o desempenho do sujeito que está realizando essas ações. Essas duas características são importantes pois consideram a aptidão do sujeito para realizar uma atividade com base no histórico desta, no contexto fisiológico, mental e ambiental. Assim, é possível realizar inferências precisas sobre situações de risco que estão envolvidas na execução de atividades humanas.

## 5 MODELO PARA INFERÊNCIA DE SITUAÇÕES DE RISCO EM AÇÕES

Este capítulo tem por objetivo apresentar em detalhes aspectos da camada *Gerência de Atividades*. Primeiramente, é apresentado o modelo utilizado para estruturar as ações realizadas por um usuário, o qual será utilizado para inferir de forma probabilística situações de risco em ações e atividades futuras. Em seguida, o capítulo apresenta o processo para associar uma situação de risco a cada uma das ações, de forma a permitir inferir o risco de ações futuras. Por último, o processo de detecção de atividades é explicado e as considerações finais sobre a camada são apresentadas.

### 5.1 A camada Gerência de Atividades

A camada *Gerência de Atividades* (apresentada na Figura 4.1) é responsável pela detecção de ações, atividades e por associar uma situação de risco a cada uma das ações. Entretanto, mais do que detectar ações e atividades, a camada *Gerência de Atividades* objetiva inferir quais serão as ações e atividades futuras executadas por um usuário, pois desta forma o *middleware* pode prever situações de risco e evitar danos aos usuários.

Para tanto, a camada *Gerência de Atividades* recebe os dados agregados da camada *Estado dos Sensores*, e fornece a próxima atividade a ser executada (*Atividade Inferida*) à camada *Classificador SRK*, bem como o risco fisiológico associado a cada ação que compõe essa atividade à camada *Analisador de Risco*. A Figura 5.1 apresenta a arquitetura geral da camada *Gerência de Atividades*. Destaca-se que a camada *Gerência de Atividades* é responsável somente pelo contexto fisiológico do usuário, enquanto a camada *Classificador SRK* é responsável pelo contexto mental. Dessa forma, é a camada *Analisador de Risco* que irá combinar os riscos mentais e fisiológicos.

Como discutido no Capítulo 2, e endossado pela Teoria da Atividade, as atividades são compostas de ações, e constituem papel importante na detecção do comportamento humano. Com o intuito de definir o padrão de comportamento de cada usuário, optou-se por utilizar as ações realizadas pelo usuário como unidade básica de avaliação do comportamento. Portanto, após receber os dados agregados da camada *Estado dos Sensores*, o primeiro passo é reconhecer a ação que está sendo executada. Para tanto, é necessário realizar o processo de *Extração de Características*, para que seja possível retirar ruídos e relacionar os dados de forma mais clara, e

aplicar um algoritmo (*Alg. Aprendizagem de Máquina*) para realizar o reconhecimento de ações (módulo de *Reconhecimento de Ação*). A partir da ação detectada, e com base no histórico de ações e atividades realizados pelo usuário (seu comportamento normal), a próxima etapa é inferir qual será a próxima ação executada (*Alg. Inferência da Próxima Ação*).

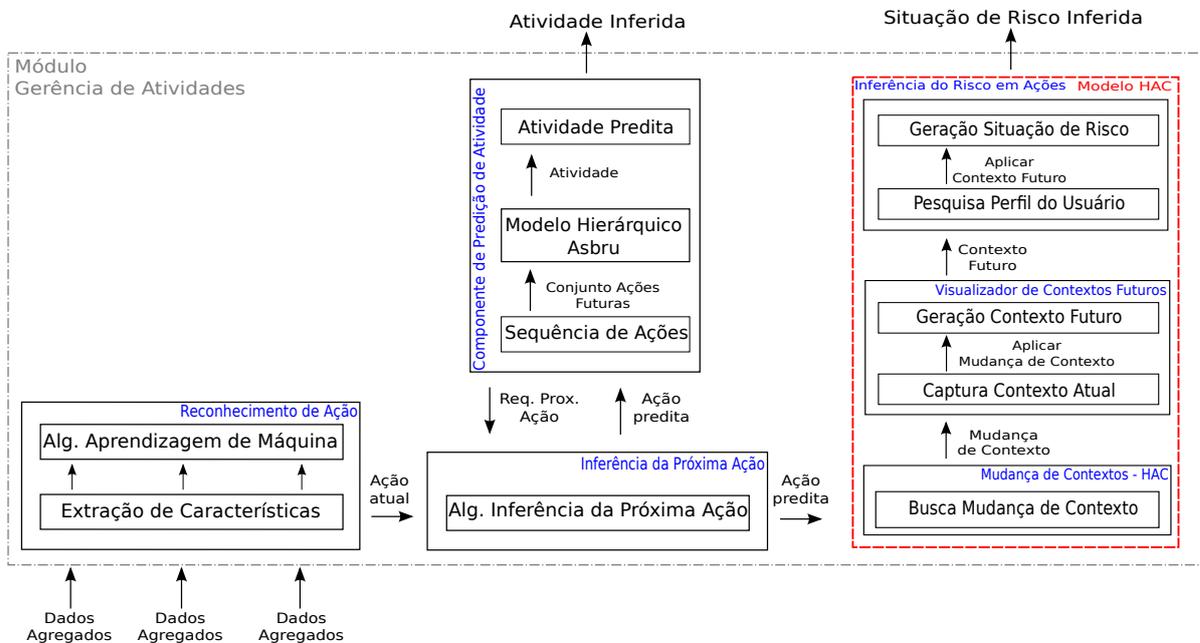


Figura 5.1 – Arquitetura da camada Gerência de Atividades. Fonte: do Autor.

Após a próxima ação ser detectada, dois processos distintos são iniciados. Primeiramente, o *Componente de Predição de Atividade* recebe a provável próxima ação e assume que essa ação de fato ocorreu, e solicita ao componente de *Inferência da Próxima Ação* que lhe envie uma nova próxima ação tomando como ação atual a próxima ação detectada anteriormente. Dessa forma, o *Componente de Predição de Atividade* repete esse processo até que uma *Sequência de Ações* seja reconhecida, ou seja, que uma *Atividade Predita* seja reconhecida de acordo com o *Modelo Hierárquico Asbru*. Para tornar esse processo claro, imagine que o componente *Reconhecimento de Ação* detectou a ação atual  $a_1$ , e o componente *Inferência da Próxima Ação* detectou que a provável próxima ação a ser executada pelo usuário é a ação  $a_2$ . O que o *Componente de Predição de Atividade* faz é solicitar ao componente *Inferência da Próxima Ação* que ele calcule a próxima ação provável tendo como ação atual base a ação  $a_2$ . O processo utilizado para realizar essa inferência é explicado na seção 5.1.2.

Além disso, um segundo processo é iniciado. O sub-sistema de *Inferência do Risco em Ações* associa uma situação de risco a cada ação inferida, com base nas mudanças de contexto e nos contextos gerados por essas mudanças. Assim, o sistema efetua uma busca de mudanças de

contexto já ocorridas para a ação predita (*Busca Mudança de Contexto*), e aplica essa *Mudança de Contexto* capturada no contexto atual para gerar um *Contexto Futuro* (módulos *Captura Contexto Atual* e *Geração Contexto Futuro*). Com o *Contexto Futuro* gerado, é realizada uma consulta ao perfil do usuário (*Pesquisa Perfil do Usuário*) para determinar se os valores dos atributos de contexto para o *Contexto Futuro* gerado estão dentro dos limites definidos como normais para o usuário. O módulo *Geração Situação de Risco*, com base nas informações de limites e no contexto gerado, determina se o usuário provavelmente estará ou não em uma situação de risco.

### 5.1.1 Reconhecimento de ações

A camada *Estado dos Sensores* fornece os dados agregados de cada tipo de sensor à camada *Gerência de Atividades* para que esta possa detectar as ações e atividades, e associar situações de risco a elas. Portanto, a primeira ação a ser tomada pela camada *Gerência de Atividades* é reconhecer a ação que está sendo executada, uma vez que as ações servem como base para as demais funcionalidades da camada em questão. Esta tarefa é realizada pelo componente *Reconhecimento de Ação*, que com base em algoritmos de classificação compara os dados recebidos da camada *Estado dos Sensores*, com os dados já classificados para cada ação cadastrada no sistema. Em suma, o conjunto de dados de sensores será classificado de acordo com a similaridade que possui com os dados cadastrados para cada uma das ações.

Dernbach et al. (2012) elencaram seis algoritmos de aprendizagem de máquina para classificação baseada em dados brutos de sensores: *Multilayer Perceptron*, *Naive Bayes*, *Bayesian network*, *Decision Table*, *Best-First Tree* e *K-star*. Os autores utilizaram o WEKA<sup>3</sup> para aplicar os algoritmos sobre os dados capturados de sensores, com os parâmetros padrão associadas a cada um dos classificadores. O algoritmo que conseguiu classificar o maior número de amostras corretamente foi o *K-star*. Neste sentido, foram aplicados os mesmos algoritmos apresentados por Dernbach et al. (2012) para a classificação das ações apresentadas neste trabalho. Entretanto, é importante notar que a arquitetura não impõe a utilização de um classificador específico, e permite a escolha de qualquer classificador capaz de informar a ação executada com base nos dados dos sensores.

Como explicado no Capítulo 2, esses algoritmos não são aplicados nos dados brutos dos sensores, pois devem sofrer um processo de extração de características. Esse processo pode

<sup>3</sup> <http://www.cs.waikato.ac.nz/ml/weka/>

acontecer no domínio do tempo, no domínio da frequência ou em ambos. Conforme descrito no trabalho de Lara e Labrador (2013), os métodos para extração de características de sinais de aceleração utilizados foram os do domínio do tempo, devido ao desempenho e simplicidade de implementação em relação a métodos como Transformadas de Fourier. Os métodos escolhidos foram: a média, desvio padrão, variância, IRQ (*interquartile range*), RMS (*root mean square*), MAD (*Mean Absolute Deviation*) e correlação entre pares de eixos. O resultado para cada um dos algoritmos executados sobre esses dados será apresentado na seção 6.2.

### 5.1.2 Inferência da próxima ação do usuário

A inferência da próxima ação a ser executada pelo usuário é baseada no histórico de ações já executados por ele, uma vez que reflete o comportamento do mesmo. Para tanto, o Algoritmo 1 baseia-se na busca por padrões de ações no histórico  $H$  do usuário, ou seja, a busca de determinadas sequências de atividades com o intuito de descobrir qual a próxima ação que provavelmente será executada após esse padrão.

---

**Algoritmo 1** Algoritmo de predição de ações.

---

**Entrada:** Tamanho máximo do padrão (Max\_Pattern\_Len)  $MPL$

**Entrada:** Histórico de ações executadas  $H$

```

1:  $N_a^p \leftarrow \text{initZero}()$ 
2:  $A \leftarrow H.\text{getLastActions}(MPL)$ ;
3:  $P \leftarrow \text{getPatterns}(A)$ ;
4: para todo  $a \in A$  faça
5:   para todo  $p \in P$  faça
6:      $N_a^p \leftarrow \text{getNumOccurrences}(H, a, p)$ ;
7:   fim para
8: fim para
9:  $ap \leftarrow \text{max}(N)$ 
10: retorna  $ap$ 

```

---

Assim, o Algoritmo 1 busca a lista  $A$  das últimas  $MPL$  ações executadas pelo usuário, onde  $MPL$  é o tamanho da janela ou a quantidade de ações a serem analisadas. Na sequência, é feita uma busca pela lista de padrões  $P$  no histórico do usuário para cada uma das ações em  $A$  anteriormente encontradas. Dessa forma, o número de ocorrências de cada uma das ações  $a$ , para cada padrão  $p$  encontrado e relacionado em no máximo  $MPL$  períodos com cada ação  $a$  é atualizado em  $N_a^p$ . A maior ocorrência encontrada é a provável ação futura.

### 5.1.3 Inferência do Risco em Ações

A inferência de situações de risco está relacionada à forma como o contexto é tratado, em especial, ao contexto pessoal apresentado na taxonomia de contexto (ver Figura 2.3), uma vez que alterações, tanto no estado fisiológico quanto no estado mental do usuário, podem indicar um risco associado. A abordagem proposta neste trabalho utiliza o contexto fisiológico, conjuntamente com o contexto de tarefa (ações) para a associação de situações de risco.

Quando uma ação acarretar uma mudança significativa em um dos atributos fisiológicos do usuário, a situação de risco da atividade modifica o seu valor, que pode ser *situação de risco* ou *situação normal*. Para detectar essas mudanças no estado do usuário, diversas informações podem ser consideradas, como pressão sanguínea, temperatura do corpo, frequência cardíaca, taxa de oxigênio no sangue, etc. Quando qualquer uma dessas informações estiver fora de um limiar estabelecido como normal, o usuário estará em uma *situação de risco*.

A determinação de situações de risco em ações proposta nesse trabalho parte do pressuposto de que cada usuário possui seu próprio padrão de comportamento, à medida que as pessoas são consideradas seres de hábitos (ROCHA et al., 2010). Portanto, a abordagem utilizada visa prever a próxima ação a ser executada pelo usuário com base nos seus hábitos. Assim, as ações realizadas pelos usuários são o objeto de análise, bem como a mudança que cada uma das ações causa no contexto a cada vez que é executada. É nesse momento que o contexto de tarefa (predição de ações, ver seção 5.1.2) relaciona-se com o contexto fisiológico do usuário (mudança de contexto, HAC).

Cabe ressaltar que essa análise das mudanças de contextos acarretadas por cada ação deve ocorrer antes de uma ação ser executada pelo usuário. Isso explica a necessidade de (i) capturar o contexto atual do usuário, para então (ii) inferir qual a próxima ação a ser executada, e somente então dar início ao processo de *Inferência do Risco em Ações*, através da (iii) aplicação das mudanças de contexto decorrentes da ação inferida no contexto atual e (iv) da avaliação do contexto futuro resultante em busca de situações de risco.

Para alcançar esse objetivo, utilizou-se o modelo HAC para descoberta das mudanças de contexto (Componente Mudança de Contexto) e um componente para simular os contextos futuros (Visualizador de Contextos Futuros) decorrentes dessas mudanças (ver Figura 5.1). De posse da ação futura inferida, o Componente de Mudança de Contexto busca nos dados históricos do usuário quais as mudanças de contexto que a ação futura encontrada já causou

anteriormente, isto é, as mudanças de contexto que já aconteceram outras vezes que esta ação foi executada no passado. A mudança de contexto que cada ação causa é calculada cada vez que uma ação foi executada, através da diferença entre o contexto gerado depois que esta atividade foi executada e o contexto passado. Todas as mudanças de contextos que uma ação causou são armazenadas, e a mediana dos valores de cada estado fisiológico do usuário é calculada para determinar um valor médio de mudança de contexto que esta ação causa. Dessa forma, é possível determinar, por exemplo, quanto a taxa cardíaca é modificada pela influencia de cada uma das ações executadas.

Uma vez encontrada, o Visualizador de Contextos Futuros aplica estas mudanças de contextos ao contexto atual do usuário com o objetivo de gerar um novo contexto que representa o estado futuro do contexto caso a ação predita for executada. Assim, com o valor médio da mudança de contexto que uma ação implica em uma propriedade fisiológica, é possível verificar se o estado atual da propriedade fisiológica ficaria fora dos limiares pré-determinados como normais para o usuário se determinada ação fosse executada. Caso afirmativo, o usuário é considerado em uma *situação de risco*. Em suma, o modelo simula a execução de uma ação para determinar se o contexto resultante configura ou não uma *situação de risco*. É importante deixar claro que a verificação dos limiares de segurança para determinar se uma situação é ou não de risco é realizada no perfil do usuário, que é atualizado a cada ação executada. O perfil do usuário possui os limiares de todos os atributos fisiológicos para cada ação que pode ser detectada pelo sistema. Neste trabalho os limiares foram calculados como a média das propriedades fisiológicas subtraída e acrescida do desvio padrão para formar os limiares inferior e superior, respectivamente.

#### 5.1.3.1 Exemplo de análise de mudança de contexto

Para propósito de exemplificação, a Figura 5.2 apresenta diversas propriedades fisiológicas (estado fisiológico) para ações realizadas por um usuário. No exemplo, existem três propriedades distintas: (i) pressão sanguínea, dividida entre sistólica (s) e diastólica (d); (ii) temperatura corporal; e (iii) frequência cardíaca. As linhas referem-se ao estado fisiológico atual do usuário quando determinada ação está sendo executada.

Analisando o comportamento passado do usuário (seus hábitos), os valores de desvio padrão para a ação  $a_3$  são 0 para a pressão sanguínea sistólica (120 mm Hg para ambas ocorrências) e diastólica (80 mm Hg para ambas ocorrências), 0.42426 para temperatura corporal (36

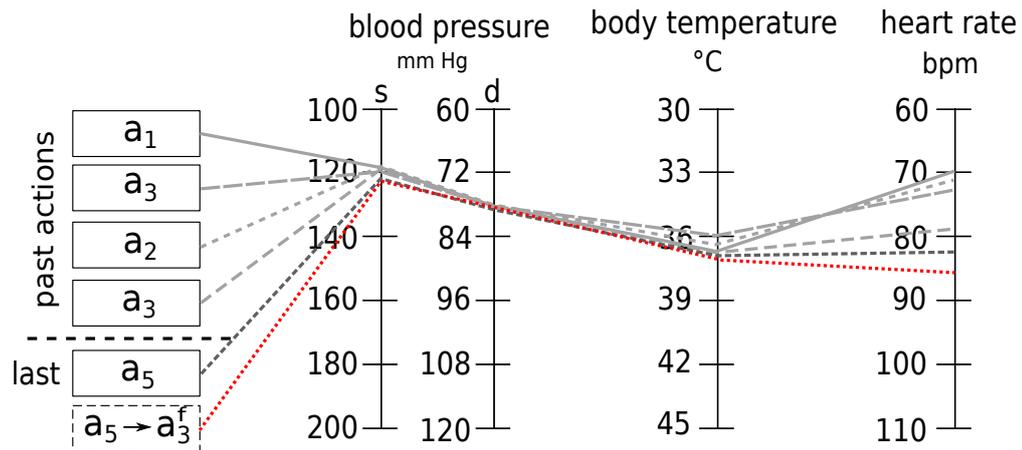


Figura 5.2 – Exemplo de mudanças no estado do usuário. Fonte: Adaptado de Rasch (2013).

°C e 36.6 °C) e 4.94975 para frequência cardíaca (72 bpm e 79 bpm). Os desvios padrão são então utilizados para a análise do impacto das ações futuras no estado fisiológico do usuário. No exemplo, esse impacto é calculado sobre a última ação realizada ( $a_5$ ) e a ação futura predita  $a_3^f$ . Considerando que os limiares pré-definidos para a frequência cardíaca do usuário são 65 bpm e 84 bpm, pode-se observar que se a ação  $a_3$  for realizada, há a possibilidade que a frequência cardíaca ultrapasse o limiar superior, caracterizando uma situação de risco.

### 5.1.3.2 Exemplo de Funcionamento do risco em ações

Para demonstrar o funcionamento geral da proposta de detecção de risco em ações, é apresentado na Figura 5.3 um cenário exemplo. No cenário, assume-se as ações *caminhar* e *correr* para o contexto de tarefa, bem como a *frequência cardíaca* para o contexto fisiológico do usuário. Neste cenário exemplo, o usuário está inicialmente realizando a ação *caminhar*, e alternará para a ação *correr*.

O primeiro passo é detectar a ação que está sendo realizada e o contexto fisiológico associado a essa ação. Neste caso, a ação detectada é *caminhar* (conforme seção 5.1.1), e o contexto fisiológico associado é o valor da frequência cardíaca, neste caso 80 bpm, capturado através do modelo HAC. De posse dessa informação, a ação atual é encaminhada ao modelo de Inferência da Próxima Ação, que como explicado na seção 5.1.2, infere que a provável próxima ação a ser executada é a ação *correr*.

A partir deste momento, o componente de Mudança de Contextos consulta dos dados históricos do usuário (perfil) em busca das mudanças de contexto relacionadas ao atributo frequência cardíaca sempre que a atividade *correr* aconteceu. Esse valor é calculado através

da mediana de todas as mudanças de contextos que já ocorreram para esta ação no histórico do usuário. Neste caso, este valor é de cerca de 23 bpm.

Essa mudança de contexto é aplicada ao contexto atual da ação *caminhar* com o intuito de simular o contexto futuro, como se o usuário tivesse executado a ação *correr*. Isso é realizado para que seja possível detectar no contexto futuro resultante, com base nas informações do perfil do usuário, se o valor obtido para a propriedade fisiológica frequência cardíaca (contexto fisiológico) está dentro dos limiares estabelecidos como normais. Os limiares normais de um usuário são calculados através da média de todos os valores da frequência cardíaca já registrados para esta atividade, acrescido e subtraído do desvio padrão desse conjunto de valores.

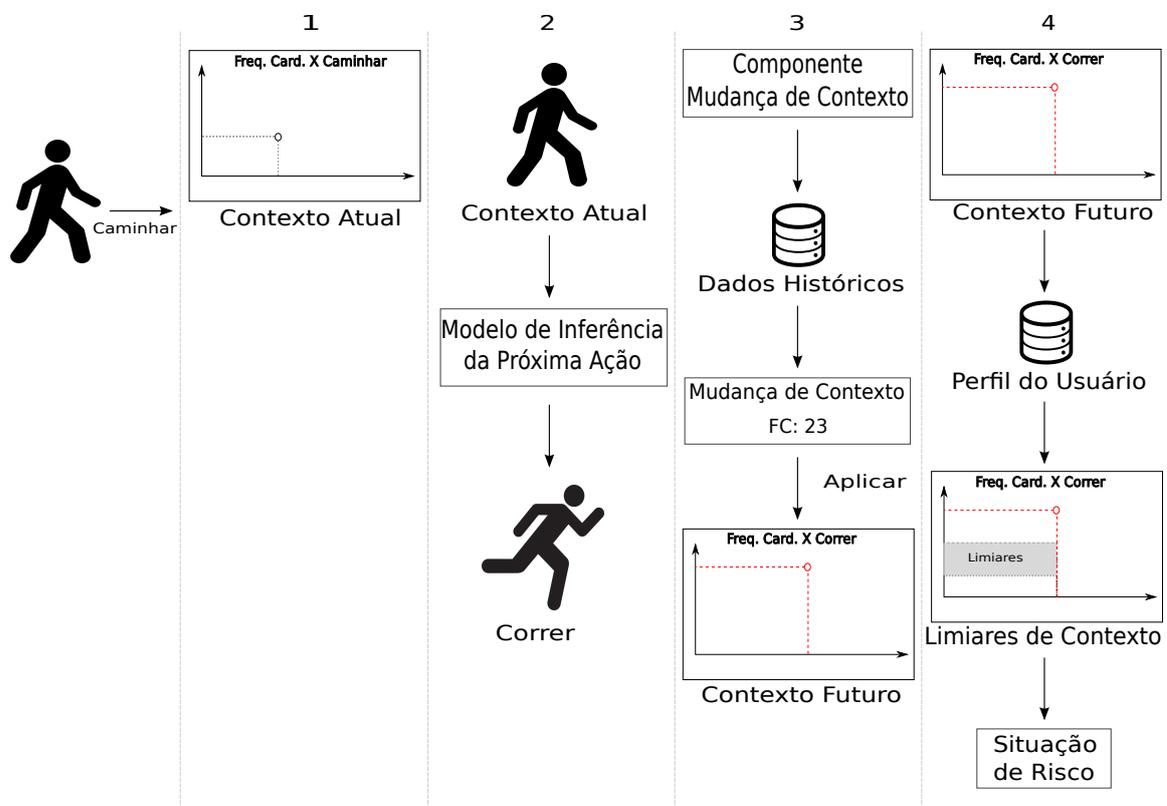


Figura 5.3 – Funcionamento da proposta de detecção de situações de risco. Fonte: do Autor.

Para o caso apresentado, os limiares são de 64, 32 e 100, 21. Aplicando a mudança de contexto de contexto de 23 ao contexto fisiológico atual de 80, obtém-se limiares de 57 e 103. Como é suficiente que qualquer um dos limiares, tanto inferior como superior, estejam fora dos valores normais, a situação detectada é uma *situação de risco*.

#### 5.1.4 Detecção e Predição de Atividade

O modelo para a detecção de atividades parte do princípio que as atividades são compostas de ações, e que o relacionamento dessas ações determinam como uma atividade acontece. Desta forma, se determinado conjunto de ações for executado em uma janela de tempo estabelecida, diz-se que uma atividade aconteceu. Para modelar as atividades cadastradas no sistemas, utilizou-se uma abordagem semelhante a de Naeem et al. (2007), a qual permite definir se ações são ou não obrigatórias, e se devem ou não ser executadas em uma ordem definida.

Com isso, dois tipos de ações são definidas: (i) ações núcleo e (ii) ações secundárias. A primeira representa as ações que são essenciais para atingir o objetivo da atividade e, portanto, são necessárias para o seu reconhecimento. A segunda diz respeito àquelas relacionadas a uma determinada atividade, mas não essenciais para o seu reconhecimento, de modo que são úteis na medida em que acrescentam significado à atividade. Para que uma atividade seja detectada, cada ação que a compõe deve ser executada em uma janela de tempo pré-definida. Assim, uma janela de tempo inicial é determinada com base no somatório das médias das durações de cada ação que compõe a atividade. Uma atividade é modelada definindo-se: (i) as ações que a compõe, (ii) se cada uma dessas ações são ações núcleo ou secundárias, e (iii) se essas ações possuem uma ordem de execução ou não. Se possuírem, deve-se informar qual a ordem.

A Figura 5.4 apresenta um exemplo de reconhecimento de atividade. No exemplo, existem três atividades (X,Y,Z) que o sistema é capaz de reconhecer: X, composta pelas ações  $a_1$  e  $a_5$ , com uma janela de tempo de 3 períodos; Y, composta pelas ações  $a_2$ ,  $a_3$  e  $a_4$ , com uma janela de tempo de 5 períodos; e Z, composta pelas ações  $a_1$  e  $a_4$  com uma janela de tempo de 2 períodos. As ações detectadas em um certo período  $t_i$  são dispostas dentro de uma caixa. Por exemplo, no período  $t_4$  as ações detectadas são  $a_1$  e  $a_7$ , pois a janela de tempo é considerada somente com as últimas ações detectadas. Dessa forma, é possível notar que a atividade X foi detectada, uma vez que durante a sua janela de tempo as ações que a compõe foram executadas e detectadas ( $a_1$  em  $t_4$  e  $a_5$  em  $t_5$ ). O mesmo acontece para a atividade Y, mas não para a atividade Z.

Uma atividade é iniciada quando uma ação é detectada durante a janela de tempo, e considerada terminada com a detecção da última ação faltante que compõe a atividade dentro desta janela de tempo. Se nem todas as ações forem detectadas durante a janela de tempo, a atividade é dita não completa, significando que somente algumas partes da atividade foram

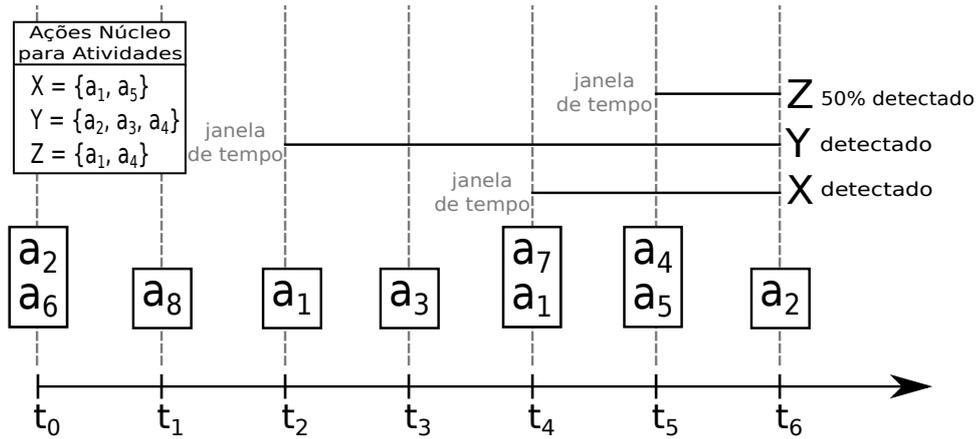


Figura 5.4 – Exemplo do método para o reconhecimento de atividade baseado na TA. Fonte: do Autor.

realizadas, é o caso da atividade  $Z$  na Figura 5.4. No exemplo apresentado,  $X$ ,  $Y$  e  $Z$  estão sendo analisadas simultaneamente, embora a atividade  $Z$  não esteja completa.

É importante deixar claro que esse método de detecção de atividade é utilizado para a predição de uma atividade, que deve ser enviada a camada *Classificador SRK* antes de acontecer de fato. Portanto, o processo de detecção de atividade é utilizado sobre um conjunto de ações inferidas pelo Componente *Inferência da Próxima Ação*, o que permite que uma atividade seja também inferida. Do mesmo modo, para uma atividade ser inferida, ela deve acontecer dentro de uma janela de tempo pré-definida para ela.

---

**Algoritmo 2** Algoritmo de predição de atividades.

---

**Entrada:** Ação corrente *curAction*

**Entrada:** Atividade a ser predita *activity*;

- 1:  $sequenceActions \leftarrow \{\}$ ;
  - 2:  $TW \leftarrow getActivityTimeWindow(activity)$ ;
  - 3:  $activityDuration \leftarrow getActionDurationMean(curAction)$ ;
  - 4:  $addActions(sequenceActions, curAction)$ ;
  - 5: **enquanto**  $activityDuration < TW$  **faça**
  - 6:    $nextAction \leftarrow nextActionInference(curAction)$ ;
  - 7:    $actionDuration \leftarrow getActionDurationMean(nextAction)$ ;
  - 8:   **se**  $(activityDuration + actionDuration) \leq TW$  **então**
  - 9:      $addActions(sequenceActions, nextAction)$ ;
  - 10: **fim se**
  - 11:  $activityDuration += actionDuration$ ;
  - 12:  $curAction \leftarrow nextAction$ ;
  - 13: **fim enquanto**
  - 14:  $detected \leftarrow isActivityDetected(sequenceActions)$ ;
  - 15: **retorna** *detected*
- 

O Componente de Predição de Atividade é responsável, com base na ação atual, por

prever a próxima atividade a ser executada e enviá-la à camada *Classificador SRK*. Uma atividade será predita se as ações que a compuserem forem preditas dentro da janela de tempo definida para esta atividade. O primeiro passo é definir o tamanho da janela de tempo, que deve corresponder ao maior tempo que o usuário levou para realizar uma atividade corretamente. Entretanto, para o início do algoritmo, quando não há nenhum dado histórico, o valor deve ser configurado manualmente.

Logo em seguida, é pesquisado no histórico do usuário a média do tempo de duração de cada ação que compõe a atividade. A cada nova ação detectada esses valores são recalculados para atualizar os valores de média. Obter esses valores de média é importante, pois a cada ação predita, a média de duração é utilizada para estimar o tempo que a atividade que está sendo predita pode demorar, e dessa forma, saber se estará ou não dentro da janela de tempo. Caso fique dentro da janela de tempo depois de todas as ações que compõe a atividade terem sido preditas, a atividade é inferida e enviada a camada *Classificador SRK*. Esse procedimento é apresentado no Algoritmo 2.

Para prever as ações que compõe a atividade, o algoritmo para inferência da próxima ação é executado com base na ação atual. De posse da ação futura inferida, o processo de inferência da próxima ação é realizado enquanto a soma das médias das durações de cada ação inferida sejam menores que a janela de tempo para a atividade em questão, ou que a atividade tenha sido detectada.

## 6 RESULTADOS

A detecção de situações de risco proposta neste trabalho baseia-se na predição das ações realizadas por um usuário baseado no comportamento prévio deste, bem como na mudança de contexto provocada por esta ação. Neste sentido, é preciso que o sistema possa prever as prováveis próximas ações executadas corretamente, bem como estimar se as mudanças de contexto ocasionadas por uma ação implicarão em um contexto arriscado para o usuário. Para validar a proposta apresentada neste trabalho, foram conduzidos três experimentos distintos. O primeiro experimento visa analisar o reconhecimento das ações através de técnicas de aprendizagem de máquina, o segundo visa analisar a precisão do modelo de predição apresentado, e o terceiro objetiva validar o modelo para detecção de situações de risco baseadas nas mudanças de contexto provocadas pelas ações no contexto do usuário.

### 6.1 Datasets utilizados

Para conduzir os experimentos foram utilizados dois *datasets*: um público, denominado *Aruba Dataset* (COOK, 2011), e um *dataset* construído pelo Grupo de Sistemas de Computação Móvel da Universidade Federal de Santa Maria, denominado *GMob Dataset*. Essa abordagem foi necessária devido à falta de *datasets* anotados que apresentem ações detectadas conjuntamente com dados fisiológicos do contexto fisiológico do usuário, como frequência cardíaca, pressão arterial, nível de oxigênio no sangue, dentre outros.

A utilização do *Aruba Dataset* permite que os resultados do modelo de predição de ações sejam comparados à outras propostas correlatas, visto que este é um *dataset* amplamente utilizado em pesquisas de reconhecimento de atividades na área de Computação Ubíqua. Já a construção de um *dataset* privado permite vincular às ações detectadas propriedades do contexto fisiológico do usuário, e dessa forma, permitir a validação do modelo para detecção de situações de risco baseadas nas mudanças ocasionadas no contexto do usuário.

#### 6.1.1 Dataset Aruba

O *dataset Aruba* (COOK, 2011) foi coletado no contexto do projeto *CASAS smart home*, da *Washington State University*, com residentes em tempo integral. Os dados foram coletados na casa de uma mulher adulta, que recebia visitas regulares dos filhos e netos, du-

rante 220 dias. O *dataset* possui registrado 11 atividades diferentes e utilizou 31 sensores de movimento, três sensores de porta (*reed swithes*), cinco sensores de temperatura e 3 sensores de luminosidade. As atividades reconhecidas e o número de vezes em que foram reconhecidas é apresentada na Tabela 6.1.

Tabela 6.1 – Número de ocorrências das atividades presentes no Aruba Dataset. Fonte: Cook (2011).

Atividades	Ocorrências	Atividades	Ocorrências
Meal Preparation	1606	Bed to Toilet	157
Relax	2910	Enter Home	431
Eating	257	Leave Home	431
Work	171	Housekeeping	33
Sleeping	401	Resperate	6
Wash Dishes	65		

### 6.1.2 Dataset GMob

Para construir o *dataset* foi utilizado um sensor de pulso, responsável pela medição da frequência cardíaca do usuário, conectado a um dispositivo Arduino Uno, e um *smartphone* com o sistema operacional Android, contendo um giroscópio e um acelerômetro. O sensor de frequência cardíaca foi colocado no lóbulo da orelha do sujeito e o *smartphone* foi fixado perto do quadril. Os dados foram coletados durante o período de um dia. A Figura 6.1 apresenta o protótipo desenvolvido para a captura dos dados no *Smartphone*.

O sujeito que realizou o experimento é do sexo masculino e possui 23 anos de idade. Foram realizadas cinco ações diferentes em uma fase preliminar: deitar, caminhar, ficar em pé (parado), correr e sentar. Nessa fase, as ações foram realizadas separadamente, para que fosse possível associar os dados dos sensores com a ação específica sendo executada. Os dados anotados do *dataset* foram então utilizados como dados de treinamento para os algoritmos de classificação. Na fase de execução o sujeito realizou as ações livremente, sem qualquer tipo de intervenção. A Tabela 6.2 apresenta o número de ocorrências para cada uma das ações presentes no *dataset* GMob.

## 6.2 Avaliação da classificação de ações

Com o intuito de classificar cada uma das ações executadas pelos usuários, foram aplicados os mesmos algoritmos de classificação elencados no trabalho de Dernbach et al. (2012).

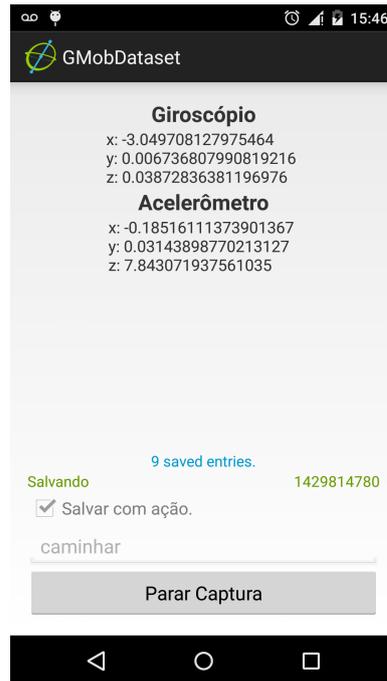


Figura 6.1 – Protótipo utilizado para captura dos dados sensores de Acelerômetro e Giroscópio do dispositivo Android. Fonte: do Autor.

Tabela 6.2 – Número de ocorrências das ações presentes no dataset GMob. Fonte: do Autor.

Ações	Ocorrências
Standing	641
Sitting	626
Walking	730
Running	137
Lying	321

Os algoritmos foram aplicados no *dataset* GMob, através do software WEKA, com os valores padrão para cada algoritmo, utilizando 30% do *dataset* como dados de treinamento. Os dados brutos sofreram o processamento da extração de características no domínio do tempo através dos seguintes métodos: a média, desvio padrão, variância, IRQ (*interquartile range*), RMS (*root mean square*), MAD (*Mean Absolute Deviation*) e correlação entre pares de eixos. A tabela 6.3 apresenta a precisão encontrada na classificação de cada um dos algoritmos utilizados.

Da mesma forma que no artigo de Dernbach et al. (2012), todos os algoritmos, exceto o algoritmo *Naive Bayes* obtiveram resultados satisfatórios para a detecção de ações simples com base nos dados do giroscópio e do acelerômetro. Escolhendo uma janela de tempo adequada, neste caso 1 segundo, foi possível identificar cada uma das ações com precisão, como pode ser notado. O fato do algoritmo *Naive Bayes* assumir inicialmente a independência entre as variáveis faz com que ele tenha esta queda de desempenho percebida (RENNIE et al., 2003).

Tabela 6.3 – Precisão dos algoritmos de aprendizagem executados no dataset GMob. Fonte: do Autor.

<b>Algoritmo</b>	<b>Precisão</b>
Multilayer Perceptron	95,63%
BestFirst Tree	95,03%
Kstar	93,18%
Bayesian Network	92,68%
Decision Table	88,03%
Naive Bayes	76,61%

Para o *dataset* GMob, o algoritmo de melhor precisão, e portanto, utilizado na arquitetura proposta foi o algoritmo *Multilayer Perceptron*, ao contrário do *KStar* encontrado no artigo de Dernbach et al. (2012). Entretanto, é importante deixar claro que os dois algoritmos obtiveram resultados elevados para precisão, e podem ser utilizados para classificação de atividades.

### 6.3 Avaliação da predição de ações

Para testar o modelo de predição de ações proposto, optou-se pela utilização do *dataset* público *Aruba Dataset*. Para tanto, cada uma das atividades foram consideradas como ações do usuário para propósito de testes. Uma vez que o algoritmo desenvolvido não necessita de uma fase de treinamento, todo o conjunto de ações foi utilizado para a predição de ações futuras, conforme o Algoritmo 1, descrito no Capítulo 5. Os resultados obtidos em cada uma das propostas, bem como o resultado para a proposta apresentada nesta dissertação, estão dispostos na Tabela 6.4 e na Figura 6.2.

Tabela 6.4 – Comparativo entre as propostas de predição de ações. Fonte: do Autor.

<b>Propostas</b>	<b>Precisão</b>
(GIL-QUIJANO; SABOURET, 2010)	61,28%
(FATIMA et al., 2013)	73,44%
Esta dissertação	78,69%

A proposta desta dissertação foi comparada aos trabalhos de Gil-Quijano e Sabouret (2010) e Fatima et al. (2013), apresentados na Seção 3.2. A precisão obtida a partir do *dataset* utilizado foi de 78,69% para o modelo proposto, com a utilização do parâmetro *MPL* em 2. Esse resultado mostrou-se superior ao resultado obtido pelo algoritmo de grafos direcionais proposto por Gil-Quijano e Sabouret (2010), de 61,28%.

O resultado apresentado nesta dissertação foi também superior ao modelo proposto por Fatima et al. (2013), que atingiu 73,44%, para o mesmo *dataset* utilizando CRF. No trabalho

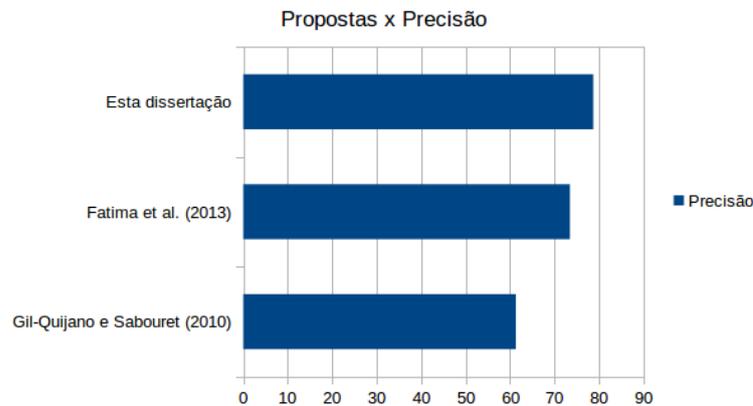


Figura 6.2 – Comparativo entre as propostas de predição de ações. Fonte: do Autor.

original, os autores conseguiram uma precisão de 79,71%. Entretanto, o cálculo da predição foi executado sobre a sequência de ações obtidas a partir do algoritmo de detecção de atividades proposto pelos próprios autores, que distorceu a ordem de execução das atividades dispostas no *dataset* original. Portanto, foi necessário executar o algoritmo dos autores sobre o *dataset* original, para que fosse possível realizar uma comparação justa.

#### 6.4 Avaliação da situação de risco em ações

A avaliação do risco em ações foi realizada no *dataset* próprio, uma vez que não foram encontrados *datasets* públicos que contivessem informações relevantes, isto é, ações anotadas em conjunto com dados fisiológicos do usuário. Os resultados obtidos em cada uma das propostas estão dispostos na Tabela 6.5 e na Figura 6.3.

Tabela 6.5 – Comparativo entre as propostas de detecção de situação de risco em ações. Fonte: do Autor.

Propostas	Precisão
(DALAL et al., 2005)	–
(CURONE et al., 2010)	88,8%
(MOCANU; FLOREA, 2011)	91,75%
(WANG et al., 2014)	96,2%
Esta dissertação	98,94%

Dessa maneira, das 2455 entradas, o modelo detectou 49 situações de risco e obteve uma precisão de 98,94%. Esta precisão foi calculada com base nos valores verdadeiro-positivos (36), verdadeiro-negativos (2393), falso-positivos (13) e falso-negativos (13). Estes valores foram obtidos a partir da análise da comparação entre os valores para a frequência cardíaca atual, os limiares previstos para a ação atual e os limiares reais da ação atual.

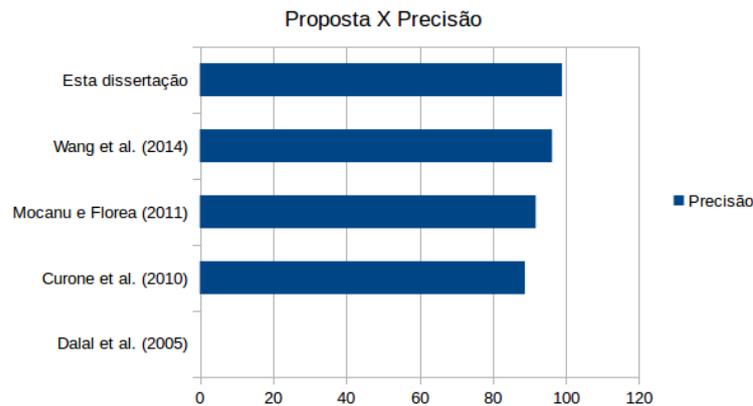


Figura 6.3 – Comparativo entre as propostas de detecção de situação de risco em ações. Fonte: do Autor.

Os limiares previstos são determinados com base na ação diretamente anterior, de modo que é utilizada a mediana das mudanças de contexto realizadas por ela e o valor da frequência cardíaca enquanto ela era desenvolvida. Os limiares reais são medidos a partir da média dos valores históricos da frequência cardíaca para a ação atual e 3 vezes o desvio padrão destes mesmos valores, visto que, os limiares que consideram a média dos valores subtraída e adicionada 3 vezes do desvio padrão representa quase que a totalidade dos valores em uma distribuição normal.

## 6.5 Avaliação da predição de atividades

Para realizar o teste de predição de atividades, utilizou-se o *dataset Aruba*, considerando as atividades reconhecidas por ele, como se fossem na realidade ações. Dessa forma, foi criada a atividade *Have Meal*, composta por um conjunto de ações presentes no *dataset Aruba*. A atividade *Have Meal* compreende o ato de preparar refeições para depois consumi-la. Como explicado na Seção 5.1.4, o processo de especificação de uma atividade possui três fases distintas: (i) especificar as ações que a compõe, (ii) especificar se as ações são ações núcleo ou secundárias, e (iii) especificar se essas ações possuem uma ordem de execução ou não. A atividade *Have Meal* é composta pelas ações *Meal Preparation* e *Eating* como ações núcleo, e *Wash Dishes* e *Relax* como ações secundárias. Além disso, foi definida que a atividade possui uma ordem de execução, definindo que a ação *Meal Preparation* deve sempre ocorrer antes que as demais ações, mas que as outras ações não possuem uma ordem definida entre elas. Isso foi definido para evitar os casos em que o usuário, por exemplo, está comendo algo pronto, que não

envolve a preparação do alimento.

Aplicando o algoritmo 2, obteve-se um valor de precisão de atividades de 70,69%. O resultado obtido superou as expectativas, uma vez que o algoritmo de predição de atividades (algoritmo 2) utiliza o algoritmo de predição de ações (algoritmo 1) para inferir as ações futuras que ocorrem depois da ação atual, no intuito de inferir uma atividade dentro da janela de tempo pré-definida. Analisando a distribuição do *dataset*, é possível notar que grande parte desse sucesso está relacionado à forma como a atividade foi modelada. No *dataset* utilizado, foi possível identificar o hábito do usuário na execução sequencial da ação *Eating* após a ação *Meal Preparation*, ficando dentro da janela de tempo. Como a ação *Meal Preparation* deve sempre ocorrer antes, conforme a ordem definida para a atividade *Have Meal*, a detecção sempre acontece após esse primeira ação ser encontrada, na sequência de atividades.

## 6.6 Comparação com os trabalhos relacionados

Seguindo os mesmos critérios de comparação elencados por Lara e Labrador (2013) no Capítulo 3, o presente trabalho obteve êxito ao ser aplicado para detectar situações de risco e prever as ações e atividades a serem executadas, tanto em atividades de locomoção (AMB), como em atividades diárias (AD). Para tanto, utilizou *datasets* públicos na presença de sensores de temperatura, movimento, acelerômetro, giroscópios, *reed switches*, dentre outros. Os resultados para as propostas de detecção de situações de risco estão sumarizados na Tabela 6.6, e os resultados para predição de ações são apresentados na Tabela 6.7.

Tabela 6.6 – Resultados do modelo proposto para detecção de situações de risco. Fonte: Adaptado de Lara e Labrador (2013).

Critérios	(DALAL et al., 2005)	(CURONE et al., 2010)	(MOCANU; FLOREA, 2011)	(WANG et al., 2014)	Esta Dissertação
Atividades	DA	AMB	DA	DA	DA e AMB
Sensores	Temp., switch e movimento	ACC, ECG	Vídeo	movimento	ACC, GYR, FC
Intrusividade	baixo	médio	alto	baixo	médio
ID	PC	PC	PC	Nodo	PC
Experimento	NAT	LAB(real)	LAB (sim.)	LAB (sim.,real)	LAB (real)
Flexibilidade	SPC	SPC	SPC	SPC	SPC
Extração	TD	TD e FD	TD e FD	TD	TD
Aprendizagem	Regras	SMA	Gramática	FP-Tree	Próprio (HAC)
Precisão	–	88,8%	91,75%	96,2%	98,94%

Quanto à intrusividade, a proposta foi classificada no nível médio, por incorporar a rotina do indivíduo dispositivos que não são comuns, caso do sensor de frequência cardíaca. Entretanto, isto depende do dispositivo utilizado. Por exemplo, se o usuário utilizar um relógio inteligente capaz de capturar a frequência cardíaca, a intrusividade pode ser considerada baixa, uma vez que o dispositivo já faz parte do cotidiano do usuário. Quanto ao critério ID, a proposta

foi classificada como PC, uma vez que os dados foram processados em um dispositivo central, e os demais dispositivos somente realizaram a captura dos dados brutos. O critério Experimento foi classificada como LAB, já que os testes foram realizados em um *dataset* público e em um *dataset* privado em laboratório.

A Flexibilidade do sistema foi classificada como SPC, ou específica do usuário, onde o modelo é treinado e testado com os dados do usuário que utilizará o sistema, e não um modelo flexível o suficiente para contemplar diferentes usuários. Dos dados brutos operou-se a extração de características, processo comum para o reconhecimento de atividades. Em nossa proposta, ela foi utilizada para reconhecer o que chamamos de ações, unidades indivisíveis que compõem uma atividade de mais alto nível. Os métodos de extração utilizados foram os do domínio do tempo, como média, desvio padrão, dentre outros. Assim, para o critério Extração, a classificação foi TD. Quanto ao método de Aprendizagem, como pode ser observado pelos resultados, o melhor resultado para precisão na detecção de situações de risco em ações foi o algoritmo desenvolvido neste trabalho, o qual utiliza as mudanças de contextos presentes no HAC. Já para a predição de ações, o algoritmo que obteve o melhor resultado de precisão foi baseado em padrões frequentes (PF – Algoritmo 1), também desenvolvido nesta dissertação.

Tabela 6.7 – Resultados do modelo proposto para predição de ações. Fonte: Adaptado de Lara e Labrador (2013).

<b>Crítérios</b>	(GIL-QUIJANO; SABOURET, 2010)	(FATIMA et al., 2013)	Esta dissertação
<b>Atividades</b>	DA	DA	DA
<b>Sensores</b>	Temp., switch e movimento	Temp., switch e movimento	Temp., switch e movimento
<b>Intrusividade</b>	baixo	baixo	baixo
<b>ID</b>	PC	PC	PC
<b>Experimento</b>	LAB(real)	LAB(real)	LAB(real)
<b>Flexibilidade</b>	SPC	SPC	SPC
<b>Extração</b>	TD	TD	TD
<b>Aprendizagem</b>	Grafos	CRF	PF
<b>Precisão</b>	61,28%	73,44%	78,69%

Por fim, cabe ressaltar o valor de precisão de 98,94% obtido na detecção de situações de risco. Este resultado enfatiza que considerar os dados de contextos fisiológicos do usuário, mais especificamente a mudança de contexto que cada ação provoca no ambiente, pode aumentar a precisão na detecção de situações de risco, visto que grande parte dos usuários possuem um padrão de comportamento na execução de suas atividades. Neste sentido, a presente proposta mostrou-se eficaz na detecção de situações de risco, e dessa forma mostrou-se superior as propostas apresentadas nos trabalhos relacionados.

## 7 CONSIDERAÇÕES FINAIS

No contexto da Computação Ubíqua e Pervasiva, as interações do usuário com o ambiente podem ser capturadas de diversas formas, que podem ser realizadas através da análise de sensores de baixo nível que representam o estado do usuário, ou através da análise dos dados processados, que geram uma informação contextual mais refinada. Uma dessas formas de captura de interação é a análise das atividades realizadas pelo usuário, que representam de forma objetiva como o usuário está interagindo com o ambiente e com outros usuários.

Entretanto, as atividades realizadas diariamente pelo usuário podem conter um risco associado, que pode causar danos ao usuário que está executando. Estes riscos podem estar relacionados diretamente a natureza da atividade (por exemplo, operações de salvamento em ambientes inóspitos), a inaptidão física do usuário decorrente de problemas de saúde (por exemplo, idosos com osteoporose), dentre outros fatores. Com o objetivo de resolver esse problema, o projeto *Activity Project* foi concebido para estudar a detecção de riscos em atividades realizadas por seres humanos na perspectiva da Computação Ubíqua e Pervasiva, através da proposta de um *middleware* sensível ao contexto composto por cinco camadas.

Essa dissertação apresentou a especificação da camada *Gerência de Atividades*, uma das cinco camadas que compõe o *middleware* para detecção de situações de risco. O principal desafio presente na camada é a necessidade de prever as próximas ações e atividades, visto que um dos requisitos é detectar possíveis situações de risco antes que elas aconteçam, prevenindo ou atenuando danos. Neste sentido, foi proposto um modelo para predição de ações e atividades baseado na Teoria da Atividade, para que com base nessas ações previstas pudesse ser inferido o risco futuro de uma ação. Esse risco foi determinado através da análise das mudanças de contexto geradas por cada uma das ações realizadas, capturadas através do modelo HAC, que permitiram inferir o estado do contexto fisiológico futuro do usuário para determinar se este configuraria um contexto de risco para os limiares estabelecidos como normais para o usuário.

Já a detecção de atividades, além de basear-se na Teoria da Atividade, utilizou um modelo hierárquico para descrever as atividades através da linguagem Asbru. Esse modelo tomou como base o trabalho de Naeem et al. (2007). As técnicas utilizadas nas abordagens adotadas mostraram-se superiores aos outros trabalhos relacionados, visto que, para a predição de ações obteve-se uma taxa de precisão de 78,69%, para a avaliação de situações de risco obteve-se uma precisão de 98,94% e para a predição de atividades a precisão foi de 70,69%. Neste sentido,

pode-se concluir que esta dissertação contribui de forma significativa na detecção de situações de risco em ambientes sensíveis ao contexto, obtendo boa precisão em comparação a trabalhos recentes na área. De forma clara, foi possível notar que a análise dos hábitos dos usuários possibilita a inferência de grande parte das ações e das situações de risco de acordo com o perfil do usuário.

## 7.1 Trabalhos futuros

A respeito dos aspectos discutidos no Capítulo 5, identificam-se alguns aperfeiçoamentos que podem ser realizados, sugerindo-se como trabalhos futuros os tópicos listados a seguir:

1. A evolução do algoritmo de predição de ações futuras, que embora tenha superado os trabalhos correlatos apresentados, apresentou precisão inferior a 80%, podendo ser melhorado.
2. Desenvolver mais modelos de atividades e aplicar a *datasets* com um maior número de ações, para que seja possível fazer uma avaliação do comportamento da predição de diversas atividades simultaneamente.
3. A proposta apresentada neste trabalho considera apenas um usuário interagindo com o ambiente. É necessário que os modelos possam considerar diversos usuários interagindo com o ambiente e entre si, o que pode ser modelado através dos componentes referentes a divisão de trabalho presentes na Teoria da Atividade, e contexto social apresentado na Taxonomia de Contexto.
4. Avaliar o desempenho dos algoritmos propostos, visto que muitos deles devem ser executados em dispositivos móveis, onde o poder de processamento é reconhecidamente menor.

## 7.2 Publicações

Abaixo segue a lista com os artigos publicados referentes a esta dissertação:

1. Del Fabro Neto, A., Boufleuer, R., Romero de Azevedo, B., Augustin, I., Lima, J. C. D., e C. Rocha, C. (2013). *Towards a middleware to infer the risk level of an activity in context-aware environments using the srk model*. UBIKOMM 2013, The Seventh International

Conference on Mobile Ubiquitous Computing, Systems, Services and Technologies, páginas 38–42.

- Qualis: B3.

2. Del Fabro Neto, A., Boufleuer, R., Romero de Azevedo, B., Augustin, I., Lima, J. C. D., e Pasin, M. *An approach based on activity theory and the SRK model for risk and performance evaluation of human activities in a context-aware middleware*. In : Proceedings of the 13th International Conference on Mobile and Ubiquitous Multimedia. ACM, 2014. p. 40-47. [dx.doi.org/10.1145/2677972.2677982](https://doi.org/10.1145/2677972.2677982)

- Qualis: B2.

3. Del Fabro Neto, A., Romero de Azevedo, B., Boufleuer, R., Lima, J. C. D., Augustin. *Model for Action Prediction and Inference of Risk Situation in Smart Environments*. In: The 2015 International Conference on Wireless Networks, Las Vegas, 2015.

- Qualis: B2;

4. Del Fabro Neto, A., Romero de Azevedo, B., Boufleuer, R., Lima, J. C. D., Augustin, I. *Modelo para predição de ações e inferência de situações de risco em ambientes sensíveis ao contexto*. In: 7º SBCUP - Simpósio Brasileiro de Computação Ubíqua e Pervasiva, Recife, 2015.

- *Best Paper*.

- Qualis: B5.

## REFERÊNCIAS

- ABOWD, G. D. et al. Towards a better understanding of context and context-awareness. In: **HANDHELD AND UBIQUITOUS COMPUTING. Anais...** [S.l.: s.n.], 1999. p.304–307.
- AUGUSTIN, I. **Abstrações para uma linguagem de programação visando aplicações móveis em um ambiente de Pervasive Computing**. 2004. Tese (Doutorado em Ciência da Computação) — Universidade Federal do Rio Grande do Sul. Instituto de Informática. Curso de Pós-Graduação em Ciência da Computação, Porto Alegre, 2004.
- BALDAUF, M.; DUSTDAR, S.; ROSENBERG, F. A survey on context-aware systems. In: **Anais...** Inderscience, 2007. v.2, n.4, p.263–277.
- BROWN, P. The stick-e document: a framework for creating context-aware applications. **Proceedings of the Electronic Publishing**, [S.l.], p.259–272, 1996.
- COOK, D. Learning setting-generalized activity models for smart spaces. **IEEE Intelligent Systems**, [S.l.], 2011.
- CRISPIM-JUNIOR, C. F.; BREMOND, F.; JOUMIER, V. A multi-sensor approach for activity recognition in older patients. In: **THE SECOND INTERNATIONAL CONFERENCE ON AMBIENT COMPUTING, APPLICATIONS, SERVICES AND TECHNOLOGIES-AMBIENT. Anais...** [S.l.: s.n.], 2012.
- CURONE, D. et al. Heart rate and accelerometer data fusion for activity assessment of rescuers during emergency interventions. **Information Technology in Biomedicine, IEEE Transactions on**, [S.l.], v.14, n.3, p.702–710, 2010.
- DALAL, S. et al. A rule-based approach to the analysis of elders activity data: detection of health and possible emergency conditions. In: **AAAI FALL 2005 SYMPOSIUM. Anais...** [S.l.: s.n.], 2005.
- DAVARI, A.; AYDIN, T.; ERDEM, T. Automatic fall detection for elderly by using features extracted from skeletal data. In: **ELECTRONICS, COMPUTER AND COMPUTATION (ICECCO), 2013 INTERNATIONAL CONFERENCE ON. Anais...** [S.l.: s.n.], 2013. p.127–130.

- DEL FABRO NETO, A. et al. Towards a Middleware to Infer the Risk Level of an Activity in Context-Aware Environments Using the SRK Model. In: UBICOMM 2013, THE SEVENTH INTERNATIONAL CONFERENCE ON MOBILE UBIQUITOUS COMPUTING, SYSTEMS, SERVICES AND TECHNOLOGIES. **Anais...** [S.l.: s.n.], 2013. p.38–42.
- DERNBACH, S. et al. Simple and complex activity recognition through smart phones. In: INTELLIGENT ENVIRONMENTS (IE), 2012 8TH INTERNATIONAL CONFERENCE ON. **Anais...** [S.l.: s.n.], 2012. p.214–221.
- EL-BENDARY, N. et al. Fall detection and prevention for the elderly: a review of trends and challenges. **International Journal on Smart Sensing and Intelligent Systems**, [S.l.], v.6, n.3, p.1230–1266, 2013.
- ENDSLEY, M. R. Toward a theory of situation awareness in dynamic systems. **Human Factors: The Journal of the Human Factors and Ergonomics Society**, [S.l.], v.37, n.1, p.32–64, 1995.
- FATIMA, I. et al. A unified framework for activity recognition-based behavior analysis and action prediction in smart homes. **Sensors**, [S.l.], v.13, n.2, p.2682–2699, 2013.
- FENG, Y.-H.; TENG, T.-H.; TAN, A.-H. Modelling situation awareness for Context-aware Decision Support. **Expert Systems with Applications**, [S.l.], v.36, n.1, p.455–463, 2009.
- FISHER, D. L.; STRAYER, D. L. Modeling situation awareness and crash risk. **Annals of advances in automotive medicine**, [S.l.], v.58, p.33, 2014.
- FLOR, N. V.; HUTCHINS, E. L. A Case Study of Team Programming During Perfective Software Maintenance. In: EMPIRICAL STUDIES OF PROGRAMMERS: FOURTH WORKSHOP. **Anais...** [S.l.: s.n.], 1991. p.36.
- GIL-QUIJANO, J.; SABOURET, N. Prediction of Humans' Activity for Learning the Behaviors of Electrical Appliances in an Intelligent Ambient Environment. In: WEB INTELLIGENCE AND INTELLIGENT AGENT TECHNOLOGY (WI-IAT), 2010 IEEE/WIC/ACM INTERNATIONAL CONFERENCE ON. **Anais...** [S.l.: s.n.], 2010. v.2, p.283–286.
- GUSTAVSEN, R. M. Condor—an application framework for mobility-based context-aware applications. In: OF THE WORKSHOP ON CONCEPTS AND MODELS FOR UBIQUITOUS COMPUTING. **Proceedings...** [S.l.: s.n.], 2002. v.39.

- HUNKELER, U.; TRUONG, H. L.; STANFORD-CLARK, A. MQTT-S—A publish/subscribe protocol for Wireless Sensor Networks. In: COMMUNICATION SYSTEMS SOFTWARE AND MIDDLEWARE AND WORKSHOPS, 2008. COMSWARE 2008. 3RD INTERNATIONAL CONFERENCE ON. **Anais...** [S.l.: s.n.], 2008. p.791–798.
- INDULSKA, J. et al. Experiences in using cc/pp in context-aware systems. In: MOBILE DATA MANAGEMENT. **Anais...** [S.l.: s.n.], 2003. p.247–261.
- JOVANOVIĆ, E.; MILENKOVIĆ, A. Body area networks for ubiquitous healthcare applications: opportunities and challenges. **Journal of medical systems**, [S.l.], v.35, n.5, p.1245–1254, 2011.
- KOFOD-PETERSEN, A.; CASSENS, J. Using activity theory to model context awareness. In: **Modeling and Retrieval of Context**. [S.l.]: Springer, 2006. p.1–17.
- KUUTTI, K. Activity theory as a potential framework for human-computer interaction research. In: **Anais...** [S.l.: s.n.], 1996. p.17–44.
- LARA, O. D.; LABRADOR, M. A. A survey on human activity recognition using wearable sensors. **Communications Surveys & Tutorials, IEEE**, [S.l.], v.15, n.3, p.1192–1209, 2013.
- LAVE, J. **Cognition in practice: mind, mathematics and culture in everyday life**. [S.l.]: Cambridge University Press, 1988.
- LEONT'EV, A. N. The problem of activity in psychology. **Journal of Russian and East European Psychology**, [S.l.], v.13, n.2, p.4–33, 1974.
- LEONT'EV, A. N. Activity, consciousness, and personality. **Englewood Cliffs, Prentice Hall**, [S.l.], 1978.
- LU, C.-H.; FU, L.-C. Robust location-aware activity recognition using wireless sensor network in an attentive home. In: **Anais...** IEEE, 2009. v.6, n.4, p.598–609.
- MIKALSEN, M.; KOFOD-PETERSEN, A. Representing and reasoning about context in a mobile environment. In: IEEE. **Anais...** [S.l.: s.n.], 2004. p.25–35.
- MIKSCH, S.; SHAHAR, Y.; JOHNSON, P. Asbru: a task-specific, intention-based, and time-oriented language for representing skeletal plans. In: WORKSHOP ON KNOWLEDGE ENGINEERING: METHODS & LANGUAGES (KEMML-97), 7. **Proceedings...** [S.l.: s.n.], 1997. p.9–19.

MOCANU, I.; FLOREA, A. M. A model for activity recognition and emergency detection in smart environments. In: AMBIENT 2011, THE FIRST INTERNATIONAL CONFERENCE ON AMBIENT COMPUTING, APPLICATIONS, SERVICES AND TECHNOLOGIES. **Anais...** [S.l.: s.n.], 2011. p.13–19.

MOSTEFAOUI, G. K.; PASQUIER-ROCHA, J.; BREZILLON, P. Context-aware computing: a guide for the pervasive computing community. In: PERVASIVE SERVICES, 2004. ICPS 2004. IEEE/ACS INTERNATIONAL CONFERENCE ON. **Anais...** [S.l.: s.n.], 2004. p.39–48.

NAEEM, U.; BIGHAM, J.; WANG, J. Recognising activities of daily life using hierarchical plans. In: **Smart Sensing and Context**. [S.l.]: Springer, 2007. p.175–189.

NARDI, B. A. Studying context: a comparison of activity theory, situated action models, and distributed cognition. **Context and consciousness: Activity theory and human-computer interaction**, [S.l.], p.69–102, 1996.

NWIABU, N. et al. Situation awareness in context-aware case-based decision support. In: COGNITIVE METHODS IN SITUATION AWARENESS AND DECISION SUPPORT (COG-SIMA), 2011 IEEE FIRST INTERNATIONAL MULTI-DISCIPLINARY CONFERENCE ON. **Anais...** [S.l.: s.n.], 2011. p.9–16.

PASCOE, J. The Smartwatch. In: CONFERENCE ON MOBILE AND UBIQUITOUS SYSTEMS (CSMU), GUIMARAES PORTUGAL. **Proceedings...** [S.l.: s.n.], 2006. p.203–206.

RANTANEN, E. M.; LEVINTHAL, B. R. Time-based modeling of human performance. In: HUMAN FACTORS AND ERGONOMICS SOCIETY ANNUAL MEETING. **Proceedings...** [S.l.: s.n.], 2005. v.49, n.12, p.1200–1204.

RASCH, K. **Smart assistants for smart homes**. 2013. Tese (Doutorado em Ciência da Computação) — Royal Institute of Technology.

RASMUSSEN, J. Skills, rules, and knowledge; signals, signs, and symbols, and other distinctions in human performance models. In: OF THE . **Anais...** IEEE, 1983. n.3, p.257–266.

RASMUSSEN, J. Risk management in a dynamic society: a modelling problem. **Safety science**, [S.l.], v.27, n.2, p.183–213, 1997.

- RENNIE, J. D. et al. Tackling the poor assumptions of naive bayes text classifiers. In: ICML. **Anais...** [S.l.: s.n.], 2003. v.3, p.616–623.
- ROCHA, C. C. da et al. A Context-Aware Authentication Approach Based on Behavioral Definitions. In: IKE. **Anais...** [S.l.: s.n.], 2010. p.178–184.
- SATYANARAYANAN, M. Pervasive computing: vision and challenges. **Personal Communications, IEEE**, [S.l.], v.8, n.4, p.10–17, 2001.
- SCHILIT, B.; ADAMS, N.; WANT, R. Context-aware computing applications. In: MOBILE COMPUTING SYSTEMS AND APPLICATIONS, 1994. WMCSA 1994. FIRST WORKSHOP ON. **Anais...** [S.l.: s.n.], 1994. p.85–90.
- STRANG, T.; LINNHOFF-POPIEN, C. A context modeling survey. In: WORKSHOP PROCEEDINGS. **Anais...** [S.l.: s.n.], 2004.
- VYGOTSKY, L. S. **Mind in society**: the development of higher psychological processes. [S.l.]: Harvard university press, 1980.
- WANG, C. et al. Distributed Abnormal Activity Detection in Smart Environments. **International Journal of Distributed Sensor Networks**, [S.l.], v.2014, 2014.
- WANG, J. et al. An enhanced fall detection system for elderly person monitoring using consumer home networks. **Consumer Electronics, IEEE Transactions on**, [S.l.], v.60, n.1, p.23–29, 2014.
- WAZLAWICK, R. **Metodologia de Pesquisa para Ciência da Computação**. [S.l.]: Elsevier Brasil, 2009. 184p.
- WEISER, M. The computer for the 21st century. In: **Anais...** Nature Publishing Group, 1991. v.265, n.3, p.94–104.
- WEISER, M. Some computer science issues in ubiquitous computing. **Communications of the ACM**, [S.l.], v.36, n.7, p.75–84, 1993.
- YURUR, O.; LIU, C. H.; MORENO, W. A survey of context-aware middleware designs for human activity recognition. **Communications Magazine, IEEE**, [S.l.], v.52, n.6, p.24–31, 2014.