

Universidade Federal Fluminense

ALESSANDRO COPETTI

**Monitoramento Inteligente e Sensível ao Contexto na  
Assistência Domiciliar Telemonitorada**

NITERÓI

2010

# **Livros Grátis**

<http://www.livrosgratis.com.br>

Milhares de livros grátis para download.

ALESSANDRO COPETTI

# Monitoramento Inteligente e Sensível ao Contexto na Assistência Domiciliar Telemonitorada

Tese de Doutorado submetida ao Programa de Pós-Graduação em Computação da Universidade Federal Fluminense. Área de concentração: Redes e Sistemas Distribuídos e Paralelos.

Orientador:

Professor Julius Leite, Ph.D.

Co-orientador:

Professor Orlando Gomes Loques Filho, Ph.D.

UNIVERSIDADE FEDERAL FLUMINENSE

NITERÓI

2010

# Monitoramento Inteligente e Sensível ao Contexto na Assistência Domiciliar Telemonitorada

Alessandro Copetti

Tese de Doutorado submetida ao Programa  
de Pós-Graduação em Computação da Uni-  
versidade Federal Fluminense.

---

Prof. Julius Leite, Ph.D. / IC-UFF (Presidente)

---

Prof. Orlando Gomes Loques Filho, Ph.D. / IC-UFF  
(co-orientador)

---

Prof. Antonio Claudio Lucas da Nóbrega, D. Sc. / IB-UFF

---

Prof. Claudio Luis de Amorim, Ph.D. / COPPE-UFRJ

---

Prof. Julio Cesar Stacchini de Souza, D. Sc. / EE-UFF

---

Prof. Mario Fritsch Toros Neves, D. Sc. / CM-UERJ

---

Prof. Ricardo Tanscheit, Ph.D. / DEE-PUC/Rio

Niterói, Dezembro de 2010.

*Para minha família: Bruno, Almira, Rafael e Mariana.*

# Agradecimentos

Ao término de mais essa etapa, venho agradecer àqueles(as) que compartilharam diversas situações durante o meu período de doutorado, tanto no lado profissional quanto no lado pessoal, e que de alguma forma me ajudaram na conclusão do curso.

Agradeço inicialmente aos professores Julius Leite e Orlando Loques, pela ética, profissionalismo e disponibilidade. Da mesma forma, proporcionaram uma ótima infraestrutura para o desenvolvimento do trabalho. Aproveito para agradecer também ao apoio financeiro da FAPERJ.

A Doris Rinaldi, por fazer com que eu me responsabilize e me empenhe nas questões mais importantes de minha vida.

Ao Prof. Dr. Antonio Claudio Lucas da Nóbrega e a Dra. Thais de Paola Chequer Barbosa, ambos do Instituto Biomédico da UFF, e ao Prof. Dr. Mario Neves do Departamento de Clínica Médica da UERJ, pelas contribuições na área médica. A interação com essa equipe médica foi fundamental para o trabalho. As conversas com a Dra. Thais foram esclarecedoras e motivadoras. Agradeço também aos membros do projeto SCIADS, tanto da UERJ quanto da UFF, e estendo a todos os professores do curso de Ciência da Computação da UFF/Niterói e da UFF/Rio das Ostras.

Gostaria de agradecer a alguns amigos que sempre deram seu apoio em diversas situações:

Cristiano Maciel, pela abertura de caminhos de vida,  
Haroldo dos Santos, pela força principalmente nos meses que antecederam a qualificação,  
Juliano Kazienko, pelas discussões de fim de tarde regadas a chimarrão,  
Larissa Frauches, pela dedicação e preocupação,  
Luciano Bertini, pelo sentimento de compartilhar vitórias e aprender com as derrotas,  
Marcus Guelpeli, pelo exemplo de garra,  
Marcus Wagner, pela transmissão de confiança,  
Rafael Copetti, por ter assumido tarefas nas situações pessoais mais difíceis,

Reinaldo Alvares, pela compreensão e espírito de doação,  
Renato Vieira, pelo companheirismo, bom humor e incentivo à superação,  
Sergio Carvalho, pelas discussões no café da padaria logo cedo,  
Vinicius Pereira, pela demonstração de que educação e palavras derrubam preconceitos,  
Vinicius Petrucci, pelo companheirismo nas descobertas na cidade maravilhosa.  
Todas essas pessoas me passaram um dos mais importantes valores que se pode passar a alguém, a persistência.

Da mesma forma, gostaria de agradecer a outros amigos, pessoas de ótima convivência, companheiros, e que muito me ajudaram com suas experiências: Adria Lyra, Alex Alves, Ana Paula Sobral, Carlos Bazilio, Carlos da Silva, Cinara Guedini, Cristiane Ferreira, Diego Brandão, Douglas Mareli, Edwin Mitacc, Giulio Bottari, Idalmis Milian, Iza Oliveira, Jacques da Silva, Jonivan Lisbôa, José Viterbo, Juliana Mendes, Luciana Brugiolo, Luciene Motta, Matheus Erthal, Renatha Capua, Ricardo Carrano, Rodrigo de Vit, Stênio Rosário, e a todos os colegas da pós-graduação em Computação da UFF, verdadeiros guerreiros.

# Resumo

A inferência de contexto representa um grande desafio no projeto de aplicações sensíveis ao contexto, de modo que uma correta interpretação dos dados implicará a viabilidade de uso da aplicação. A fim de investigar a inferência de contexto, adotamos como cenário de computação pervasiva um paciente monitorado em sua casa. Nesse sentido, esta tese contribui com um mecanismo de inferência de contexto direcionado para o tratamento de saúde no ambiente domiciliar pervasivo.

A fim de estruturar conceitualmente as funcionalidades para um monitoramento no ambiente pervasivo domiciliar, concebemos um Arcabouço de Monitoramento, capaz de agregar técnicas inteligentes que exploram a potencialidade das aplicações sensíveis ao contexto. Em especial, enfocamos a identificação de situações críticas envolvendo variações nos sinais vitais. Assim, o arcabouço contribui para uma visão holística do tratamento de saúde, enfatizando um mecanismo de Decisão que contempla a fusão de dados ambientais, fisiológicos e comportamentais. Nossa abordagem satisfaz três aspectos importantes para esse monitoramento: a individualização, a relaxação dos limites rígidos de variáveis envolvidas e a influência do comportamento e do ambiente nas variáveis fisiológicas. Desse modo, os alarmes tornam-se mais confiáveis.

O estudo de caso aqui apresentado diz respeito ao monitoramento da pressão arterial. A interação com uma equipe médica permitiu a definição de requisitos e a representação do conhecimento médico por meio de regras, possibilitando explorar técnicas adequadas para a concepção do mecanismo de Decisão, ao passo que a abordagem *Fuzzy* permitiu uma maneira natural de representação do conhecimento médico. A solução ainda mantém a interpretabilidade das regras, mesmo após uma fase de aprendizado que propõe ajustes nas variáveis *Fuzzy* envolvidas. Para tanto, construímos um protótipo que foi usado como prova de conceito da tese, com o qual foram realizados testes com dados originais de pacientes e sintéticos.

Uma equipe médica avaliou dados de Monitoramento Ambulatorial da Pressão Arterial de 30 pacientes, e a classificação produzida foi comparada com os resultados do sistema. O mecanismo de Decisão identificou com uma alta acurácia situações críticas em pacientes com diferentes níveis de pressão arterial, o que o torna uma importante ferramenta para o apoio a análise médica.



# Abstract

Context inference is a great challenge in developing context-aware applications, so much so that a correct context interpretation will lead to the feasibility of using this application. In order to investigate the context inference, we adopted as a scenario of pervasive computing a patient monitored at home. Thus, this thesis contributes with a context inference engine directed to pervasive home care.

In order to organize conceptually the features for a home health monitoring in pervasive environments, we designed a monitoring framework, capable of adding intelligent techniques that exploit the potential of context-aware applications. In particular, we focus on identifying critical situations involving changes in vital signs. Thus, the framework contributes to a holistic view of health care, emphasizing a decision mechanism that involves the fusion of environmental, physiological and behavioral data. Our approach satisfies three important aspects of this monitoring: individualization, the relaxation of the crisp limits of variables involved and the influence of both behavior and environment on physiological variables. Hence, the alarms become more reliable.

The case study presented here concerns the monitoring of blood pressure. The interaction with a medical team allowed the definition of requirements and the representation of medical knowledge through rules. The Fuzzy approach allowed a natural way of representing medical knowledge. The solution also maintains the interpretability of the rules, even after a learning phase that proposes adjustments in the Fuzzy variables involved. To this end, we developed a prototype that was used as proof of concept of the thesis, which were made with the original data of patients and synthetic.

A medical team assessed data from Ambulatory Blood Pressure Monitoring of 30 patients and the classification produced was compared with the results of the system. The decision mechanism identified with high accuracy critical situations in patients with different blood pressure levels, making it an important tool to support medical analysis.

# Palavras-chave

1. Aplicações Pervasivas na Assistência Domiciliar
2. Aplicações Sensíveis ao Contexto
3. Tratamento de Saúde em Ambientes Inteligentes
4. Computação Vestível
5. Sistemas *Fuzzy*
6. Telemonitoramento
7. Telessaúde
8. Vida Assistida em Ambientes Pervasivos
9. Assistência Domiciliar Telemonitorada

# Glossário

AVD	:	Atividades da Vida Diária
CSR	:	Central de Saúde Residencial
FC	:	Frequência Cardíaca
FCM	:	Fuzzy c-Means
GK	:	Gustafson-Kessel
GSR	:	<i>Galvanic Skin Response</i>
H-SAUDE	:	Health Support for Aware and Ubiquitous Domestic Environments
MAPA	:	Monitorização Ambulatorial da Pressão Arterial
MDP	:	Média e Desvio Padrão
MRPA	:	Monitorização Residencial da Pressão Arterial
PA	:	Pressão Arterial
PAD	:	Pressão Arterial Diastólica
PAS	:	Pressão Arterial Sistólica
SCIADS	:	Sistema Computacional Inteligente de Assistência Domiciliar à Saúde

# Sumário

<b>Lista de Figuras</b>	<b>xii</b>
<b>Lista de Tabelas</b>	<b>xiv</b>
<b>1 Introdução</b>	<b>1</b>
1.1 Contribuições da Tese . . . . .	3
<b>2 Novas Perspectivas e Desafios para o Tratamento de Saúde em Ambientes Pervasivos</b>	<b>4</b>
2.1 Assistência Domiciliar com Computação Pervasiva . . . . .	5
2.1.1 Exemplo de Cenário . . . . .	6
2.1.2 Em Direção a uma Visão Abrangente da Assistência Domiciliar . . . . .	7
2.1.3 Funcionalidades Encontradas em Aplicações <i>Pervasive Home Care</i> . . . . .	11
2.1.4 Aspectos Tecnológicos: o Uso de Sensores . . . . .	13
2.1.4.1 Perspectivas sobre Redes de Sensores no Ambiente Domiciliar Pervasivo . . . . .	15
2.2 Requisitos da Assistência Domiciliar com Computação Pervasiva . . . . .	16
2.3 Arquitetura de Decisão para <i>Pervasive Home Care</i> . . . . .	20
2.3.1 A Central de Saúde Residencial . . . . .	20
2.3.2 Classes de Variáveis para Monitoramento . . . . .	23
2.3.2.1 O Monitoramento do Comportamento . . . . .	24
2.3.2.2 Problemas no Monitoramento de um Paciente em Casa . . . . .	25
2.4 Conclusões do Capítulo . . . . .	26

---

<b>3</b>	<b>Arcabouço de Monitoramento Inteligente</b>	<b>28</b>
3.1	Componentes do Arcabouço . . . . .	29
3.1.1	Gerenciamento do Contexto . . . . .	31
3.1.2	Decisão . . . . .	33
3.1.3	Aprendizado . . . . .	35
3.1.4	Outros Componentes do Arcabouço . . . . .	36
3.1.4.1	Notificação . . . . .	36
3.1.4.2	Dados Persistentes . . . . .	36
3.2	Cenários de Uso do Arcabouço em Situações Críticas . . . . .	38
3.3	Trabalhos Relacionados . . . . .	40
3.4	Conclusões do Capítulo . . . . .	43
<b>4</b>	<b>Mecanismo de Decisão para Inferência de Contexto em Ambientes Pervasivos de Tratamento de Saúde</b>	<b>44</b>
4.1	Modelo de Decisão para o Monitoramento . . . . .	45
4.1.1	As Estratégias e o Modelo de Decisão para Inferir Situações Críticas	46
4.2	Módulo de Inferência . . . . .	48
4.3	Módulo de Aprendizado . . . . .	53
4.3.1	Estratégias de Projeto para o Módulo de Aprendizado . . . . .	53
4.3.2	A Questão da Interpretabilidade no Ajuste do Sistema de Inferência <i>Fuzzy</i> . . . . .	54
4.3.3	Geração de Dados Sintéticos para o Monitoramento de Sinais Vitais	56
4.3.4	Descrição do Módulo de Aprendizado . . . . .	59
4.3.4.1	Fase 1: selecionar um subintervalo dos casos de alertas leves	60
4.3.4.2	Fase 2: encontrar um ponto representativo . . . . .	61
4.3.4.3	Fase 3: ajustar as regras específicas às atividades . . . . .	65
4.4	Trabalhos Relacionados . . . . .	68

---

4.5	Conclusões do Capítulo . . . . .	69
<b>5</b>	<b>Avaliação do Mecanismo de Decisão</b>	<b>70</b>
5.1	Avaliação do Módulo de Inferência . . . . .	71
5.1.1	Testes com Diferentes Cenários . . . . .	73
5.1.2	Testes com Dados Sintéticos que Mantêm Características dos Dados Originais . . . . .	79
5.2	Avaliação do Módulo de Aprendizado . . . . .	82
5.3	Avaliação Médica . . . . .	91
5.4	Conclusões do Capítulo . . . . .	95
<b>6</b>	<b>Conclusões e Trabalhos Futuros</b>	<b>98</b>
6.1	Trabalhos Futuros . . . . .	99
	<b>Apêndice A – Artigos Publicados</b>	<b>102</b>
	<b>Apêndice B – Breve Introdução às Variáveis Fuzzy</b>	<b>105</b>
	<b>Apêndice C – Regras</b>	<b>107</b>
	<b>Referências</b>	<b>110</b>

# Lista de Figuras

2.1	Arquitetura de integração dos atores envolvidos na telessaúde . . . . .	8
2.2	Sensores: (a) WristClinic <sup>T</sup> M, (b) MiniClinic Wrist-unit, (c) Wireless Blood Pressure Monitor BP100, (d) aLsis emergency unit da TelcoMed [62] . . . .	13
2.3	Arquitetura de Decisão para <i>Pervasive Home Care</i> . . . . .	21
3.1	Arcabouço de Monitoramento H-SAUDE: módulos e seus componentes . .	29
4.1	Modelo de Decisão . . . . .	47
4.2	Desvio da Pressão Arterial Sistólica enquanto a pessoa dorme . . . . .	49
4.3	Desvio da Pressão Arterial Sistólica enquanto a pessoa realiza uma atividade doméstica . . . . .	50
4.4	Estado do paciente; resultado da inferência . . . . .	50
4.5	Temperatura ambiente . . . . .	52
4.6	Conceitos úteis para mudanças dos conjuntos <i>fuzzy</i> . . . . .	55
4.7	Mecanismo de Decisão para inferência de contexto . . . . .	60
4.8	Interface de Seleção do Subintervalo de Alertas . . . . .	61
4.9	Áreas possíveis de agrupamentos de alertas . . . . .	64
4.10	Variável de pressão arterial sistólica na atividade de repouso: (a) situação inicial, com o núcleo do conjunto normal em [-5,5]; (b) após o ajuste com desvio=10, o núcleo do “normal” passa a ser [-5,10]; (c) após o ajuste com desvio=-10, o núcleo do “normal” passa a ser [-10,5] . . . . .	66
5.1	Médias de PA com os pacientes ordenados pela soma PAS e PAD . . . . .	71
5.2	Função de distribuição acumulada para a diferença entre os resultados do sistema somente para os dados de MAPA e os resultados do sistema com dados sintéticos e distribuição uniforme no cenário 5-3-4 . . . . .	75

---

5.3	Percentual de alarmes nos diferentes cenários usando distribuição uniforme	78
5.4	Diferença em pontos percentuais de alarmes entre o sistema com dados sintéticos de distribuição normal e o sistema com dados de MAPA . . . . .	80
5.5	Pontos centrais para o FCM no paciente '28' na atividade de dormindo. A média do paciente é 156/94 e os resultados obtidos foram: 168/102 e 130/77	84
5.6	Pontos centrais para o FCM no paciente '28' em repouso. A média do paciente é 156/94 e os resultados obtidos foram: 173/105 e 145/90. A área retangular mostra que, na técnica MDP, outros pontos seriam considerados para o cálculo de uma PAD abaixo da média . . . . .	85
5.7	Pontos centrais do paciente '24' em repouso. A média do paciente é 142/99 e os resultados obtidos no FCM foram: 156/113 e 126/80, e no GK:159/111 e 144/107 . . . . .	86
5.8	Pontos centrais do paciente '23' dormindo. A média do paciente é 139/101 e os resultados obtidos no FCM foram: 145/106 e 124/81, e no GK: 128/82 e 124/82 . . . . .	86
5.9	Pontos centrais do paciente '11' em repouso. A média do paciente é 135/73 e os resultados obtidos foram no FCM: 155/81 e 121/70, e no GK: 151/87 e 139/62 . . . . .	87
5.10	Pontos centrais para o GK do paciente '23' em repouso usando uma 1 <sup>a</sup> série de dados. A média do paciente é 139/101 e os resultados obtidos foram: 153/116 e 122/85 . . . . .	88
5.11	Pontos centrais para o GK do paciente '23' em repouso usando uma 2 <sup>a</sup> série de dados. A média do paciente é 139/101 e os resultados obtidos foram: 156/115 e 146/112 . . . . .	88
5.12	Desempenho das técnicas por característica do paciente . . . . .	95
B.1	Conjunto <i>fuzzy</i> . . . . .	106



# Lista de Tabelas

3.1	Aplicações envolvendo situações críticas e os componentes necessários para a solução . . . . .	39
4.1	Variável desvioPASRepouso . . . . .	65
5.1	Avaliação dos dados de MAPA pelo método tradicional e pelo sistema . . .	72
5.2	Cenário 5-3-4 . . . . .	74
5.3	Cenário 20-15-20 . . . . .	76
5.4	Cenário +30-0-0 . . . . .	77
5.5	Cenário +50+30+40 . . . . .	78
5.6	Resultados do sistema com dados sintéticos de distribuição normal . . . . .	80
5.7	Pacientes e suas médias de pressão arterial em mmHg . . . . .	81
5.8	Correlação entre PAS e PAD nos dados de MAPA e nos dados sintéticos .	81
5.9	Comparativo entre os dados de MAPA e os dados sintéticos usando MANOVA	82
5.10	Ajustes propostos acima e abaixo da média PAS/PAD pelas 3 técnicas nos 3 pacientes . . . . .	83
5.11	Comparação antes e após o Aprendizado para os dados sintéticos nos pacientes normotensos . . . . .	89
5.12	Comparação antes e após o Aprendizado para os dados sintéticos nos pacientes hipertensos . . . . .	89
5.13	Comparação antes e após o Aprendizado para os dados de MAPA nos pacientes normotensos . . . . .	90
5.14	Comparação antes e após o Aprendizado para os dados de MAPA nos pacientes hipertensos . . . . .	91
5.15	Matriz de Confusão - médico A, antes do aprendizado . . . . .	92

---

5.16	Matriz de Confusão - médico A, após o aprendizado com FCM . . . . .	92
5.17	Matriz de Confusão - médico B, antes do aprendizado . . . . .	92
5.18	Matriz de Confusão - médico B, após o aprendizado com FCM . . . . .	93
5.19	Matriz de Confusão - médico A, após o aprendizado com GK, 88% de acurácia	94
5.20	Matriz de Confusão - médico B, após o aprendizado com GK, 86% de acurácia	94
5.21	Matriz de Confusão - médico A, após o aprendizado com MDP, 85% de acurácia . . . . .	94
5.22	Matriz de Confusão - médico B, após o aprendizado com MDP, 83% de acurácia . . . . .	95

# Capítulo 1

## Introdução

O aumento da proporção de idosos representa um grande desafio para o sistema de saúde. Atualmente, cerca de 11% da população mundial é composta por idosos; em 2050, os idosos deverão representar um quinto da população [83]. Um problema associado são as doenças crônicas, que no Brasil já atingem 3 em cada 4 idosos [61]. Os pacientes que convivem com doenças crônicas, como, por exemplo, diabetes e doenças cardiovasculares, necessitam de um monitoramento de longa duração em sua vida diária, com grande nível de detalhamento.

Ainda no que tange às doenças crônicas em território nacional, estima-se que pelo menos 60% dos brasileiros com mais de 60 anos são hipertensos [101]. Como muitos desses indivíduos moram sozinhos, a residência torna-se o principal local para o monitoramento.

Principalmente com o avanço das tecnologias de sensores sem fio, posicionados tanto nos ambientes como no corpo das pessoas (computação vestível), hoje já é possível projetar novas aplicações de monitoramento remoto. Estas aplicações podem executar em ambientes pervasivos dotados de dispositivos capazes de realizar computação e comunicação. A partir disso, é possível imaginarmos um ambiente doméstico com unidades de processamento que realizam desde a coleta de dados até a identificação e notificação de emergências. Por sua vez, os dados assim gerados caracterizam determinadas situações de interesse envolvendo objetos, pessoas e lugares, formando o conceito de contexto [39]. A correta transformação desses dados em informações de alto nível é um dos principais requisitos para um monitoramento eficiente.

Para um melhor entendimento, exemplificamos nesta tese duas situações proporcionadas pelo uso da computação pervasiva no ambiente domiciliar (área de *pervasive home*

*care*<sup>1</sup>) e que remetem a desafios relacionados à inferência de contexto. Na primeira situação, um idoso é monitorado de forma não intrusiva por sensores de sinais vitais acoplados a seu corpo, os quais coletam dados da pressão arterial e da frequência cardíaca, entre outras informações. Em determinado momento, ocorre uma alteração dos seus sinais vitais, sendo que, nos minutos prévios, teriam sido detectados uma temperatura ambiente alta e um aumento considerável na atividade física do paciente. Já na outra situação analisada, uma grande variação dos sinais vitais é acompanhada de uma possível queda do paciente. Em ambas as situações, caracterizadas como críticas, uma notificação é direcionada a um profissional de saúde, que, por sua vez, procura ter melhor conhecimento da situação, e.g., entrando em contato com o paciente.

Nesses dois exemplos, podemos identificar três classes de variáveis envolvidas nas informações de contexto: ambientais, fisiológicas e comportamentais. Se após a coleta das variáveis realizarmos uma fusão de dados, poderemos caracterizar melhor o estado do paciente, classificando-o, inicialmente, como normal, alerta ou emergência. Dessa forma, há a necessidade de mecanismos de decisão mais consistentes que infiram e caracterizem as situações de monitoramento, evitando alarmes falsos <sup>2</sup>.

Assim, propomos um arcabouço conceitual e um mecanismo de Decisão para o monitoramento inteligente da saúde de um paciente em casa. A solução integra recomendações médicas, condições ambientais, dados fisiológicos e o comportamento do paciente. O arcabouço tem como elementos relevantes módulos de gerenciamento de contexto, decisão e aprendizado. Os módulos são interligados para cooperarem nas atividades de tomada de decisão em aplicações pervasivas na assistência domiciliar. Nós enfatizamos a identificação de situações críticas, onde analisamos valores anormais de dados fisiológicos. Com isso, definimos um mecanismo de decisão que permita realizar o monitoramento de longa duração do paciente.

Nosso trabalho avança as arquiteturas tradicionais de telessaúde na medida em que incorpora inteligência local ao domicílio. O mecanismo de decisão identifica variações significativas de sinais vitais por meio de regras que contemplam as três classes de variáveis. Além de essas regras incluírem médias de sinais vitais, o módulo de aprendizado propõe ajustes nas regras, o que reduz o número de alarmes falsos e resulta em uma solução sistematicamente individualizada para o paciente sendo monitorado. Uma implementação desse mecanismo foi desenvolvida, com base em um estudo de caso particular

---

<sup>1</sup>Neste trabalho utilizamos o termo *pervasive home care* em vez de tratamento de saúde em ambiente domiciliar com computação pervasiva.

<sup>2</sup>Neste trabalho, os alertas e as emergências são denominados 'alarmes'.

de monitoramento de saúde, o que nos permitiu avaliar sua eficácia.

Os Capítulos estão estruturados da seguinte forma: inicialmente, no segundo Capítulo, é mostrada nossa visão sobre a área de assistência domiciliar telemonitorada, suas perspectivas e seus desafios em ambientes pervasivos. O terceiro Capítulo apresenta o arcabouço de monitoramento inteligente. O mecanismo de decisão para identificar situações críticas é desenvolvido no quarto Capítulo. No quinto Capítulo é feita a avaliação do mecanismo de decisão e, no sexto, estão as conclusões e futuros trabalhos.

## 1.1 Contribuições da Tese

Esta tese demonstra que a identificação de situações críticas envolvendo variações nos sinais vitais pode ser automatizada por um mecanismo de Decisão que considera as variáveis ambientais, fisiológicas e comportamentais, ao mesmo tempo em que satisfaz o requisito de individualização do tratamento de um paciente sendo monitorado em casa. Inicialmente, investigamos as possibilidades de um monitoramento de um paciente em ambiente domiciliar usando os recursos de computação pervasiva. Como resultado, definimos uma **arquitetura de Integração** dos atores envolvidos na telessaúde. Com essa arquitetura são discutidas novas perspectivas para o tratamento de saúde em ambientes pervasivos.

Ademais, elaboramos uma **arquitetura de Decisão** em alto nível, a qual viabiliza a inclusão de inteligência em aplicações do tipo *pervasive home care*. Ao detalhar a arquitetura, propomos um **Arcabouço de Monitoramento** para a tomada de decisão relativa ao tratamento de saúde de longa duração. Em seguida, detalhamos alguns de seus componentes para criar um **mecanismo de Decisão** individualizado que permita identificar situações críticas. A individualização é feita em uma etapa de aprendizado que propõe ao médico os ajustes nas variáveis envolvidas. Nós implementamos o mecanismo e realizamos testes usando dados sintetizados a partir de dados reais de 30 pacientes, comparando os resultados com a avaliação de uma equipe médica. O mecanismo proposto por esta pesquisa apresentou uma taxa muito baixa de falsos negativos e uma acurácia de 90% na identificação de situações críticas para o estudo de caso utilizado.

Durante o período da tese foram publicados 9 artigos. O detalhamento desses trabalhos é feito no Apêndice A. Outros dois trabalhos foram submetidos para revistas, sendo que um deles está em processo de avaliação.

## Capítulo 2

# Novas Perspectivas e Desafios para o Tratamento de Saúde em Ambientes Pervasivos

O telemonitoramento é um serviço que permite aos profissionais especializados monitorar as condições de saúde de um paciente para atuar sob indicações de um estado anormal [23]. Esse acompanhamento pode identificar antecipadamente a necessidade de alteração na medicação ou mesmo o diagnóstico de uma doença na fase inicial. Segundo Scanail et al. [103], o telemonitoramento de longa duração proporciona dados clinicamente úteis, que podem permitir aos médicos uma tomada de decisões com maior conhecimento, seja para monitorar deteriorações nas condições crônicas, seja para avaliar a resposta de um paciente a determinado tratamento.

Em geral, um sistema de telemonitoramento na área de assistência domiciliar compreende três elementos: a casa do paciente, um centro de supervisão (hospitais, empresas de assistência domiciliar, ambulatorios ou centros médicos) e uma rede de comunicação interligando os dois primeiros. Somente nos últimos anos a casa do paciente começou a ser pensada como um ambiente de computação pervasiva voltada para o tratamento de saúde (conceito de *pervasive home care*), de modo que diversos recursos computacionais sejam utilizados para o bem-estar e a promoção da saúde do residente.

Por outro lado, no centro de supervisão, as tecnologias já são largamente utilizadas há muito tempo, e a área de informática médica concentra a maior parte desses avanços. A interligação feita pela rede de comunicação é a forma de incluir novos serviços relacionando a casa ao centro de supervisão. A rede permite que o usuário tenha acesso, seja informado e produza informações independentemente do lugar onde se encontra, possibilitando um serviço completo de tratamento de saúde personalizado (*personalised healthcare*).

Nesse contexto, o monitoramento diário ou contínuo de saúde realizado em casa deve ser repensado para potencializar os seus benefícios. Essa constatação é motivada por novas tecnologias que farão parte do cotidiano das pessoas em suas residências. Pensar em ambientes ricos em computação e comunicação auxilia na compreensão de quais serão as questões alvo ou áreas de atuação da assistência domiciliar, bem como os requisitos para viabilizar sistemas eficientes para essa demanda.

Ao mesmo tempo, notamos que ainda estão em definição arquiteturas factíveis que sirvam de infraestrutura para execução das aplicações da área de tratamento de saúde em ambientes pervasivos. As propostas atuais de assistência domiciliar à saúde tratam questões pontuais que atendem parcialmente aos requisitos. Portanto, é necessário um levantamento de requisitos para definir uma arquitetura integrada para esse tipo de aplicação. Mais do que isso, queremos investigar como é possível decidir usando informações de contexto.

No presente Capítulo, duas arquiteturas são elaboradas para descrever os atores envolvidos na telessaúde e para definir o posicionamento de um mecanismo de Decisão. Os requisitos para as aplicações de *pervasive home care* são também apresentados.

Este estudo vai ao encontro do rompimento do modelo de telemonitoramento em que os dados são transmitidos diretamente ao provedor de saúde, visando a uma atuação mais pró-ativa nas questões relacionadas à saúde. Pretendemos, da mesma forma, capturar os aspectos importantes para a concepção e o projeto de aplicações pervasivas na assistência domiciliar à saúde.

O Capítulo está estruturado da seguinte forma: a Subseção 2.1 discute sobre assistência domiciliar com computação pervasiva, trazendo a visão de que o ambiente domiciliar está associado a diversas questões e pessoas envolvidas no tratamento de saúde, o que leva a inúmeras possibilidades de novas aplicações. Com isso, são apresentadas uma arquitetura de integração dos atores e a identificação de requisitos. A Subseção 2.3 mostra uma arquitetura de decisão para a *pervasive home care*. Essa arquitetura enfatiza o suporte para o tratamento das informações de contexto do ambiente domiciliar. Por fim, são apresentadas as conclusões do Capítulo.

## 2.1 Assistência Domiciliar com Computação Pervasiva

Esta Subseção apresenta inicialmente um cenário de assistência domiciliar que motiva o desenvolvimento de soluções para o monitoramento inteligente do paciente. Em se-

guida, é mostrada uma visão abrangente da assistência domiciliar, com vistas à posterior elaboração de uma arquitetura em alto nível e à discussão de seus requisitos específicos.

### 2.1.1 Exemplo de Cenário

O tratamento de doenças em casa, ou mesmo a vida assistida de idosos, é uma área muito abrangente, pois, tratando-se de saúde, envolve o bem-estar e, ao mesmo tempo, os vários cuidados que devem ser tomados dependendo do tipo de doença. Estudos preliminares [54] sobre quais doenças são objetos da assistência domiciliar com uso de tecnologia citam: doenças crônicas do coração, doenças pulmonares obstrutivas crônicas, tumores/cânceres, diabetes, tratamento de feridas, asma, ansiedade e acidente vascular cerebral. Da mesma forma, esse tipo de assistência domiciliar favorece o acompanhamento de tratamentos (após uma cirurgia ou durante a recuperação dos movimentos, por exemplo), de casos de demência ou de perda de memória.

O exemplo fictício a seguir contextualiza o tratamento de saúde a fim de buscar uma visão com maior completude da área. Ele serve também para ressaltarmos algumas demandas e problemas relacionados à assistência domiciliar. Acreditamos que essa visão que buscamos complementa as ideias de Stankovic em [105] e [106], o qual afirma que as informações holísticas e de longa duração de saúde sobre os indivíduos possibilitarão dramáticas melhorias em seu tratamento, graças a uma melhor compreensão global dos problemas de saúde e a eficácia do tratamento.

*João é um paciente idoso com diabetes, tratado por uma equipe multidisciplinar de um hospital que tem um núcleo de assistência domiciliar. Essa equipe faz visitas semanais a sua casa e o orienta no sentido de estimulá-lo a fazer o controle glicêmico. Essa consciência de seu quadro clínico permite que o paciente tenha maior responsabilidade com a sua alimentação e o motiva para a prática de exercícios físicos. Outros acompanhamentos são também realizados, coletando dados de batimento cardíaco, pressão arterial e peso. No entanto, uma visita por semana do profissional de saúde não é suficiente para acompanhar as flutuações de estado que João experimenta. No seu dia a dia, algumas atividades têm se afastado de seu comportamento habitual, pois o paciente tem ido muitas vezes ao vaso sanitário e permanecido por muitas horas no sofá da sala. João tem também experimentado temperaturas altas durante as tardes na sala de sua casa, o que lhe ocasiona irritabilidade. Devido à pouca percepção do paciente para detetar situações críticas, a equipe médica colocou um sensor*



*de ritmos cardíacos capaz de acionar o serviço de emergência. Frequentemente essa chamada ocorre, pois após alguns minutos em que o senhor varre a casa, um de seus hábitos, o serviço é invocado.*

O exemplo reforça a ideia de que existem diversos aspectos envolvidos para obter uma visão da área de tratamento de saúde em ambientes pervasivos. O monitoramento de saúde eficiente só será obtido se esses aspectos forem compreendidos e classificados. Assim, verificamos que é necessária uma investigação descrevendo os pontos de pesquisa, propostas e aplicações relevantes na área.

### 2.1.2 Em Direção a uma Visão Abrangente da Assistência Domiciliar

A assistência domiciliar com computação pervasiva envolve ambientes inteligentes (a residência do paciente) e recursos externos, que podem ser tanto um Centro de Supervisão quanto um serviço especializado de diagnóstico, provido por entidades independentes.

A assistência domiciliar em ambientes pervasivos (*pervasive home care*) também pode ser vista como uma aplicação de tratamento de saúde em ambientes inteligentes. Dessa forma, arquiteturas para ambientes inteligentes também podem ser consideradas na construção de uma arquitetura para *pervasive home care*. Adicionalmente, as aplicações devem fazer uso intenso de informações de contexto. Segundo o estudo de Marrón et al. [74] sobre o estado da arte em redes de sensores, o projeto de mecanismos sensíveis ao contexto para coleta, processamento e entrega de dados pela rede é um dos mais promissores e desafiadores problemas de pesquisa. Para iniciar o desenvolvimento de uma arquitetura devemos primeiramente definir os componentes envolvidos.

Em nossa visão, os componentes envolvidos no monitoramento estão representados na Figura 2.1. A arquitetura serve para identificar, sob a perspectiva do *pervasive home care*, os atores envolvidos, as questões pertinentes ao monitoramento e os fluxos de informações de/para fora de casa. Alguns atores específicos podem ser: a família, o médico ou o cuidador. Muitos trabalhos têm sido desenvolvidos explorando interfaces e soluções específicas para cada papel [84]. Neste trabalho, não aprofundamos essas interfaces, mas discutimos sobre fluxos de informação e outras questões relevantes de aplicação para monitoramento em *pervasive home care*.

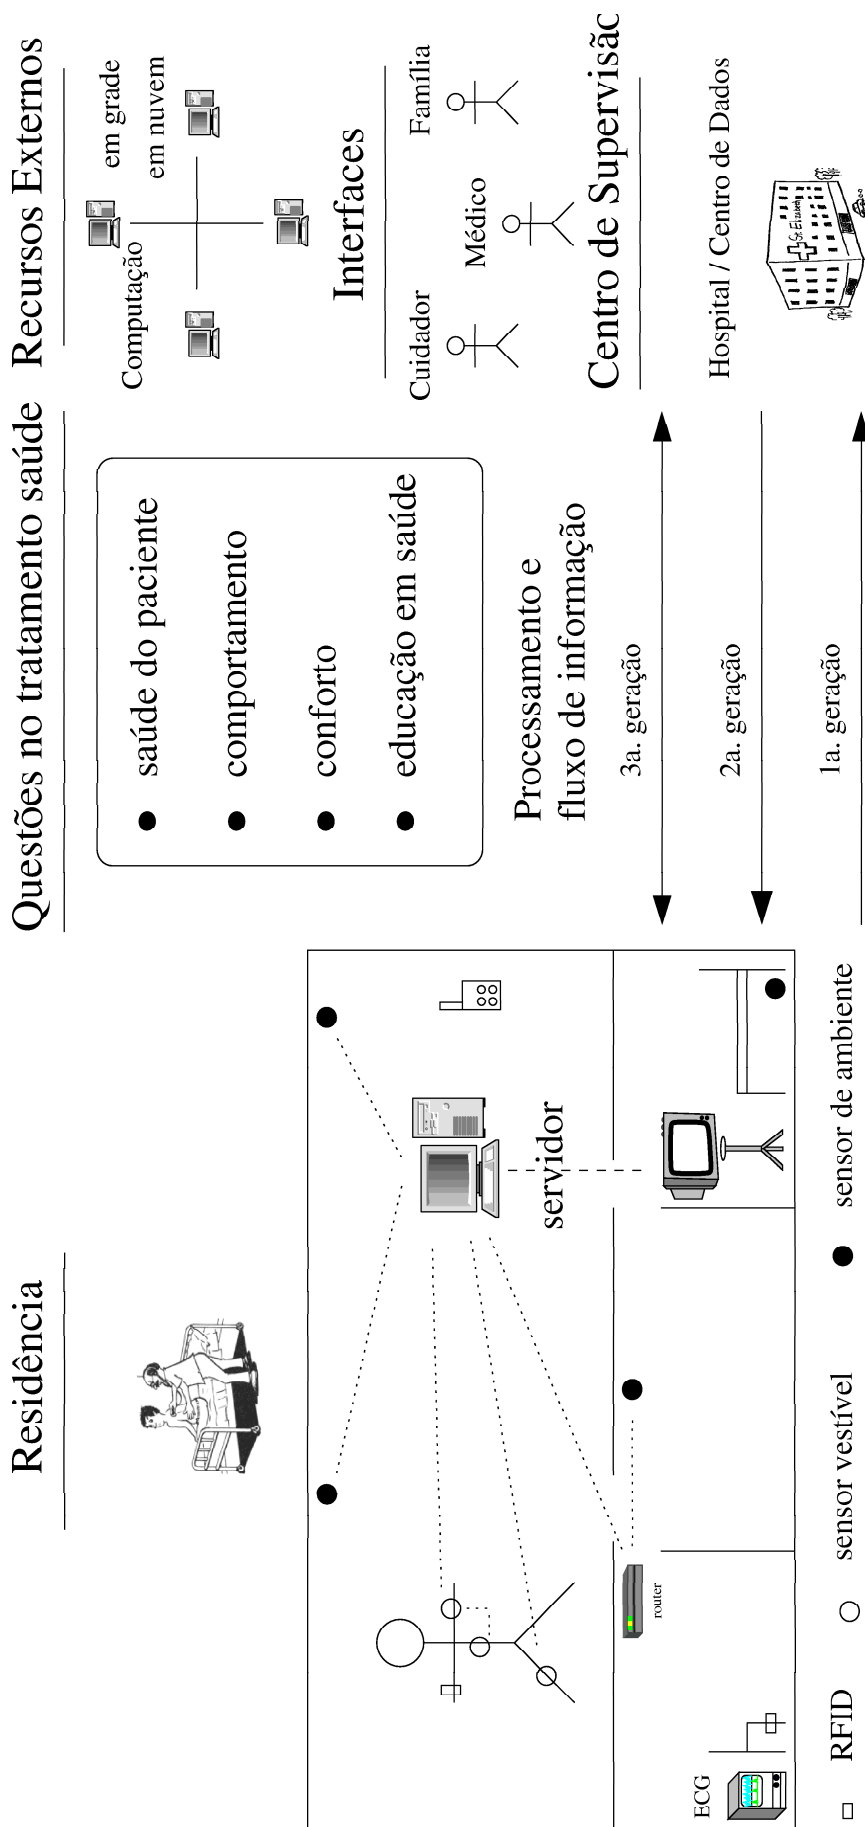


Figura 2.1: Arquitetura de integração dos atores envolvidos na tele saúde

O processamento e fluxo de informações na assistência domiciliar da Figura 2.1 é apresentado na forma de gerações. O lado em que se encontra a seta indica o local onde ocorre o processamento e a direção para onde seguem as informações. Na primeira geração ocorre somente a transferência de dados monitorados do paciente para um Centro de Supervisão ou centro de dados especializados. Esse modelo é ainda muito utilizado e representou grande parte dos projetos de pesquisa, por exemplo, na União Europeia [1]. No entanto, o paciente não é submetido a um acompanhamento local de seu estado em tempo real, o que exige que todos os dados sejam constantemente enviados para uma entidade externa, sem conseguir filtrar o que é importante.

Na segunda geração, o ambiente é inteligente e passa a solicitar recursos do meio externo. Nessa versão, pode-se solicitar serviços de vídeo educativo, por exemplo, além de permitir o desenvolvimento de sistemas capazes de assistir as tarefas da vida diária do paciente.

A terceira geração apresenta uma transparência de execução de aplicativos e de transferência de dados, de modo que um verdadeiro sistema universal de informações de saúde possa ser implementado - uma realidade ainda distante de nossos dias. A situação do paciente pode ser avaliada em sua casa e confirmada por um profissional, independentemente de lugar, por meio de mecanismos com graus diferentes de alarmes, permitindo a comunicação entre as partes envolvidas e atuação via dispositivos da residência. O Centro de Supervisão, que nas primeiras gerações suportava exclusivamente a tarefa de monitoramento, agora tem um papel maior de controle e coordenação, envolvendo rotinas de diagnóstico complexas e fazendo uso de recursos, como grades computacionais com delegação de tarefas [45] e computação em nuvem [114].

O tratamento de saúde em casas inteligentes com suporte da computação pervasiva pode ser mais bem compreendido e, dessa forma, aperfeiçoado, se forem discutidos os principais benefícios e possibilidades de aplicações advindas da união de sistemas inteligentes com aplicações pervasivas. Na área de ambientes inteligentes, essa união está presente e pode representar o próximo desafio ou passo na evolução da inteligência artificial [93]. Sendo assim, em relação aos cuidados em casa, nós introduzimos as grandes questões que podem ser contempladas pela área de *pervasive home care*. Tais questões envolvem (conforme Figura 2.1) a saúde do paciente, o comportamento, o conforto da pessoa e a educação em saúde. A seguir cada um desses itens é discutido.

A primeira questão, a saúde do paciente, é representada pelo monitoramento dos sinais vitais, uma das grandes preocupações na assistência domiciliar. Um dos objetivos

é lançar (acionar) alarmes quando os valores saem da normalidade. No caso de pacientes com problemas cardíacos, esse acompanhamento em tempo real é primordial. A reação do sistema quando há distorções em relação aos seus valores normais deve ser rápida e, por isso, determina requisitos de tempo real e confiabilidade para o sistema.

A observação do comportamento é de fundamental importância no acompanhamento do dia a dia de idosos em casa. Pacientes com problemas cognitivos, como diminuição da memória ou demência devida à doença de Alzheimer, por exemplo, requerem um maior auxílio em suas atividades diárias. Logo, é interessante que essas pessoas tenham o suporte de um mecanismo memorando-lhes suas atividades realizadas durante o dia. Nesse sentido, é comum que tais pacientes repitam erroneamente uma medicação, ou se esqueçam de realizar uma rotineira medição de pressão arterial.

Em outros casos, pode-se querer saber com que frequência um paciente está indo ao banheiro [120], ou mesmo aprender seus hábitos de sono. Detetando-se, por exemplo, determinado nível de luminosidade e a presença ou não do idoso na cama, seria possível um aviso sonoro que denunciasses sua aproximação da porta fechada, evitando acidentes.

Já em [15] é dada importância para uma análise do estilo de vida do paciente, pois, segundo o autor, uma deterioração cognitiva pode causar ao paciente um início de perda do sentido do tempo e as atividades de dia e noite podem ser invertidas. No entanto, quando considerado o monitoramento do comportamento, novas análises são possíveis. Uma consulta ao sistema poderia informar qual a relação entre a administração do remédio anti-térmico, os banhos tomados e a febre do paciente ao longo das últimas 12 horas. Nesse ponto, acreditamos que os hábitos ou atitudes do morador têm influência sobre sua saúde, especialmente nos tratamentos de longo prazo. Trata-se, porém, de situações de difícil percepção pelo profissional de saúde, pois dependem do relato das pessoas envolvidas.

Em relação ao conforto, terceira questão aqui abordada, há que se notar a relevância da automatização de tarefas a fim de trazer maior praticidade e segurança nas atividades diárias. Uma situação que podemos imaginar é a da TV ligar em um determinado horário e canal favorito quando o residente estiver em casa, além de ser automaticamente aumentado o volume da campainha do telefone. Assim, considerando pessoas com idade avançada, pode-se pensar em treinar um sistema para assisti-las nas atividades que demandem atenção ou esforço, automatizando o acionamento ou desligamento de dispositivos controlados pelo sistema domiciliar.

Por fim, no que diz respeito à educação em saúde, pode-se fazer uso das tecnologias para que, em casos de doença, os meios de comunicação existentes na casa direcionem,

por exemplo, para programas que discutam sobre a enfermidade em questão. O usuário poderia também receber em casa anúncios de palestras ou eventos que estejam relacionados com o problema enfrentado e com o aumento da sua qualidade de vida. Em um nível mais sofisticado, o idoso poderia ser incentivado a participar de terapias em grupo (suportado também por comunidades virtuais e redes sociais [40]), por intermédio de tecnologias como a TV digital ou simplesmente receber vídeos em dispositivos móveis (como um *Podcast*). De qualquer forma, esses dispositivos devem privilegiar, para o caso de idosos, o uso de mensagens de voz e tamanhos de fontes de letras maiores.

Todas essas quatro questões (a saúde do paciente, o comportamento, o conforto da pessoa e a educação em saúde), ou grandes objetivos, indicam a união das áreas de *home care* e ambientes inteligentes. No entanto, a maior parte das pesquisas trata essas questões de forma isolada.

### 2.1.3 Funcionalidades Encontradas em Aplicações *Pervasive Home Care*

A fim de contemplar as principais questões envolvidas no monitoramento em casa, torna-se necessário também verificar as funcionalidades já existentes em aplicações *pervasive home care*. Esta Subseção apresenta as mais frequentemente encontradas.

- **Identificação e localização de pessoas ou objetos:** são utilizados RFIDs (*Radio Frequency IDentification*) na forma de etiquetas em objetos, como braceletes no paciente, que permitem a localização, o rastreamento e a sua identificação. A localização das pessoas ocorre geralmente por radiofrequência ou ultrassom. Os algoritmos utilizados são executados continuamente, seja em dispositivos móveis que recebem os sinais e fazem o processamento, seja em computadores pessoais que somente processam os dados sensorizados. Existem diversas propostas nessa área [32] [47] [78] que servem como base para o desenvolvimento de aplicações sensíveis ao contexto.
- **Análise de comportamento:** com essa abordagem é possível detetar desvios de comportamento que estejam prejudicando a saúde do paciente, além de identificarem-se condutas que estejam fora das recomendadas. Diversas pesquisas investigam essas questões por intermédio do aprendizado de padrões de comportamento individuais, como, por exemplo, em [13] [18] [65]. Uma técnica que pode ser usada neste caso é a probabilidade da ocorrência de cada evento de interesse (por exemplo, em [120]). Nessa funcionalidade, evidencia-se o fato de que se devem inferir novas informações

de contexto a fim de obter níveis de abstração e de interpretação mais elevados.

- **Deteção e alarme de emergências:** as situações que mais exigem notificação são aquelas em que a pessoa não consegue reagir física ou conscientemente para chamar um atendimento de emergência. É assim na identificação de momentos críticos para dados fisiológicos e na ocorrência de acidentes ou quedas. Contudo, detetar emergências dentro de casa é um grande desafio. Segundo Laramée et al. [68], mesmo em unidades de tratamento intensivo existe uma alta incidência de alarmes falsos e clinicamente insignificantes. Já em ambientes menos controlados como uma casa, onde muitas variáveis estão envolvidas e os mecanismos de inferência de informações estão mais propensos a erros, a tendência é maior de haver situações em que um sistema deixa de lançar alarmes para casos verdadeiramente críticos.

Então, um desafio importante é a representação da situação crítica. Um modelo que pode ser adotado é um conjunto de regras, como em [113] [117], que utilizam regras do tipo Evento-Condição-Ação (ECA). As políticas, que expressam como o comportamento do sistema é governado, são ativadas por eventos. Se as condições sobre uma política são satisfeitas, a política causa as ações especificadas [111].

Por outro lado, não basta caracterizar de forma detalhada as condições de emergência, caso não haja conhecimento do histórico da pessoa e o correto tratamento dos dados coletados. O histórico pode viabilizar um processo de individualização, isto é, considerar os dados anteriores do paciente na determinação de seu estado. Já o tratamento dos dados envolve um raciocínio eficiente e que seja robusto para o processo de decisão, já que é complexo caracterizar todas as situações de emergência possíveis.

- **Lembretes ou Sistemas de Recomendação:** um exemplo típico é um lembrete de um remédio, em que o contexto pode ser utilizado para dar o aviso ao paciente sobre o medicamento que deve ser usado. Por exemplo, se ele estiver assistindo a TV, uma informação com esse lembrete será mostrada na tela, ou a mensagem será entregue para um cuidador com a agenda dos medicamentos a serem aplicados. Uma forma não tão rígida de controle do uso de remédios (sem *hardware* específico) é uma etiqueta RFID colocada nos recipientes de remédio [118], com o sistema registrando mudanças de localização. Outras aplicações para lembretes envolvem dietas alimentares [10] e plano de exercícios [25]. Os sistemas que dão suporte às pessoas com deficiência de memória estão entre os sistemas de vida assistida que certificam se as atividades da vida diária estão sendo feitas de forma correta e



Figura 2.2: Sensores: (a) WristClinic<sup>TM</sup>, (b) MiniClinic Wrist-unit, (c) Wireless Blood Pressure Monitor BP100, (d) aLsis emergency unit da TelcoMed [62]

trazendo bem-estar às pessoas. Um estudo que apresenta uma classificação para sistemas de vida assistida pode ser encontrado em [91]. Cabe ressaltar ainda a motivação associada a essa funcionalidade na questão da aderência do paciente ao tratamento. Nesse sentido, ferramentas de apoio à tarefa de monitoramento têm cumprido esse papel, como, por exemplo, em [29].

As aplicações pervasivas de tratamento de saúde em casa (*pervasive home care*) apresentadas deixam claro que deve existir um suporte de sensores e técnicas avançadas para cumprir os objetivos para os quais foram projetadas. Diferentemente de aplicações mais tradicionais de telessaúde em casa (*home telehealth*), as aplicações pervasivas sugerem uma fusão de dados de sensores e uma atuação no momento em que ocorrem mudanças de contexto. A seguir, fazemos algumas discussões sobre sensores e subsistemas usados no desenvolvimento dessas aplicações.

#### 2.1.4 Aspectos Tecnológicos: o Uso de Sensores

A fabricação de múltiplos sensores em um dispositivo, como em [4], demonstra a autonomia pretendida com o avanço na área de sensores. Os três primeiros sensores apresentados na Figura 2.2 são capazes de monitorar em conjunto frequência cardíaca, ECG de 1 eletrodo, pressão arterial, regularidade do ritmo cardíaco, frequência respiratória, taxa de oxigenação do sangue (SpO<sub>2</sub>) e temperatura do corpo. Nesses sensores, a solução incorpora o recurso para transmissão sem fio. No entanto, a atual disponibilidade de equipamentos médicos com transmissão sem fio faz com que os equipamentos existentes tenham que ser integrados em módulos com transmissores, como, por exemplo, em [44] [50] [60].

A diminuição dos preços dos sensores permitirá que uma maior parcela da população adquira esses equipamentos. Alguns trabalhos científicos têm proposto soluções de baixo

custo, como, sensores de pressão [77], contadores de passos (pedômetros) e sensores de presença (utilizados para detetar ausência ou presença de pessoas/movimentos) [34] com vistas ao reconhecimento de atividade. No entanto, o reconhecimento efetivo da atividade só é possível com o uso de acelerômetros, que medem a aceleração, tornando possível medir a frequência e a intensidade dos movimentos.

Um dispositivo que integra dados fisiológicos e a atividade é o *SenseWear BMS* da BodyMedia [5], que infere, entre outros eventos, quando a pessoa dormiu. Além do acelerômetro incorporado a uma braçadeira, o dispositivo utiliza fusão de dados para chegar a essa conclusão, usando a temperatura da pele, resposta galvânica da pele (*galvanic skin response*<sup>1</sup>) e fluxo de calor (*heat flux*).

Os trabalhos que empregam o acelerômetro como parte de uma BAN (*Body Area Networks*) mostram alguns dados sobre a utilização da rede. Em [86], um acelerômetro de 3 eixos, com amostras de  $16\text{bits}$ , numa taxa amostral de  $200\text{Hz}$ , usa uma largura de banda mínima de  $9,6\text{Kbps}$  ( $200\text{Hz} * 3 \text{ eixos} * 16\text{bits}$ ). No projeto SATIRE [47], testes verificaram que um bom desempenho para a aplicação de reconhecimento de atividades é obtido com  $68\text{bytes}$  por pacote e  $55\text{Hz}$ , o que resulta em  $30\text{Kbps}$ . No entanto, a despeito do uso da rede, é comum a análise ou o pré-processamento dos dados do acelerômetro no próprio dispositivo embarcado, como feito em [29], usando um SunSpot.

Por sua vez, a informação de contexto localização em coordenadas da pessoa, entendemos que não é de fundamental importância em aplicações de assistência domiciliar, pois é suficiente saber se existe movimento no cômodo onde se encontra o sensor – dispositivos em cadeiras e leitos também são populares, ajudando na identificação da localização/situação. Alguns trabalhos [120] têm utilizado esta variável para detetar comportamentos anormais, baseados na informação do tempo que a pessoa permanece em cada cômodo da casa. Num outro trabalho [34], os períodos de inatividade são computados por sensores de movimento, sem relação com os cômodos. Assim, após o sistema aprender os horários rotineiros de movimentação, ele alerta sobre situações anormais de longos períodos de inatividade. Da mesma forma, a localização pode ser útil quando agregada com outras informações. Por exemplo, se a pessoa está no quarto e não apresenta movimentos durante determinado período noturno, então há maior certeza para afirmar que o paciente está dormindo, desde que seus sinais vitais estejam como esperado.

---

<sup>1</sup>a GSR mede as variações da capacidade da pele de conduzir pequenas correntes elétricas, estando relacionada com a atividade das glândulas sudoríparas.



#### 2.1.4.1 Perspectivas sobre Redes de Sensores no Ambiente Domiciliar Pervasivo

É interessante fazer uma descrição dos ambientes pervasivos em uma situação ideal. Essa visão, possível em um futuro próximo, mostra como os objetos interagem e tomam decisões, indo além das restrições físicas de tamanho, baixo consumo, usabilidade, capacidade de comunicação sem fio. Conforme Weiser [119], devemos tentar conceber uma nova maneira de pensar sobre computadores no mundo. Assim, fazemos a seguir algumas considerações possíveis a respeito do desenvolvimento da tecnologia.

Em uma perspectiva de médio prazo, nós vislumbramos sensores com autonomia para tomar decisões, espalhados pelo ambiente e pelo corpo da pessoa. Essas decisões envolveriam desde a extração de características relevantes dos dados brutos, até o lançamento de alarmes avisando de um agravamento de estado. Os sensores poderão também colaborar entre si, compartilhando decisões e entrando em consenso, por exemplo, sobre o horário em que atuarão ou se serão desativados. Para tanto, são necessárias novas arquiteturas que permitam a atuação mais próxima possível do sensor, como as *Wireless Sensor and Actor Networks* (WSAN) [8]. O conhecimento do domínio do problema, isto é, o conhecimento médico, é essencial nesse processo de tomada de decisão.

No ambiente, ocorrem trocas de informações entre sistemas ou objetos. Por exemplo, o sistema que controla a temperatura ambiente recebe uma mensagem do monitor de frequência cardíaca do residente, avisando sobre um aumento gradativo do batimento.

A interoperabilidade entre biosensores, atuadores e agregadores de dados de sensores será um tópico de pesquisa permanente. Os sensores de fabricantes diferentes entrarão no ambiente e serão reconhecidos pelo sistema pervasivo. Mesmo que tenham a mesma funcionalidade, os sensores terão acurácias específicas, atuando em contextos diferentes. Assim, o sistema deve saber de onde, como e quando veio a informação [107]. Todas essas informações devem ser consideradas na interpretação do contexto.

Em [31], é enfatizado que a inferência de contexto de forma acurada é um grande desafio na área de computação pervasiva. Um exemplo descrito por tal trabalho refere-se ao uso da informação sobre a localização de uma pessoa em um sistema de segurança. Uma localização incorreta pode implicar em sérios riscos se forem concedidos determinados direitos de controle de acesso para um indivíduo. Segundo o autor, esse erro pode levar ao uso inapropriado de recursos, ao aborrecimento do usuário ou à falha do sistema pervasivo.

A inferência e a conseqüente tomada de decisão, além de produzirem saídas para os

requisitos funcionais da aplicação, também serão usadas para os requisitos não funcionais, como, por exemplo, economizar energia ou desligar sensores em períodos quando são considerados desnecessários. Em momentos mais críticos, os sensores serão mais consultados, o que evidencia a ideia de que, na maior parte das decisões, o conhecimento do domínio do problema, isto é, o conhecimento médico, é essencial.

A comunicação entre o receptor de dados e sensores pode ser bidirecional, pois o servidor também pode requisitar ajustes na frequência das medidas dos sensores. O fluxo bidirecional pode ser otimizado se a pessoa utilizar um dispositivo (como um relógio de pulso) que concentra a comunicação de vários sensores acoplados ao corpo. O concentrador ou agregador faz a interface com os sensores do corpo para ajustar a frequência do monitoramento, por exemplo. A ideia de agregadores na forma de roupa computacional já é apresentada em alguns trabalhos [123].

Espera-se também que os sistemas identifiquem mudanças no comportamento com o objetivo tanto de diagnosticar precocemente uma doença quanto para evidenciar efeitos causados durante um tratamento. Sinais de agitação, detetados por sensores de movimento, por exemplo, podem revelar uma má aceitação de algum medicamento. O sistema deverá identificar quais são essas variáveis que levam a situações indesejáveis.

## 2.2 Requisitos da Assistência Domiciliar com Computação Pervasiva

Os problemas tradicionais com o uso de sensores sem fio são agravados no caso do tratamento de saúde. A visão abrangente, apresentada na Subseção 2.1.4.1, demonstra que os sistemas devem lidar com dados e diferentes técnicas para obter novas informações, a fim de poder tomar decisões eficientemente. A inferência de informações que sejam relevantes para os envolvidos no tratamento de saúde representa um grande desafio de pesquisa, pois depende da coleta de dados corretos de várias fontes de contexto. Assim, a área de *pervasive home care* traz requisitos específicos para o projeto de soluções. Esta Subseção divide os requisitos em essenciais e desejáveis.

### a. Requisitos Essenciais

- Facilidade de uso. Exige-se uma Interface Homem-Computador adaptada para leigos em informática. Essa facilidade ou mesmo transparência na utilização dos meios computacionais deve permitir um rápido entendimento e também a personalização

dos sistemas. Em relação aos sensores, quanto menos invasivos e mais práticos, maior será a adoção desses sistemas. O uso da televisão digital interativa também é um recurso a ser explorado por ambientes pervasivos, principalmente na promoção do auto-cuidado.

- Dependabilidade ou fidedignidade. Esse conceito engloba a correção, segurança e confiabilidade [33]. É necessário não prejudicar ou afetar o paciente, por exemplo, fazendo algo errado como deixar de gerar um alarme. Garantir privacidade no acesso aos dados dos pacientes é crucial, como também seguir as regulamentações e os padrões estabelecidos pela área da saúde. Nesse item, muitas questões estão envolvidas, como a privacidade do paciente, o armazenamento seguro da informação e a confidencialidade dos dados. Soluções com o uso de autenticadores, criptografia e políticas de acesso aos dados devem ser adotadas.
- Tolerância a falhas. Por trabalhar com sensores, o sistema está sujeito ao uso incorreto do sensor, como, por exemplo, quando o paciente se movimenta muito durante uma medição de pressão arterial, e à interferência na transmissão sem fio dos dados. A detecção de erros é crítica nessa categoria de sistemas envolvendo vidas. É necessário identificar rapidamente tais erros para que não sejam propagados e comprometam a análise dos dados. Além disso, sabendo que os dados estão continuamente sendo gerados, um meio confiável de armazenamento é necessário, aliado ao uso de canais redundantes para superar os problemas de comunicação.

As falhas podem também ocorrer por insuficiência de bateria, tendo efeito na transmissão/recepção (atividade que mais gasta energia [120]) ou mesmo ficando sem operar, em um sistema no qual não se desejam recargas seguidas ou substituição de sensores (e.g. sensor embutido no corpo da pessoa).

Outro aspecto relativo à tolerância a falhas é a possibilidade de execução periódica de vários programas especialistas, com o objetivo de diagnosticar uma determinada doença. Essa abordagem n-versões garante que se tirem conclusões mais confiáveis acerca da situação do paciente, auxiliando na redução de alarmes falsos.

Essa visão de computação pervasiva em ambientes inteligentes é possível devido à redução do preço de plataformas para redes de sensores, atuadores e de dispositivos computacionais acoplados ao corpo das pessoas. Assim, a computação pervasiva suscita diversas questões a serem resolvidas e motiva, por exemplo, a pesquisa supondo fontes de contexto redundantes [32] ou o uso do conceito de “qualidade do contexto” para tomar decisões acerca do recurso mais confiável em um determinado

contexto [59]. Essa característica relacionada à tolerância a falhas é importante no monitoramento de sinais vitais, por exemplo, em pessoas com doenças cardíacas. A viabilidade de programação dessas aplicações adaptativas é possível graças a arcabouços como [26], que negociam em tempo de execução qual a melhor configuração (*self configurable systems*). Há que se ressaltar ainda que é necessário o uso de fusão de dados e técnicas de validação de dados para detetar falhas [81].

Constitui também um requisito o registro em *log* de todos os fatos ou regras que foram aplicadas. Essa informação permitirá identificar o motivo pelo qual determinada ação foi ou não tomada. As aplicações com essas propriedades são reconhecidas como aplicações responsáveis (*accountable applications*) [96].

- Raciocínio. Segundo nossa visão, as principais questões que motivam o uso do raciocínio no monitoramento de um paciente em ambientes pervasivos são: a grande quantidade de informações geradas, as relações que devem ser estabelecidas entre os dados coletados (por exemplo, o que um dado influencia em outro) e a carga de incerteza que esse tipo de monitoramento carrega. Segundo Adlassnig *et al.* [7], o conhecimento clínico e os dados médicos são inerentemente incertos. Por isso, aumentam as necessidades de gerenciamento e técnicas de inferência eficientes sobre os dados. Entre os temas que envolvem o raciocínio, o aprendizado tem papel importante. O aspecto que torna o aprendizado um requisito essencial no *pervasive home care* é a necessidade de individualização do sistema. A manutenção dos serviços oferecidos deve ser específica ao paciente, principalmente quando o médico configura parâmetros de monitoramento, envolvendo limites para disparar alarmes, taxa de amostragem e frequência de comunicação para armazenamento estável em um banco de dados. De uma forma mais abstrata, a aprendizagem permite que o sistema se prepare para tratar a grande quantidade de dados gerados e inferidos, e reconhecer as relações entre eles, para então poder responder de maneira eficiente e rápida às variações mais importantes do ambiente monitorado.

Dada a importância de um controle rigoroso, por exemplo, sobre pacientes diabéticos, ajustar adaptativamente o sistema conforme as variações nos dados de monitoramento é um importante tópico de pesquisa. A questão é complexa, pois podemos perceber inúmeros fatores que influenciam o monitoramento de dados fisiológicos, como, por exemplo, influência dos remédios administrados, fatores de risco (como obesidade), gestação ou mesmo doenças paralelas. Estas variações também podem ser influenciadas pelo comportamento ou pelas condições do ambiente. Assim, por exemplo, enquanto a pessoa está comendo ou caminhando, a sua pressão arterial

naturalmente aumenta [36] [101]; além disso, a temperatura do ambiente também tem influência sobre a pressão arterial [76].

Em [112], é citado o caso de pacientes diabéticos, cujos níveis de açúcar no sangue tendem a cair durante a noite em relação ao dia e também após as refeições. Portanto, existe a necessidade de uma fase de treinamento para definir a faixa de valores considerada normal em cada exame/sinal vital para o paciente.

Outra exigência para o aprendizado é a localização da pessoa, informação de contexto comumente usada. Em residências, a localização é fator importante para a interpretação de um determinado contexto, como, por exemplo, o tempo de permanência em um determinado lugar da casa, relacionado, de alguma forma, com a atividade executada pelo paciente, como cozinhar, dormir ou tomar banho. Dessa forma, os sistemas de *pervasive home care* exigem um elevado grau de individualização e de inteligência para interpretar o contexto.

### **b. Requisitos Desejáveis**

- **Qualidade de serviço:** Deve-se certificar que os usuários obtenham dados confiáveis e no momento correto. Incluem-se aqui os requisitos de tempo real *soft* e a garantia de entrega dos dados coletados. Acreditamos que as tecnologias de rede sem fio resolvam as questões inerentes à comunicação para redes de sensores em ambientes fechados. Mesmo assim, associar parâmetros de qualidade de serviço a cada sensor ou serviço parece ser um caminho inevitável quando há grande tráfego na rede sem fio ao mesmo tempo em que se medem sinais vitais. Essa visão é compartilhada na demonstração feita em [123]. Da mesma forma, mecanismos que consigam reduzir o tráfego na rede, diminuindo a frequência de monitoramento em determinadas situações, resultam em uma melhoria da qualidade de serviço, além de contribuírem para a economia de energia da bateria dos equipamentos.
- **Acesso às informações atualizadas do paciente:** Por exemplo, quando um profissional de saúde faz uma visita, ele pode querer executar um serviço de diagnóstico a partir do seu PDA, com dados do paciente. Por outro lado, um familiar pode desejar saber remotamente o estado do paciente. Abre-se, pois, espaço para discutir onde os dados serão armazenados e que mecanismos serão usados para acessá-los.

Devido à quantidade de informações geradas, muitas dessas informações são irrelevantes para o problema e sua transferência para uma área de armazenamento fora da residência resulta em desperdício. Portanto, sistemas flexíveis que possibilitem

a transferência de dados relevantes para um hospital e que permitam, ao mesmo tempo, armazenar os dados localmente ou mesmo guardar informações em um nível mais alto são alternativas interessantes de serem estudadas. Esses sistemas devem contar com uma infraestrutura de segurança, com possibilidade de acesso vindo de fora. A disponibilidade de informações terá também que se preocupar com diferentes visões dos sistemas para os pacientes, profissionais de saúde, cuidadores e familiares, o que determina a definição de papéis (como em [90]) neste cenário.

- Flexibilidade e heterogeneidade: A solução deve estar apta para interagir com um conjunto heterogêneo de *hardwares* e *softwares*. É necessária uma infraestrutura aberta para admitir novos serviços ou componentes. A adição ou substituição de um sensor por outro de mesma funcionalidade não deve exigir que o sistema tenha que ser reconfigurado em seu mecanismo de raciocínio (por exemplo, regras que avaliam a pulsação do paciente).

## 2.3 Arquitetura de Decisão para *Pervasive Home Care*

Este trabalho tem como objetivo a concepção e desenvolvimento de um mecanismo de Decisão para identificar situações críticas em um ambiente domiciliar pervasivo para monitoramento da saúde de um paciente. Como cenário, consideramos uma pessoa idosa vivendo sozinha em uma residência e recebendo acompanhamento de profissionais de forma não contínua. Para iniciar essa concepção é proposta uma arquitetura de Decisão (Figura 2.3), contendo um mecanismo capaz de gerar alarmes de forma confiável.

A arquitetura apresenta um esquema simples, em que todos os sensores ou equipamentos médicos têm comunicação com uma Central de Saúde Residencial (CSR). A CSR tem por objetivo tratar de forma completa a saúde do paciente e, por isso, seu papel é de um gerenciador de auto-cuidados (*self care manager*). O gerenciamento da saúde do paciente é feito por intermédio de um Plano de Cuidados [29].

A motivação para a adoção desta arquitetura é discutida na Subseção 2.3.1, seguida da descrição das principais variáveis a serem monitoradas, na Subseção 2.3.2.

### 2.3.1 A Central de Saúde Residencial

A maior parte dos projetos e arquiteturas definidas para *home care* [67] [86] enfocam a telemedicina, o monitoramento remoto ou infraestruturas envolvendo um provedor de

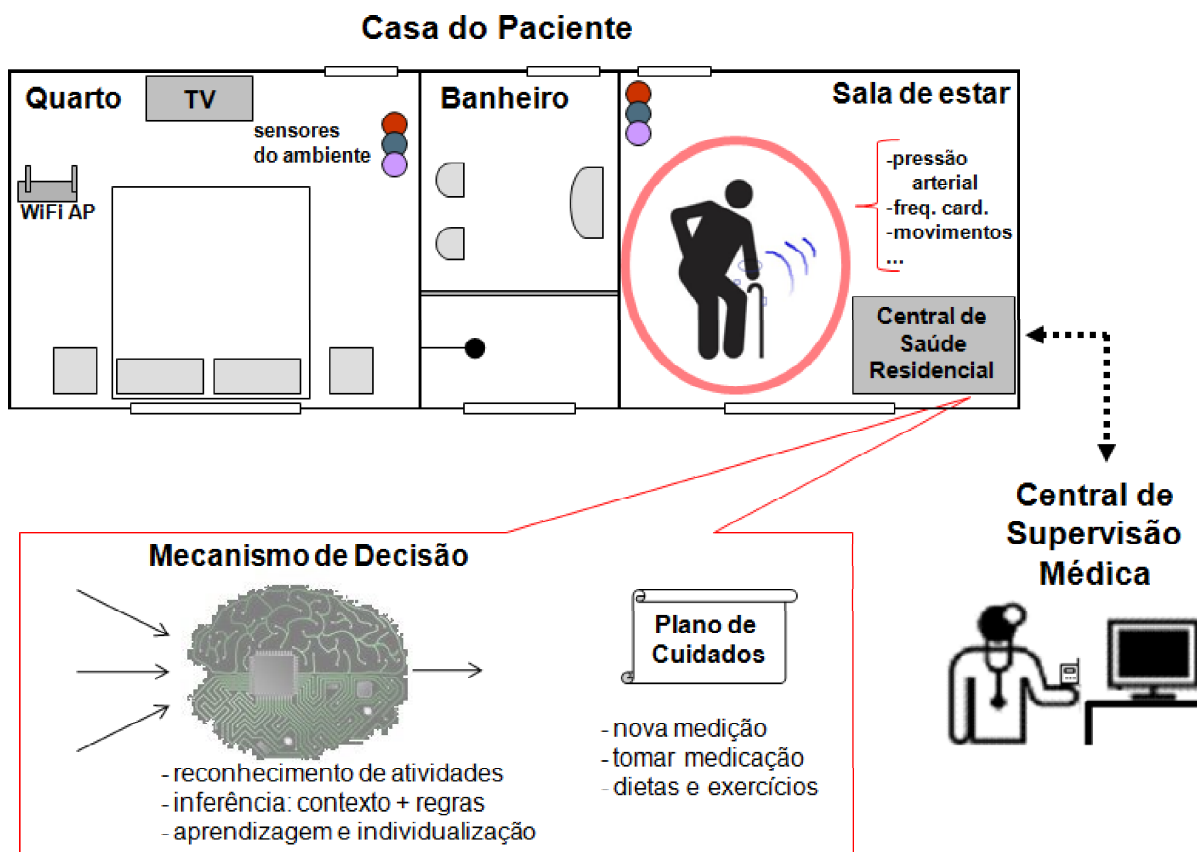


Figura 2.3: Arquitetura de Decisão para *Pervasive Home Care*

*home care*. Nessas arquiteturas, ocorre a coleta de dados dos equipamentos ou sensores e a transmissão dos dados para o hospital ou provedor através de um *gateway*. Localizado na casa do paciente, este último componente pode ser um dispositivo móvel (por exemplo, um PDA ou telefone inteligente), um PC ou um *hardware* específico (alguns exemplos em [3] [57] [120]) que tem a responsabilidade de interfacear com a rede de sensores, equipamentos e a rede de comunicação externa. De qualquer forma, nesse *hardware* é importante que existam várias interfaces de tecnologias sem fio, como ZigBee (IEEE 802.15.4), mas também Bluetooth (IEEE 802.15.1) e Ultra Wideband (UWB). Em conjunto, é interessante explorar a diversidade dos enlaces de comunicação, como, banda larga e telefonia celular, a fim de que o sistema tolere falhas e tenha flexibilidade.

A dependência de envio dos dados monitorados para fora da residência é um obstáculo nessas arquiteturas. Uma série de argumentos contribui para buscar uma solução complementar à transmissão para hospitais ou *data centers* (ver Figura 2.1). Uma análise de dados fora da residência exige que o sistema transmita dados por um longo período e com confiabilidade no mecanismo de comunicação. Em situações críticas para o paciente, mais dados devem ser transmitidos, o que dependerá também dos dados de interesse.

Por exemplo, podemos citar o monitoramento da frequência cardíaca, em comparação à temperatura corporal, pois dados sobre a primeira devem ser transmitidos mais frequentemente. Além disso, a percepção, pelos sistemas da casa, de uma alteração no quadro clínico só será informada ao paciente se ocorrer a transmissão de ida, o processo remoto de avaliação dos dados e a comunicação de volta.

O problema torna-se ainda maior quando se adotam dispositivos com restrições de recursos, e.g. um celular ou um equipamento com a função principal de coleta de dados. Além de não conseguirem desempenhar com qualidade a sua função de *gateway*, dispositivos dessa natureza não são bem aceitos por idosos, que muitas vezes não têm contato com tecnologias mais modernas nem dispõem de uma pessoa que os assessorie.

O aumento da aplicabilidade das redes de sensores faz com que aumente também o tráfego gerado pelas diversas fontes de contexto. Apesar disso, em publicações, pouco tem sido discutidos a quantidade de espaço para armazenar um dia de dados coletados dos pacientes e enviados para fora da residência, ou o consumo ao longo do tempo de recursos dos dispositivos de monitoramento de saúde. O problema é de grande complexidade, principalmente se levarmos em consideração que o sistema deve ser escalável para o atendimento de uma expressiva parcela da população. Apenas recentemente apareceram trabalhos com essa preocupação, mas na área de saúde pública [17].

Uma alternativa interessante é o processamento de dados e sua análise poderem ocorrer na própria casa do paciente, em vez da transmissão em tempo real dos dados para uma instituição de saúde. O armazenamento tanto na residência quanto externamente dos dados do paciente está mais em sintonia com as ideias de computação confiável [21] e com a importância da replicação em aplicações vitais. Outra constatação vinda de [17] é a natureza distribuída dos sensores e a alta quantidade de dados produzidos, exigindo a adoção de infraestruturas distribuídas de gerenciamento de dados.

A Central de Saúde Residencial, apresentada previamente na Figura 2.3, garante, de uma melhor forma, as exigências de processamento, armazenamento e comunicação pretendidas (inclusive os *drivers* e protocolos para tratar a heterogeneidade de dispositivos). Nós assumimos também que existe uma Central de Supervisão Médica que recebe alarmes de emergência e possui uma equipe médica para fazer a análise da situação. Além de ser notificada e receber atualizações dos dados sendo coletados, a Central tem acesso às CSR. Embutida na CSR segundo nossa proposta, é possível também estabelecer uma conversação médico-paciente.



### 2.3.2 Classes de Variáveis para Monitoramento

Uma questão importante é definir o que será monitorado para viabilizar a adoção de serviços em *pervasive home care*. O avanço nos sensores e a adoção das redes sem fio permitem vislumbrar ambientes pervasivos gerando dados em tempo real de diversos tipos de dispositivos. Isso traz uma nova dimensão do auto cuidado e possibilita, entre outros aspectos, que as pessoas sejam avisadas de certos sintomas ou situações que até então não estavam sendo percebidos.

Na nossa visão, um sistema de telemonitoramento deve considerar três grandes classes de variáveis: ambientais, fisiológicas e comportamentais. A seguir, descrevemos cada uma delas:

- Ambientais. No ambiente podem ser encontrados diversos sensores, entre eles os de detecção de luz, som, fumaça, umidade, fogo, temperatura, pressão no piso e, em geral, monitoramento de fogão ou aparelhos eletro-domésticos que ofereçam algum risco ao paciente. Nesse contexto, dependendo da doença, alguns tipos de sensores são mais importantes do que outros, como, por exemplo, detetar se o piso está molhado para diminuir a possibilidade de quedas, no caso de pacientes com Esclerose Lateral Amiotrófica, que estão mais sujeitos a quedas. Medir a intensidade do som ou a luminosidade do ambiente permite também acompanhar a situação do paciente idoso quando suas capacidades fisiológicas e/ou motoras se reduzem com o passar dos anos.
- Fisiológicas. Envolve o uso de equipamentos, sensores e dispositivos adicionados ao corpo do usuário (*wearable devices*), formando uma *Wireless Body Area Network*. É interessante notar que a tecnologia médica está tornando acessíveis certos equipamentos e sensores para uso em casa, os quais podem transmitir seus dados eletronicamente. Nesse sentido, destacam-se, em [54], a análise da concentração de hemoglobina e a tendência de coagulação do sangue (mensurados pelo oxímetro de pulso), além da capacidade pulmonar (aferida pelo espirômetro). Outros exemplos mais comuns são: pressão arterial, nível de glicose, temperatura corporal, peso, frequência cardíaca e eletrocardiograma.
- Comportamentais. Nesse aspecto, a rede de sensores coleta os dados que registram as atividades realizadas em casa. Os dados são analisados e usam-se técnicas de inteligência artificial para tomada de decisão e produção de informações em mais alto nível. A preocupação com a independência recai sobre as Atividades da Vida

Diária (AVD): banhar-se, vestir-se, usar o banheiro, locomover-se, ter continência e alimentar-se. Outras atividades também são interessantes de serem monitoradas, como dormir, sair e retornar à casa e realizar atividades domésticas. Sensores em portas, RFIDs em objetos e acelerômetros são os principais sensores utilizados nesses ambientes fechados.

### 2.3.2.1 O Monitoramento do Comportamento

A análise de comportamento torna possível detetar desvios que estejam prejudicando a saúde do paciente, ou identificar condutas que estejam fora das recomendadas. Nessa funcionalidade, evidencia-se o fato de que se deve realizar uma fusão de dados usando as informações de contexto, a fim de interpretar e obter níveis maiores de abstração.

O monitoramento do comportamento ou da atividade física das pessoas precisa dar conta de um conjunto muito grande e diverso de ações humanas. Uma possível solução encontra-se em reconhecer as ações por meio de técnicas de classificação baseadas em treinamento, isto é, o sistema aprende após lhe serem demonstrados os movimentos. A análise do comportamento tem como processo básico o reconhecimento da atividade que a pessoa está desempenhando. Para realizar esse monitoramento ciente do contexto e aprender padrões de comportamento individuais e reconhecer atividades, os trabalhos de pesquisa têm usado algoritmos de aprendizado [9] [13] [18] [22] [65] [75] [89].

No entanto, é importante separar alguns conceitos envolvidos: tipo de atividade, monitoração do movimento, conduta da pessoa, postura, e movimentos de transição, como se observa a seguir:

- O tipo de atividade é o nome dado a uma AVD, como: comer, dormir, tomar banho, caminhar etc.
- A monitoração de movimentos pode consistir simplesmente em detetar a presença ou ausência de pessoas em cômodos, ou mesmo verificar o nível/intensidade de atividade durante o dia. As atividades que envolvam ou não movimentos são quantificadas para a análise da mobilidade da pessoa.
- A conduta da pessoa diz respeito a quais ações ela realiza diante de um evento. Por exemplo: quando entra no banheiro, ou após entrar em casa, ou em um determinado horário. Em outro tipo de conduta, pode-se querer saber o tempo de permanência em cada cômodo da casa. Portanto, investigar a conduta da pessoa é um aspecto de alto nível que possibilita gerar perfis de atividade.

- A postura é relacionada a posições corporais, tais como sentar-se em uma cadeira, o que pode envolver, por exemplo, o cruzamento das pernas [77], ou sobre uma cama. Nota-se que posições impróprias para cada doença, idade ou para o próprio bem-estar podem ser alertadas [44] quando identificadas.
- Os movimentos de transição são mais específicos: “sentado-em pé”, “em pé-sentado”, “deitado-em pé”, “em pé-deitado”, como realizado em [64]. Esses movimentos de transição podem ajudar a caracterizar também uma situação em que a pessoa eventualmente caiu. Nessa linha, existem trabalhos envolvendo detecção de quedas [27].

### 2.3.2.2 Problemas no Monitoramento de um Paciente em Casa

O monitoramento de saúde em uma casa possui particularidades que o diferem e o tornam mais complexo que o monitoramento em uma Unidade de Tratamento Intensivo. Isso pode ser observado na questão dos alarmes que identificam a ocorrência de situações críticas. Nesse sentido, uma primeira alternativa seria o paciente acionar um alarme informando sobre uma emergência. A outra alternativa, que seria a mais comumente usada, é a de um sistema reagir quando limites pré-fixados de dados fisiológicos são ultrapassados. No entanto, vemos que há a necessidade de identificar situações críticas com maior eficiência, tendo um compromisso entre não ser omissivo e não ter um comportamento paranoico. Diante desse objetivo, o monitoramento do paciente envolve um conjunto de questões para serem resolvidas. Os principais problemas são:

- a) correlação entre variáveis. A piora num dado fisiológico pode ser acompanhada de uma piora num outro tipo de dado – em algumas circunstâncias, o aumento da frequência cardíaca pode vir seguido de uma queda ou aumento na pressão arterial.
- b) individualização no tratamento do paciente. Os dados fisiológicos variam muito para cada paciente. Uma solução possível para esse problema é a definição de regras que estabeleçam os limites individuais, ou então que o histórico seja considerado nas decisões. Assim, uma pessoa que já possui valores altos de pressão não terá alarmes constantemente sendo disparados devido a seu estado.
- c) influência do comportamento e do ambiente. Um exemplo é a temperatura ambiente interferir na frequência cardíaca do paciente, ou a pessoa, quando realizando uma atividade doméstica, ter um aumento na sua pressão arterial. Deve-se ter consciência dessas circunstâncias para considerá-las nos limites do paciente e também auxiliar na detecção de causas das variações.

- d) relaxação (ou afrouxamento) dos limites de cada variável. Os valores rígidos que tentam expressar um conceito ou situação não são adequados nas diversas variáveis, principalmente as fisiológicas. Somente se o limite definido for ultrapassado, acontecerá uma mudança para um estado diferente do atual.
- e) incerteza na leitura dos sensores devido a ruídos e condições do ambiente. A simples definição de regras genéricas que restringem os valores possíveis de obter para cada exame não são suficientes para resolver a complexidade desse problema. Nesse item, deve-se considerar a posição dos sensores, os movimentos da pessoa e também os problemas inerentes à transmissão de dados em redes sem fio.

Vale ressaltar que este trabalho supõe que os sensores disponíveis são confiáveis, de modo que o item “e” não é aqui abordado.

## 2.4 Conclusões do Capítulo

Os trabalhos realizados até o momento na área de computação pervasiva que realizam a assistência domiciliar em casas inteligentes não relacionam a atividade do paciente com seus sinais fisiológicos. Além disso, a influência das condições do ambiente sobre a saúde dos pacientes em períodos de tratamento não é considerada. Assim, a identificação da necessidade de uma visão holística do telemonitoramento é a principal contribuição deste Capítulo.

A implantação de sistemas *pervasive home care* requer uma integração da área de ambientes inteligentes e da área de *home care*. Em especial, há a necessidade de conhecimento de saúde nos sistemas que dão apoio ao paciente em casa. As arquiteturas apresentadas neste Capítulo – de integração dos atores envolvidos na telessaúde e de decisão – são o primeiro passo para realizar a integração dessas áreas. Com isso, as possibilidades de aplicações pervasivas puderam ser vislumbradas. Os ganhos podem ser obtidos com um aumento da qualidade do tratamento de saúde, com o paciente acompanhando mais de perto sua saúde, com os profissionais de saúde e outros envolvidos obtendo informações mais detalhadas ou, por fim, com informações sendo evidenciadas no momento oportuno.

Os estudos realizados neste Capítulo contribuem, assim, para uma visão como um todo do tratamento da saúde, priorizando a fusão dos dados ambientais, fisiológicos e comportamentais. Considerando essas classes de variáveis, pretendemos investigar um mecanismo de Decisão no monitoramento inteligente e sensível ao contexto o qual identi-

fique de uma melhor forma situações críticas.

Para tanto, é necessário estabelecer as principais funcionalidades para o monitoramento que pretendemos. No próximo Capítulo definimos um arcabouço conceitual com os componentes necessários para viabilizar um mecanismo de Decisão. Ao mesmo tempo, o arcabouço consolida a visão de monitoramento para *Pervasive Home Care*, apresentada neste Capítulo, com o estado da arte das áreas envolvidas neste estudo.

# Capítulo 3

## Arcabouço de Monitoramento Inteligente

Este Capítulo apresenta a proposta de um arcabouço conceitual para o monitoramento em ambientes inteligentes voltados para a telessaúde. O arcabouço define os principais componentes necessários para um monitoramento inteligente e sensível ao contexto, utilizando a sensibilidade ao contexto para estabelecer interações internas. Ao mesmo tempo, a estrutura privilegia a agregação de mecanismos inteligentes para o desenvolvimento de aplicações pervasivas de telessaúde. A generalidade do arcabouço permite contemplar diferentes questões de saúde relacionadas ao dia a dia do morador, além de comunicar-se com o meio externo, transferindo conteúdo útil, na forma de alertas mais confiáveis.

A proposta de um arcabouço visa facilitar o desenvolvimento de aplicações de telemonitoramento, permitindo identificar os componentes mais importantes e suas interações. Assim, investigamos como interpretar dados na área de *pervasive home care*. Em especial, queremos viabilizar a identificação de situações críticas, considerando as classes de variáveis ambientais, fisiológicas e comportamentais do paciente. Para esse tratamento de dados, o arcabouço deve ser flexível para que sejam agregadas técnicas inteligentes.

A Seção 3.1 apresenta os componentes de *software* previstos para o arcabouço. Ao longo do texto, são referenciados trabalhos que sustentam a adoção do componente. A Seção 3.2 apresenta cenários de situações críticas e quais componentes podem ser utilizados. Na Seção 3.3, é feito um estudo sobre trabalhos relacionados e, por fim, são apresentadas conclusões.

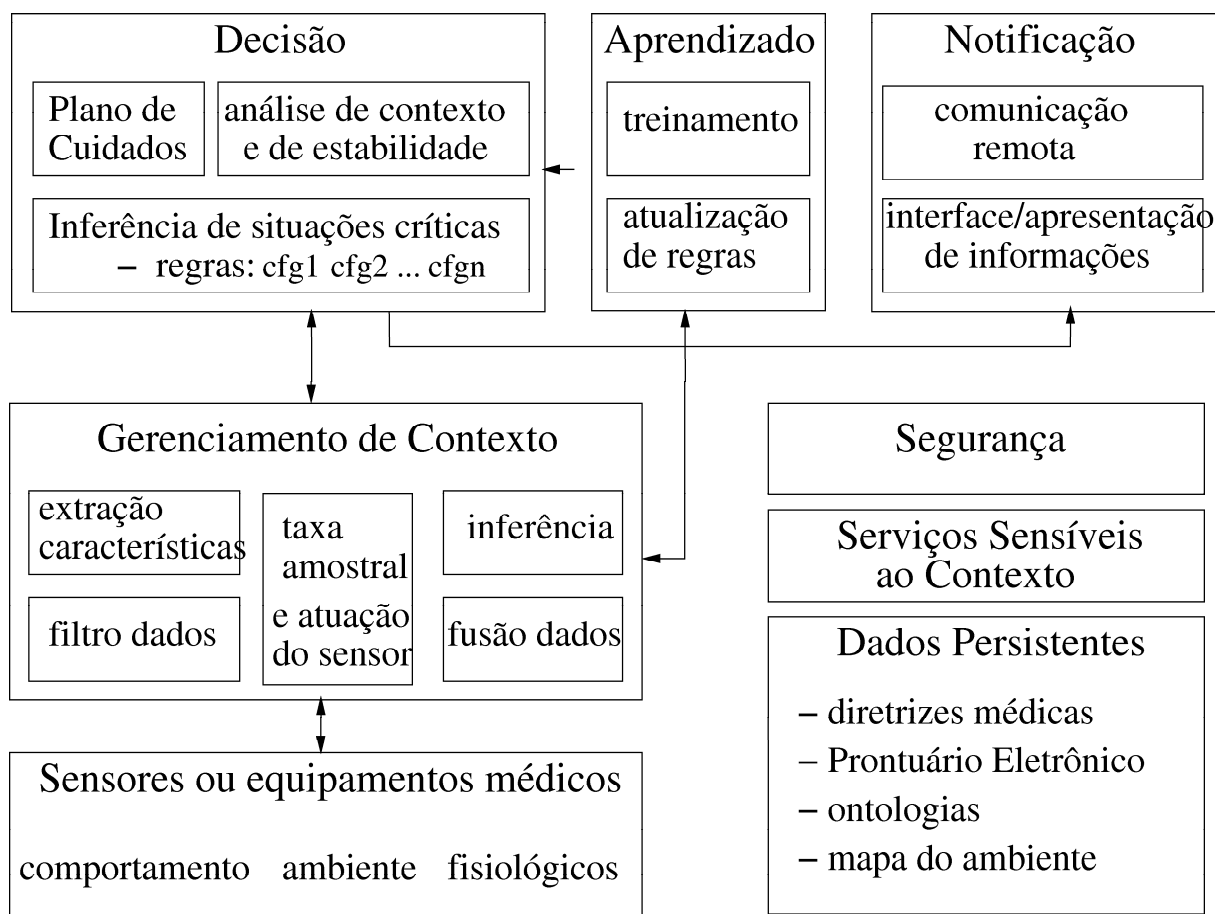


Figura 3.1: Arcabouço de Monitoramento H-SAUDE: módulos e seus componentes

### 3.1 Componentes do Arcabouço

O arcabouço proposto neste trabalho chama-se H-SAUDE: *Health Support for Aware and Ubiquitous Domestic Environments* e oferece suporte ao monitoramento inteligente e sensível ao contexto. O arcabouço possibilita um projeto sistemático de aplicações de telemonitoramento por estabelecer inter-relações entre componentes requeridos para tratar os dados de sensores.

O arcabouço tem como elementos relevantes os módulos de Gerenciamento de Contexto, Decisão e Aprendizagem (Figura 3.1). Os módulos são constituídos por componentes que usam regras internamente. Quando descrevemos situações normais ou anormais de saúde, com base na descrição das variáveis de contexto, e determinamos ações a serem executadas, estamos definindo regras para acompanhar e tomar decisões no monitoramento do paciente. Por exemplo, uma regra pode declarar que se a pessoa estiver em repouso e a frequência cardíaca estiver acima de  $140\text{bpm}$ , trata-se de uma situação de alerta ou emergência.

A importância de gerar alertas confiáveis em sistemas de telemonitoramento faz do

módulo de Decisão o núcleo do arcabouço. Nesse módulo, existe um componente com regras para gerenciar o Plano de Cuidados. Exemplos dessas regras incluem: “ative a câmera web em casos de emergência”, ou “agende um horário para o paciente tomar um medicamento”. Outro componente, de inferência, possui regras para identificar situações críticas, associadas com um peso ou uma prioridade. Assim, em uma determinada situação, mais de uma regra pode ser lançada ao mesmo tempo, com maior ou menor prioridade, ou contribuindo com maior ou menor peso para a tomada de decisão.

Outra atribuição do módulo de Decisão é servir como base para o desenvolvimento de aplicações de monitoramento que trabalhem com as variáveis ambientais, fisiológicas e comportamentais do paciente em casa. Técnicas de análise de estabilidade (*Stability Analysis*), como filtros de Kalman, podem ser acopladas para detectar desvios nas diversas classes de variáveis. Já a análise de contexto (*Context Analysis*) pode identificar em quais circunstâncias estão ocorrendo as situações de alarmes. Para isso, árvores de decisão podem ser usadas.

O módulo de Gerenciamento de Contexto enfatiza mecanismos de tratamento e refinamento dos dados. Inicialmente, podem ser realizadas a filtragem de dados e a extração de características relevantes. A fusão de dados (agregação) e a inferência geram uma nova informação. O módulo pode atuar no ambiente da casa, alterando a taxa amostral de um sensor. É importante aqui separar as atividades de gerenciamento de contexto e os serviços de contexto, conforme feito em [35], uma vez que o módulo de Gerenciamento de Contexto pode contar com Serviços Sensíveis ao Contexto (*Context Aware Services*), comuns a diversas propostas nesta área [26] [116]. Entre esses serviços, podemos citar seleção, descoberta, representação, armazenamento e disseminação, cuja integração com nossa proposta é apresentada em [107].

A fusão de dados e a inferência geram informações em um nível mais alto para o módulo de Decisão. Por exemplo, uma regra pode definir que, se a pessoa está no quarto e não apresenta movimentos, então ela está dormindo. Adicionalmente, podem ser utilizados algoritmos inteligentes, como, por exemplo, modelos de Markov ocultos e redes neurais, para realizar a inferência.

O módulo de Aprendizado pretende atender ao requisito de individualização de sistemas de assistência domiciliar pervasivos. A base de treinamento pode ser constituída por exames realizados previamente pelo paciente. Exemplos disso são os dados de MAPA (Monitorização Ambulatorial da Pressão Arterial), coletados durante 24 horas, e os dados de teste de estresse mental.



É possível nesse módulo formar uma base de treinamento por meio de um processo de calibração, que consiste em demonstrar para o sistema uma atividade, uma sequência de sinais vitais ou uma situação na casa envolvendo o usuário. Por exemplo, a variação na frequência cardíaca e a aproximação da pessoa junto a equipamentos de ginástica podem representar uma sessão de exercícios físicos. Muitos trabalhos fazem essa demonstração real para que o sistema reconheça atividades da pessoa [89] [124]. Algoritmos de classificação como os agrupamentos podem reconhecer esses momentos.

Podemos adotar um cenário fictício para mais bem compreender como se dá a atuação de cada módulo. Nesse cenário, em que o sistema deveria avaliar se determinada situação é crítica, o paciente levantaria da cama e ocorreria uma hipotensão ortostática, por ter passado bruscamente para a posição vertical, causando-lhe sintomas hipotensivos. O Gerenciamento de Contexto inferiria se ocorreu um movimento de transição (no caso, de deitado para em pé) e então dispararia uma regra no módulo de Decisão para realizar uma medição – a regra está definida no componente de regras para o gerenciamento do Plano de Cuidados. Feita a medição, as regras do componente que identifica situações críticas analisariam os dados e atualizariam a situação do usuário (basicamente, se é uma situação normal, alerta ou emergência). Caso o paciente estivesse com um valor muito baixo de pressão arterial (por exemplo, um decréscimo acentuado da pressão sistólica, maior que 20mmHg<sup>1</sup>), então poderia ser utilizado o serviço de Notificação. Porém, se fosse apenas um valor relativamente baixo, a regra do Plano de Cuidados poderia determinar que o componente de taxa amostral antecipasse uma nova medição dos sinais vitais da pessoa.

A seguir, é descrito em maiores detalhes cada um dos principais módulos do arcabouço: Gerenciamento de Contexto, Decisão, Aprendizado e demais módulos (Notificação, Dados Persistentes, Segurança e Serviços Sensíveis ao Contexto).

### 3.1.1 Gerenciamento do Contexto

Como verificado em [109], são extremamente importantes as informações de contexto, com vistas à adaptação do uso dos dispositivos de monitoramento e à promoção de um suporte inteligente para o usuário. O gerenciador de contexto tem o papel de entregar informação relevante para o módulo de Decisão. Por exemplo, o reconhecimento de atividade. A informação da atividade será usada como entrada para o módulo de Decisão. Os seguintes componentes fazem parte do módulo:

---

<sup>1</sup>mmHg = milímetros de mercúrio

- Fusão de dados e inferência

Na literatura de aplicações sensíveis ao contexto, há uma constante referência ao uso de raciocínio (*reasoning capabilities*) [94] na interpretação do contexto. A interpretação ocorre em tempo de execução, verificando o que é importante tanto para uma dada situação, quanto para a sua utilização em relação ao futuro (*predictive context* ou *proactive procedures*). Neste trabalho, estamos inicialmente preocupados com o momento da execução. A interpretação pode ocorrer por fusão de dados, que faz a combinação de várias fontes de contexto para chegar a uma conclusão; ou por inferência, gerando uma informação de mais alto nível. As informações produzidas por esses componentes serão usadas pelo módulo de Decisão.

- Filtragem de dados

O componente de filtragem dos dados realiza o descarte de informações de contexto *on-line*, pois não é necessário armazenar ou processar todos os dados recebidos. Além disso, algumas regras podem manifestar uma condição em particular, como, por exemplo, gerar *log* quando a frequência cardíaca estiver superior a *100bpm*. A filtragem também evita que dados de sensores extrapolem o domínio de valores possíveis estabelecidos por regras, pois, caso isso ocorra, o sistema pode notificar um erro/ruído na leitura dos dados.

Mecanismos mais sofisticados podem ser elaborados, quando somente se está interessado em algumas variáveis do conjunto de dados sendo coletados. O componente de filtragem de dados descartará as leituras de variáveis que não influenciam no modelo. Esse processo torna-se interessante quando a seleção das variáveis e o descarte são automatizados. O procedimento de poda em árvores de decisão pode ser um recurso para atingir esse objetivo.

- Extração de características

Após o recebimento dos dados pelos sensores, já em formato digital, são aplicados algoritmos de filtragem de ruídos e correções de distorção no sinal, para em seguida realizar a extração de características [50]. Já na visão de Jafari *et al.* [63], a extração dos dados relevantes de dados brutos de sensores passa por três fases: pré-processamento (envolve filtragem), reconhecimento de padrões (envolve segmentação e extração de características) e classificação. Um exemplo é o reconhecimento de um movimento de transição.

- Taxa amostral

Este componente atualiza a taxa de amostragem dos sensores. A implementação do controle da taxa de amostragem pode ser realizada tanto na Central de Saúde Residencial como no próprio sensor. No entanto, uma regra de taxa amostral pode ser complexa, o que acarretaria uma descrição um pouco mais sofisticada da situação, por exemplo: se a frequência cardíaca é um pouco maior que o recomendável e se o número de pessoas na casa é 1, então a frequência de monitoramento deve ser de *10min*.

### 3.1.2 Decisão

Este módulo realiza a tomada de decisão do arcabouço, apoiada em conhecimento do domínio do problema, por meio das diretrizes médicas e das regras estabelecidas por profissionais de saúde. Seus componentes são: a inferência de situações críticas, o Plano de Cuidados e o analisador de contexto e de estabilidade.

- Inferência de situações críticas

Este componente possui regras que associam variáveis ambientais, fisiológicas e comportamentais. As variáveis e regras devem ser expressas em termos linguísticos, permitindo que os profissionais de saúde especifiquem as regras. Uma situação crítica pode ser, por exemplo, uma queda de uma pessoa ou um sinal vital muito elevado. No caso de uma queda, outras regras podem ser ativadas, com a intenção de verificar se a pessoa desmaiou ou se simplesmente a pessoa deitou em uma cama. Da mesma forma, uma regra pode confirmar uma pressão alta após uma segunda medida e, assim, acionar um serviço de emergência, por exemplo.

Além disso, as regras podem ser genéricas ou individualizadas. As regras genéricas são diretrizes médicas que valem para todas as pessoas, enquanto as individualizadas consideram médias ou parâmetros do paciente sendo monitorado. Essas últimas devem ter prevalência sobre as primeiras, embora, de qualquer forma, todas as regras contribuam para avaliar a situação crítica.

O componente de Inferência deve ainda flexibilizar o monitoramento, na medida em que dispõe de diferentes conjuntos de regras, sendo mais tolerante ou mais rígido. Isso é feito por meio das diferentes configurações de regras.

- Plano de Cuidados

As regras do Plano de Cuidados tratam de questões como horários de medição, de ingestão de medicamento, de alimentação e de exercícios físicos, bem como a

recomendação de dietas. Por exemplo, é possível definir o tempo de atividade física para o paciente durante o dia. Essas informações podem ser analisadas para garantir que as recomendações/prescrições médicas estão sendo cumpridas, o que está intimamente relacionado à adesão ao tratamento. A análise pode ser feita pelo componente de análise de contexto e de estabilidade. O Plano de Cuidados pode também lançar regras para situações críticas, ativando, por exemplo, uma câmera web para acompanhamento remoto por um familiar.

- Análise de contexto e de estabilidade

Esta análise é importante para autocuidados e pode detetar tanto pioras como melhoras na saúde. A partir disso, pode-se pensar em premiações como elogios a um determinado condicionamento ou mesmo recomendações e propostas de mudanças de atitudes. Essa propriedade do *software* segue a linha de ferramentas para promoção da saúde [73]. Tal análise pode ser realizada através de filtros de Kalman, como no trabalho de Padovitz et al. [87], que analisa leitura de sensores para estimar futuras mudanças no contexto.

A importância desse componente é verificada em funcionalidades relacionadas à vida assistida. Assim, uma ação que o sistema poderia executar no caso de um paciente com distúrbio do sono (verificado pelos movimentos durante a noite, tanto no corpo do indivíduo como em cômodos da casa) é dar sugestões, a exemplo da não ingestão de produtos com cafeína no final do dia ou sugestões de alimentos a serem consumidos. Outro exemplo pode ser a detecção do aumento de tremores em pacientes com Mal de Parkinson. A análise de estabilidade pode garantir uma melhor investigação da causa dos tremores, além da detecção de alterações acentuadas no peso corporal do paciente. A análise de séries temporais é um importante recurso neste componente, a fim de que sejam detetadas tendências e comparadas com determinados padrões.

As informações de contexto geradas pelo ambiente pervasivo podem ser de grande valia para identificar situações que estão ocorrendo com frequência. Os algoritmos de regras de associação são fundamentais para encontrar causas que estão gerando muitas situações críticas, como variações de sinais vitais. É possível obter como resultado de uma extração de regras a associação entre essas variações e, por exemplo, a temperatura alta dentro dos ambientes em que o paciente permanece. Assim, as regras existentes podem ser revistas ou novas regras serem elaboradas para atender a essas situações indesejáveis ou estressantes. Nesse sentido, uma fotografia de fa-

mília poderia até mesmo ser projetada em uma TV ou em um porta-retratos digital, no final da tarde, quando o paciente está em repouso e não há outras pessoas na casa.

### 3.1.3 Aprendizado

Como mencionado anteriormente, o módulo de Aprendizado atende ao requisito de individualização do paciente. Essa individualização é de fundamental importância no monitoramento, já que possibilita uma melhor interpretação dos dados, conforme o perfil do paciente.

Em nossa proposta, a individualização já pode ser praticada na fase inicial do tratamento, que é a avaliação realizada pelo médico e o acompanhamento no primeiro dia do paciente em casa (teste de campo). Se essa espécie de calibração for feita também por um teste de estresse mental, realizado em ambulatório, o médico terá que decidir se os dados que estão sendo informados entrarão para o sistema, pois há a possibilidade de o paciente ir para uma situação crítica. Mesmo que não chegue a esse ponto, se o estado de estresse persistir por muito tempo, o dano será inevitável [72]. Em resumo, com essas avaliações e testes, é formada uma base de dados contendo a associação de dados fisiológicos com dados comportamentais. Os seus componentes são:

- Treinamento

O componente de Treinamento prepara os dados para uma posterior análise pelo componente de análise de contexto e estabilidade ou pelo componente de atualização das regras. Para desempenhar esta função, pode ser feita uma demonstração de comportamento de pessoas para reconhecimento do uso de objetos ou da sua atividade, como, por exemplo, mostrado em [89] [124]. É também possível atribuir a esse componente a tarefa de gerar dados sintéticos para descrever situações em que os dados reais não as contemplam.

- Atualização de regras

O componente de atualização de regras deve ter acompanhamento e supervisão médica. O componente se constitui no uso de diversas técnicas de inteligência computacional e de aprendizado de máquina para viabilizar propostas de alterações nas regras. No caso da identificação de situações críticas, o ajuste proposto deve resultar em um número menor de alarmes falsos, quando aplicado às regras.

### 3.1.4 Outros Componentes do Arcabouço

Nesta Subseção reunimos os módulos de Notificação e de Dados Persistentes. Os outros dois módulos, de Serviços Sensíveis ao Contexto e de Segurança (da mesma forma que o de Dados Persistentes), dão apoio às outras funcionalidades do arcabouço, por isso não estão colocados em posições específicas no diagrama, nem com setas de fluxo específicas.

#### 3.1.4.1 Notificação

O módulo de Notificação realiza a comunicação tanto com o usuário quanto com entidades externas (CSM, familiares etc.). O seu princípio básico é que o sistema deve ser adaptativo e enviar notificações conforme o contexto. Algumas possibilidades são: e-mail, mensagens instantâneas, mensagens via celular, mensagens de voz em alto-falantes espalhados na casa, imagens ou mensagens multimídia enviadas à TV, ligação para o telefone da residência ou para um serviço de emergência. Dependendo do tipo de evento ocorrido e do contexto das pessoas que devem ser informadas (caso de deficiência visual do paciente, por exemplo), o sistema utiliza um conjunto de regras que seguem prioridades associadas aos dispositivos ou mecanismos notificadores, podendo diversificar os chamados caso não obtenha resposta de recebimento.

A notificação pode ser interna ou externa, englobando desde lembretes para o paciente tomar um remédio até chamadas aos serviços de emergência. A tarefa de envio dos dados sensorizados também é feita por este componente. Em situações críticas ou sob requisição autorizada, ele pode constantemente enviar dados para entidades externas. De acordo com políticas, o envio pode ser programado para ser feito em determinados momentos do dia, como durante a geração de relatórios diários.

Na definição das políticas, há ainda outro atributo de prioridade relacionado ao tipo de exame, que determina ações mais enérgicas no momento da notificação. Assim, resultados de exames que caracterizem alto risco são definidos com prioridade alta.

#### 3.1.4.2 Dados Persistentes

Este módulo dá suporte aos demais. Ele é necessário para a compreensão e inserção de nosso trabalho no contexto das pesquisas desenvolvidas em outras áreas de estudo. Reunimos neste módulo estruturas ou modelos importantes para sistemas de telessaúde.

- Prontuário eletrônico do paciente

O prontuário serve tanto para consulta de informações do paciente quanto para armazenamento de informações geradas pelo sistema. As solicitações médicas para controlar determinados tipos de exames são exemplos de conteúdos para o prontuário. Assim, o módulo de Gerenciamento de Contexto poderá atualizar informações desses exames. É um requisito que o prontuário siga um padrão médico bem estabelecido. Esse ainda é um tópico de pesquisa, que deve explorar novas estruturas de dados, permitindo ao mesmo tempo a interoperabilidade entre os vários sistemas [46]. É importante ressaltar que os valores esperados para vários sinais vitais ou comportamentos estarão registrados neste prontuário. Um exemplo é o registro de um exame de MAPA.

- Diretrizes Médicas

As Diretrizes Médicas (*medical guidelines*) representam o conhecimento do domínio do problema. Este componente possui regras com conhecimento ou recomendações médicas válidas para as pessoas em geral. Assim, as regras contidas neste componente também podem ser avaliadas pelos componentes envolvendo regras do Módulo de Decisão. De uma forma mais avançada, os *guidelines* computadorizados representam a situação ideal de acompanhamento e tomada de decisão num tratamento. Um exemplo de modelo de representação dos *guidelines* computadorizados é o GLIF (*Guideline Interchange Format*). Esse modelo pode ser integrado com o prontuário eletrônico do paciente, como proposto em [115].

- Ontologias

Este trabalho assume que existem ontologias de contexto capazes de representar tanto informações de contexto gerais (localização, tempo, bateria, largura de banda etc.) quanto de conhecimento médico (diabetes como uma doença, insulina como um remédio etc). A utilização desses conceitos facilitará que as regras contemplem várias situações como: “se a pessoa está tomando antibiótico, alerte-a quando detetar possibilidade de consumo de bebida alcoólica”. Além disso, a ontologia é usada na especificação do *guideline* computadorizado.

- Mapa do ambiente

Esta é uma estrutura de dados importante no monitoramento das AVD. Para tanto, deve-se associar cada cômodo da casa a: quarto, cozinha, banheiro, área aberta ou outros. Desse modo, o mapa é utilizado na assistência domiciliar para auxiliar na

identificação de atividades sendo realizadas pelas pessoas. Também é possível o uso de sensores e/ou robôs móveis para determinar áreas de ocupação e obstáculos no ambiente.

## **3.2 Cenários de Uso do Arcabouço em Situações Críticas**

A Tabela 3.1 apresenta possíveis aplicações que envolvam a identificação de situações críticas e os componentes do arcabouço que atendem as funcionalidades básicas para o desenvolvimento da aplicação. O reconhecimento de atividades serve como base para todos os outros cenários, de modo que esse item foi colocado por último na Tabela.



Cenários de Situações Críticas		
Cenário/Aplicação	Componentes do Arcabouço	Tarefas
Variação de sinal vital	<ul style="list-style-type: none"> <li>- Inferência</li> <li>- Inferência de Situações Críticas</li> <li>- Plano Cuidados</li> <li>- Tx Amostral e Atuação do Sensor</li> <li>- Atualização de Regras &amp; Treinamento</li> </ul>	<ul style="list-style-type: none"> <li>- reconhece a atividade</li> <li>- infere o estado do paciente</li> <li>- se é uma situação crítica: diminui a freq. de medição</li> <li>- agenda uma próxima medição</li> <li>- ajusta regras para tolerar certas variações</li> </ul>
Queda	<ul style="list-style-type: none"> <li>- Extração Características</li> <li>- Inferência de Situações Críticas</li> <li>- Comunicação Remota</li> </ul>	<ul style="list-style-type: none"> <li>- reconhece um movimento de transição</li> <li>- se é queda e não responde a um chamado: emergência</li> <li>- notifica um familiar</li> </ul>
Desmaio	<ul style="list-style-type: none"> <li>- Extração Características</li> <li>- Inferência de Situações Críticas</li> <li>- Comunicação Remota</li> </ul>	<ul style="list-style-type: none"> <li>- reconhece um movimento de transição</li> <li>- se é desmaio e não responde a um chamado: emergência</li> <li>- notifica um familiar</li> </ul>
Falta de mobilidade	<ul style="list-style-type: none"> <li>- Extração Características</li> <li>- Análise de Contexto e Estabilidade</li> <li>- Inferência de Situações Críticas</li> <li>- Treinamento</li> </ul>	<ul style="list-style-type: none"> <li>- captura tempo sem movimento</li> <li>- analisa o período sem movimento</li> <li>- se falta de mobilidade: alerta</li> <li>- estabelece um <i>baseline</i> para falta de mobilidade</li> </ul>
Permanência no banheiro	<ul style="list-style-type: none"> <li>- Mapa do Ambiente</li> <li>- Análise de Contexto e Estabilidade</li> </ul>	<ul style="list-style-type: none"> <li>- consulta localização</li> <li>- analisa do tempo normal de permanência</li> </ul>
Tremor excessivo	<ul style="list-style-type: none"> <li>- Extração Características</li> <li>- Análise de Contexto e Estabilidade</li> </ul>	<ul style="list-style-type: none"> <li>- captura picos de movimentos</li> <li>- analisa nível do tremor</li> </ul>
Reconhecimento de atividade	<ul style="list-style-type: none"> <li>- Filtro de Dados</li> <li>- Extração de Características</li> <li>- Fusão de Dados</li> <li>- Inferência</li> </ul>	<ul style="list-style-type: none"> <li>- calcula dados estatísticos dos movimentos</li> <li>- captura atributos dos movimentos</li> <li>- combina com dados do ambiente ou de sinais vitais</li> <li>- classifica/reconhece o padrão</li> </ul>

Tabela 3.1: Aplicações envolvendo situações críticas e os componentes necessários para a solução

### 3.3 Trabalhos Relacionados

A pesquisa sobre tratamento de saúde com computação pervasiva (*pervasive health-care*) é uma área de aplicação relativamente recente, pois teve seu primeiro congresso em 2006 ([pervasivehealth.org](http://pervasivehealth.org)). No entanto, a área é resultado de conhecimentos acumulados de outras áreas, como informática médica, computação ubíqua e pervasiva (envolvendo redes de sensores e computação móvel), ambientes inteligentes e áreas da saúde. Como a questão do tratamento de saúde envolvendo computação é uma vasta área de pesquisa e com grandes desafios, é comum vermos trabalhos nas diversas áreas do conhecimento.

Ao restringirmos o foco de análise para o monitoramento de pessoas, principalmente envolvendo questões de saúde, vemos vários avanços com o uso da computação pervasiva. Esses trabalhos geralmente criam arquiteturas ou modelos para tentar generalizar a solução encontrada para um problema específico. A seguir, descreveremos alguns desses trabalhos e faremos comparações ou observações em relação ao nosso trabalho. No entanto, todos os estudos de alguma forma contribuíram para a concepção do arcabouço aqui proposto.

Em [12], é apresentado um refrigerador inteligente, que monitora a abertura e o fechamento da porta, a temperatura interna, a validade e a posição (dentro ou fora) dos alimentos. Dessa forma, serviços em mais alto nível podem ser oferecidos, como o serviço de cozinha propor uma receita ou o serviço de assistência pessoal gerar um relatório com os itens provavelmente consumidos. A arquitetura preocupa-se principalmente com a integração dinâmica de serviços suportada pela busca de serviços e um mecanismo de *publish-subscribe* para comunicação. Cabe ressaltar que o nosso trabalho não se preocupa com os mecanismos e padrões de troca de mensagens.

Na arquitetura proposta em [118] para vida assistida (*assisted living*), a prioridade é dada à flexibilidade, à disponibilidade e à segurança/privacidade. A solução apresenta a figura de um “mordomo” que interage com os dispositivos da residência através de diferentes tecnologias de rede sem fio. Nesse componente há três camadas: SO, *middleware* e aplicações. No *middleware*, estão a gerência dos dispositivos e uma abstração para os mecanismos de comunicação, de forma transparente do equipamento usado como mordomo (por exemplo, PDA ou PC). Tanto a arquitetura de [12] quanto a de [118] não apresentam soluções para o raciocínio e aprendizagem de dados.

Um arcabouço para ambientes inteligentes é apresentado em [37], contendo um módulo de informações de contexto separado de um módulo de decisões. Esses módulos pretendem

suportar a combinação de informações de sensores e um modelo apreendido de padrões de atividade e preferências de um habitante. No entanto, não são consideradas informações de saúde. Em um recente trabalho de [107], definimos uma arquitetura que inclui serviços sensíveis ao contexto, os quais possibilitam descobrir e gerenciar recursos (sensores e dispositivos). Assim, as aplicações de monitoramento de saúde podem contar com uma infraestrutura para gerenciar os recursos envolvidos.

No trabalho de [93] sobre o uso de técnicas de inteligência artificial em ambientes inteligentes, é apresentada uma visão abrangente das funcionalidades que devem ser tratadas nesses ambientes. De forma mais específica, nossa proposta complementa a visão de ambientes inteligentes ao aproximar as tarefas de gerenciamento de contexto dos mecanismos de decisão em alto nível, dando ênfase para as atividades de fusão de dados. Com isso, é possível, por exemplo, fazer o reconhecimento de uma atividade e já disponibilizar essa informação como entrada para uma inferência do estado de saúde do paciente.

De forma semelhante ao nosso trabalho, em [23] um arcabouço é proposto para o desenvolvimento de aplicações de monitoramento remoto. São apresentados três componentes: gerenciamento de contexto, gerenciamento do ciclo de vida (por exemplo, o registro de componentes) e conectividade (comunicação entre aplicações sem considerar a tecnologia de rede). No entanto, não se contemplam funcionalidades de raciocínio

Apenas recentemente, as primeiras propostas foram apresentadas para definir componentes básicos/comuns para o desenvolvimento de aplicações de monitoramento remoto, como em [56] e [98]. Neste último trabalho, é introduzido um modelo de referência genérico para o desenvolvimento de serviços de autocuidado pervasivos (*pervasive self-care*). Os autores acreditam que, com os componentes modulares, seja eliminada a duplicação de esforços exigidos atualmente para desenvolver elementos de infraestrutura para suportar aplicações específicas. Com enfoque na representação e comunicação com o meio externo, o trabalho não inclui mecanismos de decisão.

Em [19], é usado o conceito de refinamento de informações de contexto. Segundo os autores, o refinamento está preocupado em tomar decisões se uma dada informação de contexto é de importância significativa para o usuário antes de entregá-la. De maneira semelhante ao proposto pelos autores, definimos os principais componentes para obter novas informações de contexto dentro do domínio do problema.

Em [47], com uma *body area network* (usando uma roupa computacional), são coletados dados de movimento e de localização da pessoa. Quando ela está próxima a um computador autorizado, os dados são transferidos. O trabalho ressalta e implementa

esquemas de economia de energia que prolongam o tempo de vida da bateria aproximadamente em uma ordem de magnitude. Assim, em vez de alguns dias, as baterias podem funcionar por alguns meses. Nesse arcabouço [47], são definidas as seguintes camadas no computador que gerencia os dados: os sensores, um *parsing* dos dados brutos de sensores, um interpretador para acomodar algoritmos diferentes e uma camada de aplicação. A preocupação com a economia de energia aparece no arcabouço com uma implementação no dispositivo sensor, com modo de economia de energia em momentos em que os dados sensorizados não mudam e, ainda, com uma técnica de truncagem de dados.

O projeto ALARM-NET [120] tem pontos em comum com o nosso trabalho, sendo que suas prioridades recaem sobre coleta e processamento de dados em tempo real; componentes de *software* sensíveis ao contexto, que possibilitam gerenciamento eficiente de energia; consulta aos dados de sensores com gerenciamento de energia; privacidade; e segurança. A sensibilidade ao contexto é suportada pelo aprendizado de AVDs e pela interpretação de padrões de comportamento. Os componentes do sensor podem realizar filtragem e agregação de dados para envio. É possível, com isso, realizar operações do tipo: “quando a pessoa estiver dormindo, desligue os sensores da sala e verifique a temperatura ambiente a cada 2 min no quarto”. A arquitetura possui um computador onde os dados dos sensores são armazenados e também um *gateway* que faz interface entre a rede sem fio e a rede Internet. Enquanto o computador faz a análise de comportamento da pessoa, o *gateway* engloba os componentes de gerenciamento de energia, privacidade e de consultas.

Uma arquitetura com ênfase em técnicas para análise de dados é apresentada em [43]. A arquitetura proposta utiliza sensores no ambiente e no corpo da pessoa para o reconhecimento de atividades. A análise de dados utiliza diversas técnicas de inferência e de aprendizado para o monitoramento do comportamento. Apesar de não contemplar sinais vitais e conceitos de aplicações sensíveis ao contexto, o trabalho contribui para ressaltar as funcionalidades de fusão e análise de dados. Em especial, a análise de dados envolve reconhecimento de padrões de comportamento e análise de tendências.

Em [69], são usadas técnicas de fusão de dados para gerar um contexto para uma situação em particular. O objetivo é produzir dados altamente confiáveis para diagnóstico e tratamento médico. Da mesma forma, em nossa proposta, buscamos, de forma mais específica, identificar situações críticas com uma reduzida taxa de falsos negativos. Em [69], uma arquitetura de componentes é definida para dar respostas rápidas em situações de emergência. O diferencial de nossa proposta é o forte aspecto de individualização, que utiliza informações tanto do perfil do paciente quanto do histórico de respostas do sistema

para sugerir ao médico uma atualização de regras.

O mesmo enfoque dado em nosso arcabouço de mecanismos de decisão também é feito no arcabouço apresentado por Sneha [104]. Portanto, podemos comparar diretamente os dois trabalhos. O trabalho de Sneha não agrega o conceito de comportamento, apesar de citar a possibilidade de coletar dados referentes à agitação e ao andar da pessoa. Sem contemplar a fusão de dados, o trabalho não considera a associação de sinais vitais com as classes de variáveis de comportamento e de ambiente. Além disso, não menciona regras com menor ou maior prioridade ou com atribuição de pesos envolvendo as classes de variáveis diferentes. Ademais, não está prevista uma fase de aprendizado para atualização do modelo.

### 3.4 Conclusões do Capítulo

O arcabouço H-SAUDE de monitoramento de saúde inteligente permite que sejam visualizados os componentes necessários para realizar um monitoramento pervasivo considerando as três classes de variáveis. O tratamento de dados e as primeiras inferências estão concentradas no módulo de gerenciamento de contexto. Dessa forma, o processamento fica mais próximo da coleta de dados e, assim, os sensores ou as unidades de coleta podem ter um papel mais ativo, realizando um pré-processamento dos dados. O módulo de Decisão separa as funcionalidades do Plano de Cuidados e as da identificação de situações críticas, mas preserva em ambos os componentes a ligação com as diretrizes médicas.

O arcabouço conceitual proposto neste trabalho faz com que ocorra uma separação de cada funcionalidade de decisão que compõe as aplicações. Com isso, é possível agregar técnicas inteligentes nas aplicações pervasivas e manter em separado as principais decisões feitas pelas aplicações. Um exemplo típico são as técnicas de reconhecimento de comportamentos e de atividades diárias. Essas técnicas fornecem informações para um nível mais alto, o módulo de Decisão, que usará as informações “úteis” juntamente com os dados fisiológicos para tomada de decisão. Assim, é necessário detalhar um mecanismo de Decisão adequado para o arcabouço.

Nesta tese, concentramo-nos em dois componentes do arcabouço: o componente de Inferência de situações críticas, pertencente ao módulo de Decisão, e o componente de atualização de regras, pertencente ao módulo de Aprendizado. O próximo Capítulo faz esse detalhamento.

## Capítulo 4

# Mecanismo de Decisão para Inferência de Contexto em Ambientes Pervasivos de Tratamento de Saúde

Esta tese demonstra que a identificação de situações críticas envolvendo variações nos sinais vitais pode ser automatizada por um mecanismo de Decisão que considera as variáveis ambientais, fisiológicas e comportamentais, ao mesmo tempo em que satisfaz o requisito de individualização do tratamento de um paciente sendo monitorado em casa. Este Capítulo apresenta o mecanismo de Decisão para inferência de contexto em aplicações de monitoramento de saúde. O mecanismo agrega conhecimento médico, é individualizado e se ajusta às variações de sinais vitais conforme a atividade que o paciente realiza. Nossa solução define, inicialmente, um modelo denominado de Decisão, do qual derivam dois módulos principais: um Módulo de Inferência, que reconhece situações críticas; e um Módulo de Aprendizado, que propõe ajustes no Módulo de Inferência. A união entre os dois módulos constitui o mecanismo de Decisão.

Como estudo de caso para desenvolver o mecanismo de Decisão, escolhemos o controle da pressão arterial. Alguns fatores contribuem para essa escolha, como a importância do monitoramento de longa duração da pressão arterial, demonstrada em nível global [16]; a presença de especialistas médicos na área de cardiologia e hipertensão em nossa equipe; e a influência do comportamento e das condições ambientais, ocasionando variações na pressão arterial [36] [76] [101] [102].

No caso de um controle da pressão arterial, dois procedimentos são estabelecidos pela Sociedade Brasileira de Cardiologia, os quais consideram a pessoa sendo monitorada fora do consultório médico: MRPA (Monitorização Residencial da Pressão Arterial) e MAPA (Monitorização Ambulatorial da Pressão Arterial). Apesar de serem usadas principal-

mente para esclarecimento diagnóstico [76], essas ferramentas podem estabelecer a base de conhecimento para definir um monitoramento de longa duração. O MRPA estabelece que o paciente faça três medições pela manhã e três à noite, durante cinco dias. Já a MAPA é realizada durante um período de 24 horas, podendo atingir em torno de 80 medições, com intervalos de  $20min$  durante a vigília e  $30min$  durante o sono [101]. Os pacientes são orientados em ambos os métodos a anotar sua atividade, ou seja, o que estavam fazendo quando da medição.

O mecanismo de Decisão a ser desenvolvido envolve inferência e aprendizado. Para avaliá-lo, é importante o uso de uma grande quantidade de dados, a fim de que se possa, posteriormente, implantá-lo em ambientes reais. Neste Capítulo, também discutimos o uso de dados de MAPA de pacientes reais e ampliamos esses dados com dados sintéticos deles derivados – os testes envolvendo um protótipo como prova de conceito para avaliar o mecanismo são feitos no Capítulo 5. Além de muitos dados necessários para o sistema aprender, é discutida no presente Capítulo a necessidade de manter uma fácil interpretação das regras, mesmo com uma proposta de ajuste.

O Capítulo está estruturado da seguinte forma: a primeira Seção apresenta o Modelo de Decisão, do qual se originam o Módulo de Inferência e o Módulo de Aprendizado, apresentados nas Seções 4.2 e 4.3, respectivamente. Na Seção 4.4, são discutidos trabalhos relacionados ao mecanismo.

## 4.1 Modelo de Decisão para o Monitoramento

Esta Seção discute e apresenta um Modelo de Decisão para identificar situações críticas, caracterizadas principalmente por alterações nos sinais vitais. Um requisito fundamental é incorporar conhecimento médico. Uma forma simples para uma representação desse conhecimento, que pode ser bem entendida por médicos, são as regras se-então. Assim, elaboramos regras a partir do conhecimento publicado em diretrizes médicas e da experiência de especialistas em saúde participantes de nosso grupo de pesquisa. Alguns exemplos são:

- Se a média da pressão sistólica for maior que  $135mmHg$  e a da diastólica for maior que  $85mmHg$ , então o paciente é considerado hipertenso [100]
- Se está comendo, a pressão sistólica deve subir no máximo  $8,8mmHg$  da média e a diastólica  $9,6mmHg$  [76]

- Se está realizando tarefas/atividades domésticas, então a pressão sistólica deve subir no máximo  $10,7mmHg$  da média e a diastólica  $6,7mmHg$  [76]
- Se está dormindo, então a pressão sistólica deve ficar no máximo  $-10mmHg$  da média e a diastólica  $-7,6mmHg$  [100]
- É sempre admissível que a frequência cardíaca em repouso esteja entre 61 e 99bpm
- Se a temperatura ambiente está alta e a pressão arterial está baixa, então é considerado um alerta leve

As regras para o Modelo de Decisão podem associar as três classes de variáveis: ambientais, fisiológicas e comportamentais (a atividade da pessoa). Um elemento importante da regra é a possibilidade de usar a média de um determinado sinal vital. Este recurso permite uma generalização da regra aplicável em pacientes com diferentes níveis de dados fisiológicos.

#### 4.1.1 As Estratégias e o Modelo de Decisão para Inferir Situações Críticas

Esta Subseção discute as estratégias para construir um modelo de Decisão ('D') que identifique situações críticas. As situações críticas são parte da definição feita neste trabalho para uma variável denominada "estado do paciente", que contempla as situações de: normal, alerta ou emergência. O estado de normalidade significa que a entrada de dados produziu um valor esperado ou razoável para o paciente. Já os alertas e as emergências são categorizados como situações críticas, mas em níveis diferentes. Um alerta serve para identificar variações e facilitar a análise médica. As emergências determinam que o sistema solicite, logo em seguida, uma nova medição para confirmar a primeira. Após isso, a emergência pode lançar um aviso a um médico ou a um serviço de pronto atendimento.

As estratégias para o Modelo de Decisão são:

- D1. Para um conjunto de entrada de dados, caracterizando o contexto do paciente, deve ser produzido um resultado que qualifique esta situação, o qual denominamos estado do paciente. Esse estado não deve ser alterado bruscamente sob pequenas variações de sinais vitais. No entanto, cabe ressaltar que, ao contrário de querer realizar um diagnóstico, o enfoque do sistema é auxiliar o profissional de saúde a se concentrar em situações relevantes.



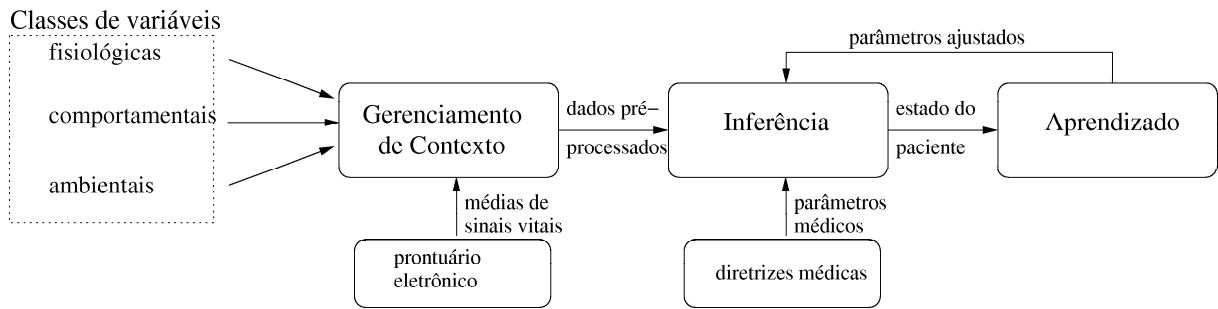


Figura 4.1: Modelo de Decisão

- D2. Monitorar sinais vitais pode produzir melhores resultados quando adicionamos variáveis e regras pertinentes para o processo de decisão. Uma melhora nos resultados é observada por meio de situações críticas corretamente identificadas, distinguindo alertas de emergências e não gerando alarmes falsos.
- D3. O modelo deve responder adequadamente para pacientes que possuam diferentes níveis de sinais fisiológicos. Isso implica, por exemplo, evitar a emissão de alarmes frequentes para pessoas com predomínio de pressão alta, o que torna o modelo mais adequado para o monitoramento de longa duração.
- D4. O sistema deve identificar situações críticas em atividades específicas. Assim, o modelo pode identificar atividades que causam mudanças nas variáveis fisiológicas. Ao contrário, se a atividade é a causa natural de uma mudança, então pode ser considerada como uma situação normal. Dessa maneira, as condições de saúde do paciente podem ser monitoradas pelos resultados do modelo. Tal forma rígida de controle permite capturar situações em que o paciente tem sinais vitais alterados em momentos em que não há uma causa relacionada à atividade.
- D5. Os valores de sinais vitais considerados normais por diretrizes médicas devem resultar em uma resposta “normal” do modelo, o que requer a definição de regras genéricas, válidas para todas as pessoas.
- D6. As emergências têm prioridade. Se ao mesmo tempo em que uma emergência é detetada, outra regra resulta em normal para determinado sinal vital, esta última não deve prevalecer sobre a regra que estabelece a emergência.

Com essas estratégias e buscando uma simplificação da inerente complexidade do problema, elaboramos um sistema de decisão que implementa um Modelo de Decisão, apresentado na Figura 4.1. As diferentes classes de variáveis são tratadas, inicialmente, pelo Módulo de Gerenciamento de Contexto, já descrito no Arcabouço de Monitoramento,

o qual usa informações do prontuário eletrônico do paciente. Essas informações podem ser, por exemplo, as médias de sinais vitais, para calcular os desvios em relação a essas médias. Em seguida, o componente de Inferência realiza a inferência de contexto para determinar o estado do paciente. Após uma determinada quantidade de medições, o componente de Aprendizado pode atuar e uma atualização nas variáveis pode ser proposta ao médico. Essa quantidade de medições só poderá ser determinada pelo médico após um tempo de execução do sistema.

Os projetos dos componentes de Inferência e de Aprendizado são implementados pelos respectivos módulos, apresentados na Subseção 4.2 e na Seção 4.3, respectivamente.

## 4.2 Módulo de Inferência

Esta Seção descreve as variáveis, regras e métodos utilizados no Módulo de Inferência. O projeto desse Módulo considera as diretrizes para os exames de MAPA e de MRPA. No entanto, a nossa solução difere em duas características desses dois tipos de monitoramento. Na proposta aqui alinhavada, o controle da pressão arterial é de longa duração, e concebemos um ambiente de monitoramento com sensores na residência e no corpo da pessoa.

A dinâmica do comportamento humano, a inerente variabilidade dos sinais vitais e as incertezas associadas com os dados coletados dos sensores devem ser consideradas quando definidas as variáveis de interesse. Adicionalmente, o conhecimento médico é expresso de uma maneira que torna a aplicação de conceitos rígidos inapropriada nesse tipo de problema. Considerando esse contexto, adotamos um modelo em lógica *fuzzy* [97] para representar as variáveis relevantes e para implementar a função de tomada de decisão do Módulo. Um breve resumo sobre variáveis *fuzzy* é feito no Apêndice B.

As variáveis presentes na MAPA estão restritas à pressão arterial (PA), à frequência cardíaca (FC) e à atividade que é informada pelo paciente. Assim, as variáveis fisiológicas escolhidas são: pressão arterial sistólica (PAS), pressão arterial diastólica (PAD) e frequência cardíaca. Essas variáveis podem ser facilmente coletadas e mudam rapidamente de acordo com o estado do paciente. Entre os fatores ambientais (luz, temperatura, ruído e umidade, entre outros), escolhemos a temperatura ambiente, por ter maior influência na saúde do paciente e ser de fácil obtenção. Para a variável atividade do paciente, consideramos: dormindo, em repouso, comendo, caminhando e em atividade doméstica. Como não pretendemos explorar técnicas de reconhecimento de atividade neste trabalho, supomos




Figura 4.2: Desvio da Pressão Arterial Sistólica enquanto a pessoa dorme

que um subsistema fica responsável por informar a atividade para o nosso sistema.

Como parte de um protocolo de monitoramento (a ser definido futuramente em outro trabalho), o exame de MAPA é realizado no paciente. O exame serve principalmente para atualizar a média de pressão arterial do paciente. Após isso, o sistema de monitoramento usa essa média de pressão para subtrair de cada nova medição. Com isso, temos um **desvio** da média, que faz parte da composição das regras.

As variáveis fisiológicas foram modeladas associadas às variáveis comportamentais ou ambientais. As regras levam a um resultado do sistema (estado do paciente): normal, alerta ou emergência. Por exemplo, para uma pessoa que esteja dormindo (Figura 4.2), o desvio da PAS em relação à média de PAS do paciente, estando entre 0 e -10mmHg, é considerado normal<sup>1</sup>. Essa variável pode ser comparada com as recomendações médicas da pressão arterial para uma pessoa realizando atividade doméstica (Figura 4.3). Vemos que, uma vez reconhecida a atividade doméstica realizada pelo paciente nos minutos precedentes à medição, a medida de PAS com desvio um pouco superior à média pode ser considerada normal. Ao contrário, na atividade de sono, o desvio tem que ser um pouco inferior à média para ter uma maior pertinência no conjunto 'normal'.

A variável “atividade” é tratada como um *singleton*, isto é, somente os valores inteiros que representam cada atividade têm uma pertinência total. Com exceção da atividade de se alimentar, as outras atividades estão relacionadas com o movimento, desde dormir até varrer a casa (atividade doméstica). Isso não exclui, porém, outras possibilidades que venham a ser incorporadas ao sistema, como telefonar ou tomar um medicamento.

<sup>1</sup>Segundo o conhecimento especialista e as diretrizes médicas, o desvio é de 10% a 20% em relação à pressão arterial de dia. O valor -10mmHg, associado à pertinência total, provém da diferença em relação à média de pressão arterial das 24horas. Estabelecemos para o 'normal' até -20mmHg, com graus menores de pertinência.

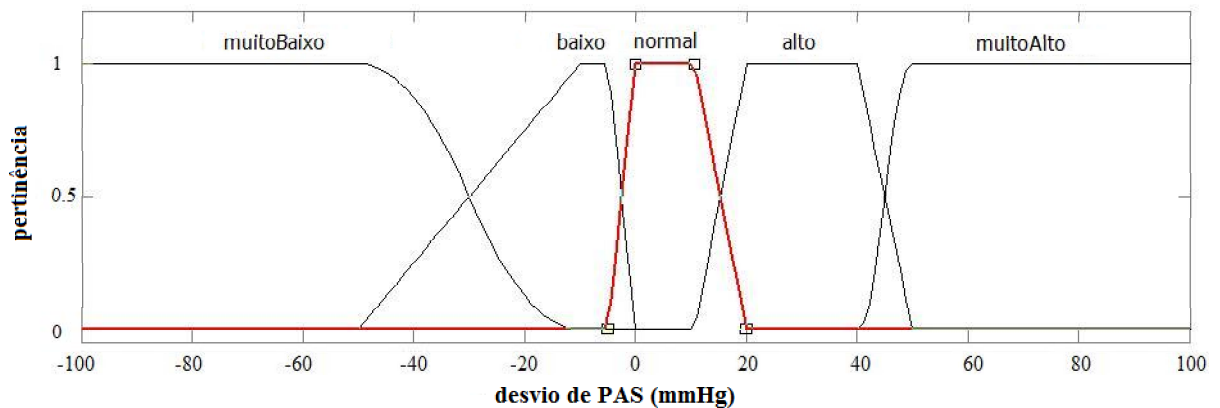


Figura 4.3: Desvio da Pressão Arterial Sistólica enquanto a pessoa realiza uma atividade doméstica




Figura 4.4: Estado do paciente; resultado da inferência

Quanto ao estado do paciente, acreditamos que os valores normal, alerta e emergência representem adequadamente situações reais de um paciente (Figura 4.4). O valor possível obtido como saída do sistema está no intervalo de números reais  $[0..1]$ . A opção por esse intervalo é arbitrária, pois o objetivo é estabelecer simplesmente um número crescente para cada estado do paciente. O estado “normal” foi mapeado na faixa  $[0..0,4]$  e não exige nenhuma atuação do sistema. No estado “alerta”, com intervalo aberto  $(0,4..0,7)$ , estão os casos em que o médico pode se deter para uma análise após um longo período de monitoramento. Outra possibilidade, logo depois de identificado um alerta, é o sistema atuar no ambiente, por exemplo, mostrando fotos ou dando recomendações ao paciente, com o objetivo de dar alternativas para sair de uma situação estressante. Uma recomendação pode ser simplesmente mostrar uma informação sobre a importância do consumo de determinado alimento ou da realização de exercícios. Por último, o estado de “emergência”  $[0,7..1]$  implica solicitar uma nova medição que confirme a anterior, ou notificar familiares, médicos ou uma central de supervisão médica.

Para exemplificarmos as regras, expomos a situação de uma pessoa que esteja rea-

lizando uma atividade doméstica (varrendo a casa, por exemplo) e com pressão arterial sistólica alta – denominaremos *desvioPASAtivDomestica* a variável apresentada na Figura 4.3. As seguintes regras estão envolvidas, sendo que as duas últimas podem ser ativadas:

```

If (atividade is ativDomestica) and (desvioPASAtivDomestica is muitoBaixo) then (acao is emergencia)
If (atividade is ativDomestica) and (desvioPASAtivDomestica is baixo) then (acao is alerta)
If (atividade is ativDomestica) and (desvioPASAtivDomestica is normal) then (acao is normal)
If (atividade is ativDomestica) and (desvioPASAtivDomestica is alto) then (acao is alerta)
If (atividade is ativDomestica) and (desvioPASAtivDomestica is muitoAlto) then (acao is emergencia)

```

Os conjuntos ‘muitoBaixo’ e ‘muitoAlto’ possuem funções de pertinência, respectivamente, *zmf* (*z-shaped membership function*) e *smf* (*s-shaped membership function*), enquanto os demais conjuntos são trapezoidais. Uma outra alternativa seriam funções trapezoidais para todos os conjuntos. No entanto, exploramos o uso das formas em ‘z’ e ‘s’ para a transição do alerta para emergência. Nossa justificativa é de que essa transição não é gradual, pois há a necessidade de um “suficientemente muitoAlto” para ir para uma emergência. Esse comportamento é esperado pela área médica, pois, na ocorrência de uma emergência, as atitudes tomadas são bem diferentes das que se emprega em um alerta. No entanto, essa escolha deve ser mais bem investigada em um trabalho futuro, pois a diferença em relação a uma trapezoidal é muito pequena.

A variável *tempo* é necessária durante a execução do sistema para uma análise mais apurada dos casos de alertas ou de emergências. As emergências têm uma maior significância quando são confirmadas por medições sucessivas em um curto espaço de tempo. Já nos alertas, uma concentração em um determinado período pode ser um fato a ser estudado clinicamente. Um procedimento que faz uma avaliação considerando o tempo pode ser implementado após a inferência da medição. Para esta pesquisa, enfocaremos somente a inferência da medição isolada.

A variável temperatura ambiente (Figura 4.5) pode fazer parte das regras, pois podem ocorrer alterações nos sinais vitais mediante a diferença da temperatura ambiente para a temperatura corporal. Uma regra tolerante poderia garantir um estado “normal” para um paciente que tem pequenas alterações de pressão arterial decorrentes da temperatura ambiente. Já em uma regra direcionada para um paciente mais sensível, por exemplo, a temperaturas altas, uma elevação da pressão, nessas circunstâncias, poderia resultar em um alerta, para que uma recomendação fosse direcionada ao paciente. No entanto, cabe ressaltar que a variável de temperatura ambiente não é registrada pelo exame de MAPA.




Figura 4.5: Temperatura ambiente

A configuração do sistema de inferência *fuzzy* foi aperfeiçoada durante o desenvolvimento do trabalho. A configuração final possui os seguintes parâmetros: o sistema de ‘inferência’ é o ‘Mamdani’; na ‘implicação’ é utilizado o operador ‘mínimo’; na ‘agregação’, o operador ‘soma’ foi utilizado; o ‘bissetor’ foi o método de ‘defuzzificação’ empregado. Esses parâmetros foram interessantes para o tipo de problema e direcionados para obter uma saída do sistema gradual em cada estado do paciente. Os parâmetros foram obtidos experimentalmente, levando em consideração as estratégias do Modelo de Decisão.

A definição dos pesos para cada regra também tem papel decisivo na solução. Esses pesos refletem os requisitos do problema quanto à individualização e à identificação de situações críticas. Os critérios adotados para a definição dos pesos são os seguintes: as regras com as médias do paciente devem ter maior peso do que as regras que valem para todos os pacientes (denominadas regras genéricas); as situações de emergência têm prioridade em relação às situações de alerta ou de normalidade; as regras que não incluem a pressão arterial, como, por exemplo, as regras de frequência cardíaca e de temperatura ambiente, recebem um peso mais baixo, devido à maior importância clínica da pressão arterial.

Um total de 63 regras fazem parte da modelagem (vide Apêndice C). Essa grande quantidade se justifica pela repetição das regras considerando cada uma das 5 atividades. Para cada atividade temos 10 regras que tratam a PAS e a PAD. As 13 regras restantes incluem regras que reforçam as situações de emergência (denominadas de regras de reforço), mas específicas para os pacientes hipertensos; regras genéricas; e regras com variáveis que não envolvam a pressão arterial. Um exemplo desse último caso é uma regra que dá um primeiro passo para associar os sinais vitais com as variáveis ambientais: se a frequência cardíaca é alta e a temperatura ambiente é alta então a ação é normal (o peso atribuído para essa regra é 0,1).

## 4.3 Módulo de Aprendizado

Esta Seção apresenta a descrição do Módulo de Aprendizado, o qual permitirá atualizações no Módulo de Inferência. O objetivo deste Módulo é personalizar os parâmetros das regras, usando para isso a experiência do médico e os dados de um longo tempo de monitoramento. São apresentadas as estratégias, a questão da interpretabilidade no ajustamento do sistema de inferência, o uso de dados sintéticos e a descrição do Módulo de Aprendizado.

### 4.3.1 Estratégias de Projeto para o Módulo de Aprendizado

As seguintes estratégias funcionais foram selecionadas para projetar o Módulo de Aprendizado ('A') e estão acompanhadas de discussões ou diretrizes:

- A1. O sistema deve avaliar os casos de alertas quanto à sua relevância clínica, para, eventualmente, acionar o mecanismo de aprendizado. A relevância clínica é determinada pelo médico e representada no sistema pela variável de saída (estado do paciente). O sistema deve, então, ter a capacidade de consultar alertas e histórico, oferecendo ao médico uma proposta de ajuste.
- A2. Os casos de alerta em atividades específicas podem passar a ser considerados normais (por exemplo, no caso do descenso noturno, que leva alguns pacientes a terem valores baixos de pressão arterial enquanto dormem). Para atender a essa estratégia, terá que ser feita uma modificação específica nos parâmetros da variável relacionada à atividade.
- A3. Não deve ser alterado o que é considerado uma emergência de alta pertinência. O sistema deve preservar as regras de emergência, para que seja confiável quanto a não deixar de perceber casos relevantes que requeiram notificação (evitar casos de falsos negativos).
- A4. Os valores mais distantes em relação às médias dos casos de interesse devem ser desconsiderados no aprendizado. O sistema deve encontrar novos valores toleráveis, mas que não considerem valores extremos já ocorridos. Estas alterações devem ser incrementais, tendo prudência na proposta de ajuste.
- A5. Os valores propostos para ajuste devem ser válidos para uma atualização no modelo. Um ajuste não deve gerar conflitos entre regras, portanto o aprendizado

deve ser limitado e, ainda, supervisionado por um especialista. Com isso, a necessidade de clareza nas regras (no sentido de transparência ou interpretabilidade das regras) deve ser cumprida. Ajustes que alterem a formação inicial das regras não devem ser propostos.

- A6. Deve haver uma análise de significância estatística para validar os experimentos com o aprendizado. Um sistema de monitoramento de saúde deve ser exaustivamente testado antes de ser usado em pacientes. Neste trabalho, faremos uma avaliação preliminar com testes usando dados reais de MAPA e gerando dados sintéticos para formar séries maiores. Adicionalmente, é de fundamental importância obter intervalos de confiança e os resultados serem avaliados por médicos.
- A7. O especialista não deve ser solicitado para interações frequentes com o sistema para realizar o aprendizado. Mesmo que o sistema ofereça a flexibilização de seus parâmetros, o sistema deve chegar a uma proposta de ajuste de forma automática. Cabe ressaltar que existem muitas variáveis envolvendo o conhecimento da tolerância de cada sinal vital associado a cada atividade. Assim, o médico especialista deveria examinar todas as variáveis mudando, por exemplo, parâmetros e/ou limites de variáveis. É necessário, então, um mecanismo que possibilite expressar em um nível mais alto a tolerância que o sistema deve usar para automaticamente aprender e se adaptar.

### 4.3.2 A Questão da Interpretabilidade no Ajuste do Sistema de Inferência *Fuzzy*

A Subseção anterior apresentou as estratégias de projeto referentes ao Módulo de Aprendizado. Nesta Subseção, discutimos uma estratégia essencial para sistemas de monitoramento de saúde: a interpretabilidade das regras. Essa discussão serve para tomarmos as principais decisões para o projeto do Módulo.

Uma questão de extrema relevância para sistemas de monitoramento de saúde diz respeito ao entendimento das regras por parte dos especialistas de saúde. A estratégia ‘A5’ determina que ocorra esta interpretabilidade das regras. O médico necessita compreender o mecanismo de inferência do estado do paciente, principalmente após uma proposta de alteração da regra.

O projeto de um sistema de inferência *fuzzy* pode ser originado do conhecimento do especialista ou de dados. Segundo [52], o sistema baseado no conhecimento do especialista



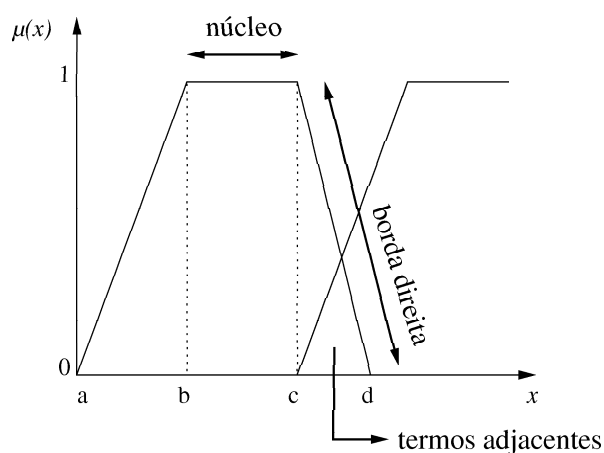


Figura 4.6: Conceitos úteis para mudanças dos conjuntos *fuzzy*

pode sofrer uma perda de acurácia. Em [30] é sugerido que o usuário escolha um nível de compromisso entre acurácia e transparência, envolvendo a seleção de valores apropriados para parâmetros do sistema de inferência. Assim, acreditamos que as alternativas devem ser avaliadas para obter um sistema que apresente interpretabilidade, ao mesmo tempo em que permita o ajuste do sistema de inferência, respeitando as características do problema de monitoramento de saúde.

A evolução/ajuste do sistema de inferência *fuzzy* pode ser classificada em duas grandes abordagens: a adaptação dos conjuntos das funções de pertinência ou a adaptação das regras *fuzzy*. Cada uma dessas abordagens usa dados de treinamento para realizar as adaptações. Em [58], são apresentadas diferentes formas para realizar essas duas adaptações. Retirando os aspectos das técnicas genéticas apresentadas por Huang e usando os conceitos *fuzzy* apresentados na Figura 4.6, podemos entender melhor quais são as operações possíveis em cada abordagem. A adaptação dos conjuntos *fuzzy* pode fazer as seguintes operações: deslocar, mudar o núcleo ou adicionar. O *deslocamento* leva todo o conjunto para uma nova posição no eixo 'x'. Já a *mudança do núcleo* altera somente o núcleo do conjunto. Por último, a *adição* cria um novo conjunto. Já na abordagem de adaptação das regras *fuzzy*, as operações atuam sobre as regras para: mudar (substituir a variável da regra, trocar um termo de uma regra ou mudar um operador da regra), adicionar ou habilitar/desabilitar. A *mudança* permanece com a regra, mas pode alterar totalmente o seu significado. A *adição* de uma nova regra gera uma regra para o sistema de inferência. A *habilitação ou desabilitação* pode ser feita pela alteração do peso da regra.

Na abordagem de adaptação das regras *fuzzy*, temos dois principais exemplos de técnicas: *Neuro-fuzzy* ou *Fuzzy Genéticos* [55]. Sistemas *Neuro-fuzzy* combinam a capacidade

de aprendizado das redes neurais com a representação de conhecimento da lógica *fuzzy*. Trabalhos recentes têm explorado essa técnica, inclusive em ambientes sensíveis ao contexto [11]. Os sistemas *Fuzzy Genéticos* utilizam algoritmos genéticos para também automatizar a aquisição de conhecimento. Por meio das operações de *crossover* e mutação, os algoritmos geram novos parâmetros e/ou novas regras, para o sistema *fuzzy* [55]. O uso de redes neurais no projeto de funções de pertinência já é bem antigo. Segundo [108], em 1988 os primeiros trabalhos lançaram essa ideia. No ano posterior, os algoritmos genéticos foram utilizados para esse propósito.

Apesar de sistemas de *Neuro-fuzzy* e *fuzzy genéticos* obterem bons resultados em várias áreas em que são aplicados, eles produzirão mudanças significativas no conjunto de regras iniciais de um sistema de monitoramento de saúde. No contexto do nosso trabalho, essas mudanças têm que ser minimizadas para preservar a interpretabilidade das regras, buscando uma solução que não crie novas regras e use poucas variáveis no antecedente da regra.

Segundo [49], quanto maior o número de variáveis, mais o número de regras aumenta drasticamente e, conseqüentemente, o número de instâncias necessárias para aprender o conjunto de regras. Uma questão associada é que a modificação de um conjunto *fuzzy* em uma variável tem reflexo em todas as regras que usam aquela variável. Segundo [38], é preferível criar núcleos maiores de conjuntos *fuzzy*.

No caso da criação de uma nova regra, o lançamento da regra pode entrar em conflito com outra já existente, além de prejudicar a interpretabilidade das regras. Se permitirmos que cada médico que faça uso do sistema possa criar novas regras também abriremos espaço para erros no sistema. Então, concluímos que a preservação das regras após o aprendizado manterá consistente o conhecimento médico embutido no sistema de inferência *fuzzy*.

### 4.3.3 Geração de Dados Sintéticos para o Monitoramento de Sinais Vitais

Esta Subseção investiga a questão da preparação dos dados para submetê-los para o módulo de Aprendizado. Para construir um protótipo para o módulo de Aprendizado, é importante executar testes. O principal objetivo da preparação é obter uma quantidade suficiente de dados realísticos para que os resultados do módulo sejam estatisticamente válidos. Se tomarmos somente os dados de MAPA e de poucos dias de monitoramento e ainda restringirmos aos casos que estão no subintervalo de alertas leves, teremos medições

insuficientes para aprender. Uma alternativa, então, é aumentar essa quantidade por geração de dados sintéticos.

Para tanto, é fundamental gerarmos dados sintéticos que se aproximem dos dados reais. Um passo muito importante nessa direção é a geração com base nos dados de MAPA, que é uma monitorização bem estabelecida na prática médica.

No entanto, outras questões são necessárias para aprimorarmos a geração de dados sintéticos. O problema torna-se ainda mais complexo no controle da pressão arterial, foco de nosso estudo de caso. Assim, acreditamos que seja de grande importância responder a duas questões:

a) Os dados sintéticos de PAS ou de PAD possuem a mesma distribuição de probabilidade dos dados originais?

b) Os dados sintéticos mantêm a correlação entre PAS e PAD verificada nos dados originais?

Ao analisarmos a distribuição em dados de MAPA<sup>2</sup> identificamos uma distribuição normal, mas isso só é válido quando limitamos os dados para somente uma atividade específica. Essa constatação é razoável, pois sabemos que, na maior parte das pessoas, os valores mais altos de pressão são obtidos na vigília, e os mais baixos, no sono, da mesma forma que o esforço físico pode elevar os sinais vitais. Cabe ressaltar que a atividade que consta na MAPA depende da informação dada pelo paciente e, muitas vezes, essa informação não é dada ou é dada de forma incorreta. Mesmo assim, nos dados que temos disponíveis, a distribuição normal é encontrada somente quando separamos os dados por atividade.

Então, o emprego da distribuição normal na geração de dados sintéticos aumenta a possibilidade de obter dados mais próximos dos dados reais e permite serem testados no mecanismo de aprendizagem. Outro argumento é de que a distribuição normal já foi experimentada em outros trabalhos de análise de sinais fisiológicos [42] [80] [110].

Quanto à correlação entre os sinais vitais, sabemos do grande desafio que isso representa. A correlação depende de paciente para paciente: quando um sinal vital aumenta em algumas pessoas, outro sinal vital também aumenta; dependendo de outros fatores, um sinal vital pode subir e outro pode descer. Essa correlação deve ser preservada nos dados sintéticos, a fim de reproduzir, o mais próximo da realidade, os sinais vitais do paciente.

---

<sup>2</sup>Utilizamos exames de MAPA de pacientes reais descritos no Capítulo 5.

Com o objetivo de gerar dados com o máximo de características dos dados de MAPA, usamos o programa de simulação GenData [99], que gera dados preservando a correlação do conjunto de dados. Por fim, um processo de eliminação/filtragem nos dados sintéticos é realizado, mais especificamente nos valores de pressão arterial, retirando valores praticamente impossíveis de acontecer para cada paciente. Três regras foram definidas para essa filtragem com base nos dados de MAPA: a) É subtraído 10 do menor valor de cada sinal vital nos dados de MAPA do paciente. Todos os valores menores do que o valor calculado são eliminados dos dados sintéticos; b) Já no lado do maior valor de cada sinal vital, após um incremento de 10 no maior valor, são eliminados todos os maiores nos dados sintéticos; c) De posse do menor valor da pressão de pulso ( $PAS - PAD$ ), é feita uma subtração de 10 são eliminadas todas as medições que possuam um valor inferior. O valor 10mmHg é usado como uma margem de segurança para aceitar dados que sejam próximos aos já ocorridos.

O Algoritmo 1 apresenta a descrição da forma que geramos dados sintéticos mantendo as características dos dados reais de MAPA (ABPM: *Ambulatory Blood Pressure Monitoring*). Inicialmente, os dados são separados por atividade. Em seguida, as características dos dados originais (menor, maior e correlação) são obtidas. A tarefa de geração dos dados é feita pela função *normalDistribution()* que mantém a correlação dos dados. Por fim, o filtro de dados é aplicado.

```

1 tolerance = 10;
2 activity = {sleeping, resting, eating, walking, domesticActiv};
3 foreach patient do
4     foreach activity do
5         data = getABPMData(activity);
6         restrictions[] = getMinorAndMajorValueFromVitalSigns(data, tolerance);
7         correlation = getVitalSignsCorrelation(data);
8         syntheticData[activity][] = normalDistribution(data, correlation);
9         syntheticData[activity][] = dataFilter(syntheticData[activity],
10            restrictions);
11     end
12 end

```

**Algorithm 1:** Algoritmo de geração de dados sintéticos

### 4.3.4 Descrição do Módulo de Aprendizado

Esta Subseção apresenta o funcionamento do Módulo de Aprendizado, o qual faz uma análise do histórico do paciente e propõe ao médico um ajuste nas regras do modelo. Um exemplo prático de necessidade de ajuste é o paciente ter usualmente um descenso noturno muito elevado, o que deveria ser ajustado no sistema para não gerar alarmes desnecessários. Situação semelhante ocorre com pacientes que sofrem com picos moderados de pressão, que, por avaliação médica, não são considerados graves.

Uma primeira questão que surge no aprendizado é por que o sistema deve ser ajustado? A principal motivação do ajuste é de reduzir o número de alertas, personalizando o tratamento, sem deixar de lançar alertas para eventos importantes. Em outras palavras, é ajustar o modelo com base na relevância dos alertas, para cada paciente individualmente.

A questão que vem em seguida é: quais são os alertas sem grande relevância? Esses alertas são denominamos de “alertas leves”. Nosso objetivo é que o sistema possa aprender usando casos de alertas ao longo do tempo e passe a considerar “normais” casos que o sistema reconhece atualmente como alertas leves. Essa tarefa de analisar os alertas sem relevância deve ser supervisionada por um médico, conforme definido na estratégia ‘A1’.

Dessa forma, dois resultados podem ser obtidos após o ajuste: alargar ou estreitar o intervalo de normalidade. Após uma grande quantidade de dados monitorados, pode-se ter uma amostra considerável de alertas. A amostra servirá para definir como serão os ajustes, tolerando uma maior variação nos sinais vitais, ou restringindo ainda mais as regras.

A Figura 4.7 apresenta o fluxo do mecanismo de Decisão para inferência de contexto. O processo de aprendizado ocorre sob supervisão médica. Essa intervenção é facilitada pelo parâmetro que define o conceito para alertas leves. A necessidade de usar uma quantidade substancial de dados para aprender é solucionada por considerar os dados de MAPA e os dados sintéticos. Ao final, o médico confirma as alterações nas regras propostas pelo sistema. Da mesma forma, uma mudança para um conjunto de regras mais rígido ou para um conjunto mais tolerante fica a cargo do médico. O mecanismo como um todo evidencia um dos pontos mais importantes do sistema: o aprendizado é individualizado e, ao longo do tempo, personaliza a tomada de decisão sobre situações críticas.

Assim, no projeto do mecanismo de ajuste de regras definimos as três seguintes *fases*:

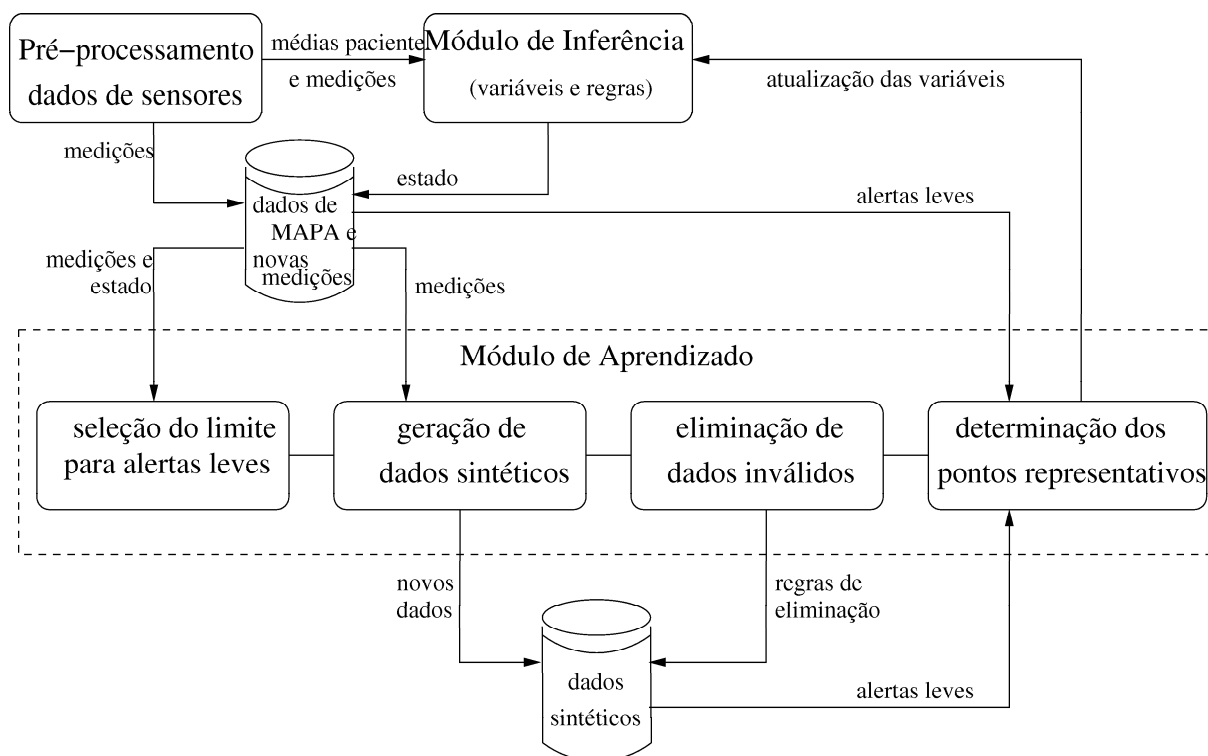


Figura 4.7: Mecanismo de Decisão para inferência de contexto

1. selecionar um subintervalo dos casos de alertas leves
2. encontrar um ponto representativo
3. ajustar as regras específicas às atividades

A seguir, são discutidas cada uma dessas fases.

#### 4.3.4.1 Fase 1: selecionar um subintervalo dos casos de alertas leves

A primeira decisão a ser tomada diz respeito a quais serão os dados usados pelo aprendizado. O médico atua nessa fase selecionando o subintervalo de casos de alerta. Por exemplo, o médico seleciona o subintervalo em que o estado seja  $> 0,4$  e  $\leq 0,65$ . Isso satisfaz a seleção, pois o valor  $0,4$  é o valor obrigatório (valor original de limite da faixa para normalidade, conforme Figura 4.4).

A Figura 4.8 apresenta uma interface que será usada pelo médico para selecionar o subintervalo.

O recurso de seleção do subintervalo proporciona ao médico a possibilidade de expressar o grau de absorção dos casos de alerta pelo Modelo de Decisão. Assim, o médico define um valor limite para a variável “maxAlertaLeve”. Todos os casos de alertas desse

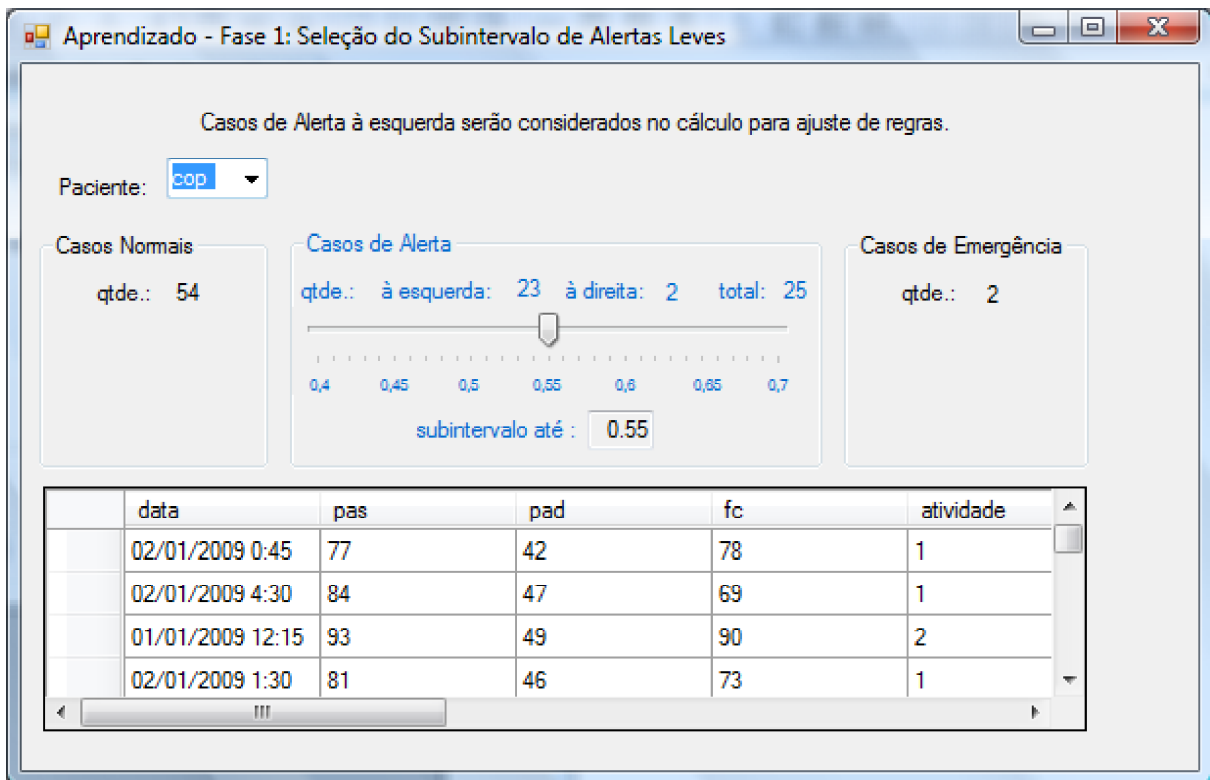


Figura 4.8: Interface de Seleção do Subintervalo de Alertas

subintervalo contribuirão para determinar um ponto de ajuste. O objetivo final é ajustar as regras do Módulo de Inferência, para que os casos de “alertas leves” se tornem normais. A próxima fase encontrará um ponto que represente esse subintervalo.

#### 4.3.4.2 Fase 2: encontrar um ponto representativo

Nesta fase, depois de obtida a variável “maxAlertaLeve”, queremos encontrar o ponto central (ou representativo) dos casos de alerta que se encontram nesse subintervalo. O ponto central é um conjunto de valores de variáveis usado como referência para ajustar as regras. O ponto central deve atender as estratégias de projeto definidas na Subseção 4.3.1 – ‘A4’ e ‘A5’ definem, respectivamente, a não utilização de casos extremos para o cálculo do ponto central e a validade do ajuste sem cometer alterações em excesso.

Em nosso estudo de caso de monitoramento, independentemente da técnica escolhida para determinar o ponto central, os alertas ocorrem de duas formas: ou estão acima da média de pressão arterial ou estão abaixo. O que contribui para essa afirmação é a correlação entre PAS e PAD, investigada em [48]. Nesses dois grupos, temos que desconsiderar, ou dar menor importância, para valores extremos (*outliers*). Portanto, duas propriedades são desejáveis para a técnica: a eliminação de *outliers* e a definição de agrupamentos

(*clusters*).

Outra questão diz respeito ao enfoque dado pelo nosso trabalho para a PA, composta pela PAS e pela PAD. A PAS-PAD possui uma singularidade entre outros sinais vitais, pois, no processamento da pressão arterial, os dois valores não estão dissociados. Por outro lado, também é possível tratar de forma isolada cada uma dessas variáveis.

Nossa proposta é que três diferentes técnicas sejam testadas para encontrar o ponto representativo, usando as variáveis do estudo de caso. O tratamento em separado da PAS e PAD será feito por uma técnica simples, denominada de média e desvio padrão (MDP). O tratamento em conjunto será feito por duas técnicas que usam agrupamentos: *Fuzzy c-Means* (FCM) e Gustafson-Kessel (GK). Essas duas técnicas foram escolhidas por diferirem no método para calcular a distância em relação ao ponto central. Com uma solução tomando as médias de PAS/PAD acima e/ou abaixo da média do paciente, obtemos valores em separado que podem não trazer a correlação PAS/PAD do paciente. Assim, uma questão a ser investigada é a eficiência de técnicas que tratam PAS e PAD de forma separada ou em conjunto.

A seguir, as três técnicas são apresentadas, enquanto os testes e detalhes das técnicas são apresentados na Subseção 5.2.

### **Média e desvio padrão (MDP)**

De acordo com a estratégia A4, os valores mais distantes da média do conjunto de alertas não devem ser considerados no aprendizado. O método de média e desvio padrão faz esse controle por meio do desvio padrão.

No método MDP, de posse dos casos de alerta, separamos os valores de PAS/PAD e, posteriormente, dividimo-los em valores acima e abaixo da média. São então formados quatro grupos, em torno da média geral de PAS/PAD do paciente. O primeiro grupo contém os valores de PAS superiores à média. No segundo grupo estão os valores de PAD superiores à média. O terceiro grupo contém os valores de PAS inferiores à média. No quarto grupo estão os valores de PAD inferiores à média. Os seguintes *passos* são executados para os grupos:

1. calcular a média
2. calcular o desvio padrão
3. eliminar valores extremos



#### 4. recalcular a média

O procedimento do passo 3 é a eliminação dos pontos situados nas extremidades do agrupamento (*outliers elimination*). Para isso, é utilizada a média acrescida (ou subtraída) de 1 desvio padrão. Assim, como regra, esse mecanismo utiliza 68% dos valores do conjunto de dados, assumindo uma distribuição normal.

Devido à simplicidade da MDP, essa técnica também pode ser usada para outros dados fisiológicos, como frequência cardíaca e peso. No entanto, devido ao relacionamento entre PAS e PAD, é interessante explorar técnicas que proporcionem uma abordagem mais sofisticada de tratamento, o que é feito pelas técnicas de agrupamento.

#### **Agrupamento FCM**

Empregaremos dois algoritmos na determinação dos agrupamentos e, mais especificamente, para encontrar o ponto central do agrupamento: *Fuzzy c-Means* (FCM) [20], que usa a distância Euclidiana para o cálculo do ponto central; e Gustafson-Kessel (GK) [53], que usa a distância de Mahalanobis para o cálculo do ponto central.

Na técnica de FCM, a função objetivo é minimizar a distância Euclidiana entre cada objeto de dados e seu centro do agrupamento. Um objetivo paralelo é maximizar a distância Euclidiana entre centros de agrupamentos [97]. A distância Euclidiana entre os pontos  $a$  e  $b$ , num espaço Euclidiano  $n$ -dimensional, tendo:  $a = (x_1, x_2, \dots, x_n)$  e  $b = (y_1, y_2, \dots, y_n)$ , é:

$$d(a,b) = \sqrt{(x_1 - y_1)^2 + (x_2 - y_2)^2 + \dots + (x_n - y_n)^2}$$

Tanto na FCM quanto na GK é necessário escolher previamente qual quantidade de agrupamentos ( $c$ ) que se quer formar. Definimos  $c = 2$ , referindo-nos ao agrupamento de valores acima da média e ao agrupamento de valores abaixo da média. Como já explicado, esse comportamento é esperado, devido ao fato de que os alertas só podem ser maiores ou menores do que a média do paciente.

A Figura 4.9 apresenta as possibilidades de concentração dos pontos de alerta. Dentro da área circular, que inclui a média geral do paciente, a possibilidade de casos de alertas é baixa. Externamente ao círculo, estão identificados os 4 quadrantes, usados para visualizar onde podem ocorrer agrupamentos de alertas. No entanto, consideramos que 2 pontos representativos (podendo estar em 2 quadrantes diferentes ou em 1 somente) são suficientes, pois queremos obter um ponto que represente concentrações específicas de




Figura 4.9: Áreas possíveis de agrupamentos de alertas

variações de pressão arterial. Com 2 pontos representativos é possível termos um ponto acima e/ou abaixo da média, para o caso de PAS e/ou de PAD. Conforme a experiência médica, um fato que se encaixa nessa restrição é que, em idosos, geralmente ocorre uma PAS alta e uma PAD que se mantém inalterada. O ponto representativo, nesse caso, fica entre o 1º e o 4º quadrantes.

Vejamos um exemplo: um paciente com média de PAS/PAD (em mmHg) de 125/85 e os resultados para os dois pontos representativos em 110/70 (3º quadrante) e em 140/75 (4º quadrante). Para a PAS, os dois pontos representativos dos alertas são 140 e 110: um valor acima e outro abaixo da média. Com isso, podemos alterar o núcleo do conjunto normal da variável de PAS (em uma determinada atividade), tanto para cima quanto para baixo. Já no caso da PAD, o ajuste pode ser de 70 ou de 75, pois ambos os valores são menores do que a média de 85. Portanto, a proposta de ajuste não apresenta ajuste para acima da média e somente um valor de PAD, como esperado, para abaixo da média. Para esse último, a escolha de um dos dois valores, sendo conservadora, usa como critério o valor mais próximo da média 85, que é o 75. Assim, nos métodos de agrupamentos (incluindo o GK, que será mostrado), durante o cálculo do ponto representativo/central, os valores PAS/PAD são tratados em conjunto. No entanto, são separados no momento em que é feito o ajuste de cada variável.

### Agrupamento GK

O algoritmo de Gustafson-Kessel também é uma técnica de agrupamento, que utiliza Mahalanobis na determinação do ponto central e é indicada para configurações de agrupamento aproximadamente hiperelipsoidais [82], enquanto o FCM é mais indicado para formas hiperesféricas. A distância de Mahalanobis distingue-se da distância Euclidiana por levar em conta as correlações do conjunto de dados. Essa característica pode ser in-

interessante em relação à PAS-PAD, por determinar um centro do agrupamento com maior quantidade de pontos à sua volta. Outra vantagem é identificar um grupo que englobe dois quadrantes que estejam lado a lado, formando uma elipse.

A distância de Mahalanobis entre um grupo de valores com média  $\mu = (\mu_1, \mu_2, \mu_3, \dots, \mu_p)^T$  e matriz de covariância  $\Sigma$  para um vetor multivariado  $x = (x_1, x_2, x_3, \dots, x_p)^T$  é definida como:

$$D_M(x) = \sqrt{(x - \mu)^T \Sigma^{-1} (x - \mu)}$$

#### 4.3.4.3 Fase 3: ajustar as regras específicas às atividades

O ajuste de regras específicas para cada atividade é a última fase do aprendizado. Ela acontece após ser encontrado o ponto representativo dos casos de alerta. Inicialmente, o ponto representativo (encontrado por qualquer uma das 3 técnicas apresentadas) é subtraído da média do paciente e resulta no desvio. Por exemplo, se o valor do ponto representativo de PAS é 140 e a média do paciente é 125, então o desvio será  $140 - 125 = 15$ . O desvio será o parâmetro para a atualização de uma regra existente.

A seguir, apresentamos um exemplo de como as regras em atividades específicas podem ser ajustadas. Para tanto, tomaremos as regras de repouso em relação à PAS como exemplo:

If (atividade is repouso) and (desvioPASRepouso is muitoBaixo) then (acao is emergencia)  
 If (atividade is repouso) and (desvioPASRepouso is baixo) then (acao is alerta)  
 If (atividade is repouso) and (desvioPASRepouso is normal) then (acao is normal)  
 If (atividade is repouso) and (desvioPASRepouso is alto) then (acao is alerta)  
 If (atividade is repouso) and (desvioPASRepouso is muitoAlto) then (acao is emergencia)

A variável *desvioPASRepouso*, que faz parte dessas regras, é mostrada na Figura 4.10-a e mais bem definida na Tabela 4.1.

Tabela 4.1: Variável *desvioPASRepouso*

Termo da variável	Função de pertinência (f.p.)	Parâmetros da f.p.
muitoBaixo	Zmf	[-50; -20]
baixo	Trapezoidal	[-50; -20; -10; -5]
normal	Trapezoidal	[-10; -5; 5; 10,7]
alto	Trapezoidal	[5; 10,7; 20; 50]
muitoAlto	Smf	[20; 50]



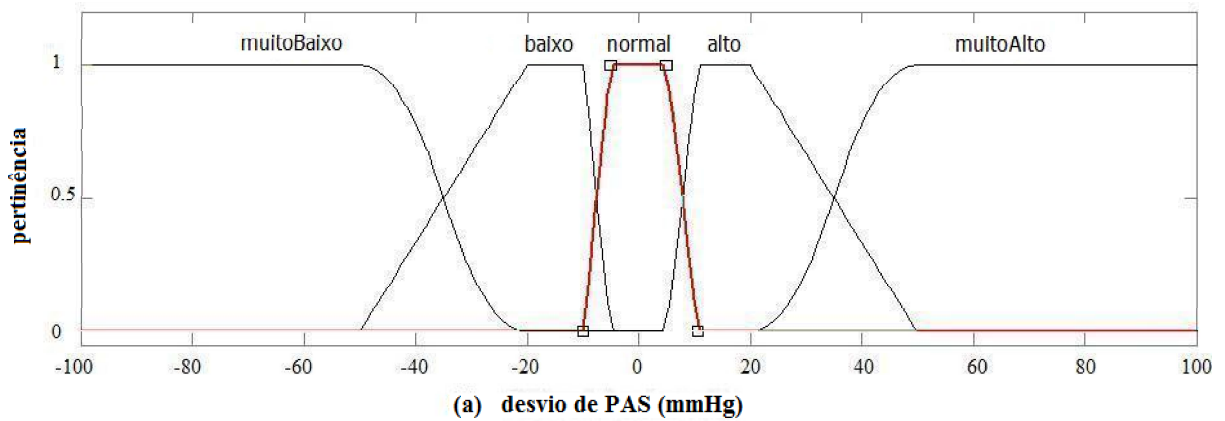


Figura 4.10: Variável de pressão arterial sistólica na atividade de repouso: (a) situação inicial, com o núcleo do conjunto normal em  $[-5,5]$ ; (b) após o ajuste com desvio=10, o núcleo do “normal” passa a ser  $[-5,10]$ ; (c) após o ajuste com desvio=-10, o núcleo do “normal” passa a ser  $[-10,5]$

Nossa metodologia para o ajuste consiste em manter as distâncias entre os termos adjacentes (vide Figura 4.6) estabelecidas nas regras iniciais, pois assim preservamos o conhecimento médico incorporado ao modelo. Ao mesmo tempo, evitamos que ocorram sobreposições com total pertinência, como, por exemplo:  $\exists x \mid \mu_{normal}(x) = \mu_{alto}(x) = 1$ , onde  $\mu_A(x)$  é a pertinência de  $x$  no conjunto  $A$ .

Para efetivar esta alteração de parâmetro do conjunto *fuzzy*, temos que observar alguns valores: a distância da borda direita do trapézio no termo “normal” é de 5,7 ( $10,7 - 5$ ), o que denominaremos “bordaDireitaNormal”; e a “bordaEsquerdaNormal” é 5 ( $|-10 - (-5)|$ ); além disso, a distância entre o terceiro e o segundo parâmetro do trapézio para o termo “alto” é 9,3 ( $20 - 10,7$ ), que corresponde ao núcleo do “alto”. Com esses valores, podemos aumentar o núcleo do “normal”, ao mesmo tempo em que mantemos tanto a borda direita do termo “normal” quanto o núcleo do “alto”. Um requisito final é não alterar a área de total pertinência do termo “muitoAlto”, que implica uma emergência (conforme orienta a estratégia A3).

A fase de encontrar um ponto representativo, apresentada na Subseção 4.3.4.2, resultou em um valor de PAS e/ou PAD. Vamos supor neste momento que dois valores para o resultado de PAS foram obtidos: um em que o desvio é de +10 em relação à média do paciente e outro em que o desvio é de -10.

a) Desvio proposto de +10 para a PAS

Após um ajuste com esse desvio, a situação esperada para a variável *desvioPASReposo* é apresentada na Figura 4.10-b. Os conjuntos modificados são: “normal”, “alto” e “muitoAlto”. Isso se deve ao fato de que o desvio deste exemplo é para acima da média. O núcleo do “normal”, que era  $[-5,5]$ , passa a ser  $[-5,10]$ .

Para fins de ilustração, usaremos duas variáveis em pontos específicos do ajuste:  $x$ , como sendo o valor do desvio, e  $y$ , como sendo o valor do desvio acrescido da “bordaDireitaNormal”. Como o desvio proposto para a PAS é desvio=10, então a alteração será:

normal:  $[-10; -5; x; y]$   
alto:  $[x; y; y + 9,3; 50]$

Onde  $x$  é o desvio ( $x = 10$ ) - deve ser verificado se o mínimo aceito para o desvio é maior do que 5 (que é o valor original, conforme a Tabela 4.1):  $\max(\text{desvioProposto}, 5)$ ;

$y$  é o desvio acrescido da “bordaDireitaNormal” ( $y = 10 + 5,7$ )

b) Desvio proposto de  $-10$  para a PAS

Neste exemplo, que usa um valor abaixo da média (valor de PAS para o ajuste é de desvio= $-10$ ), então a alteração será:

muitoBaixo:  $[-50; y - 10]$

baixo:  $[-50; y - 10; y; x]$

normal:  $[y; x; 5; 10,7]$

Onde  $x$  passa a ser  $-10$  - deve ser verificado se o mínimo aceito para o desvio não é menor do que  $-5$ :  $\min(\text{desvio}, -5)$ ;  $y$  passa a ser  $(-10 - 5)$  - deve ser satisfeita a condição:  $(-5 - 10) > -50$ .

A Figura 4.10-c mostra o resultado da variável após o ajuste para o lado esquerdo.

## 4.4 Trabalhos Relacionados

Os sistemas atuais de tratamento de saúde em casa exigem que a pessoa informe emergências através do acionamento de alarmes, como, por exemplo, por meio de um botão de pânico. Ou então, que os sistemas reajam quando limites pré-fixados de sinais vitais são ultrapassados, como em [70][88]. Há, nesses casos, a necessidade de identificar situações críticas com maior eficiência, tendo um compromisso entre acionar alarmes e ser tolerante às variações de sinais fisiológicos.

No entanto, pouco avanço foi realizado até hoje na fusão das diferentes classes de variáveis envolvidas no monitoramento. Em [92], é apresentado um estudo explorando o relacionamento entre variáveis psicológicas e fisiológicas no monitoramento domiciliar; algumas variáveis comportamentais também são consideradas e realizadas correlações entre as variáveis. Por exemplo, níveis altos de estresse estão associados com menor tempo de sono. Já em [41], é construído o perfil comportamental da pessoa monitorada em casa, investigando o relacionamento entre variáveis comportamentais e fisiológicas, em especial, a frequência cardíaca.

A análise para uma tomada de decisão, apresentada em [104] na forma de agentes inteligentes, tem como fundamento o armazenamento de sinais vitais durante um período de 24 horas e a comparação com limites rígidos que toleram uma determinada variação.

Por exemplo, o peso corporal não pode ultrapassar limites superiores ou inferiores de +10 e -10 unidades no período de 24 horas. Em pacientes que enfrentam um aumento gradual de peso durante alguns dias, devido, entre outras coisas, à retenção de líquido, os agentes podem não reconhecer essa situação crítica. Em nossa solução, o prontuário eletrônico armazena valores médios de exames que são usados em conjunto com a avaliação das regras. Se ocorrer um aumento constante de determinado sinal vital, as regras conseguem identificar essa situação, pois existem regras para comparar com o valor médio e regras genéricas que estabelecem os valores alvo.

Em [85], é apresentada uma solução para projetar alarmes inteligentes capazes de lidar com as falhas e limitações dos alarmes com limites fixos (*threshold alarms*). O trabalho se concentra no monitoramento da evolução temporal das variáveis fisiológicas, em unidades de terapia intensiva (UTIs). Cabe ressaltar que em uma UTI geralmente ocorre a coleta de vários sinais vitais ao mesmo tempo, em um ambiente controlado, dependendo somente das variáveis fisiológicas e suas inter-relações. Já no ambiente domiciliar, ocorrem mais incertezas, e é comum não serem feitas medições regulares. No entanto, o trabalho de [85], ao modelar o tempo como variáveis *fuzzy*, pode contribuir em um trabalho futuro para adicionarmos essa variável em nossa solução.

## 4.5 Conclusões do Capítulo

Neste Capítulo, apresentamos um mecanismo de Decisão para inferir contexto. O contexto inclui classes de variáveis ambientais, fisiológicas e comportamentais de um paciente sendo monitorado em um ambiente pervasivo de tratamento de saúde. O mecanismo expande os componentes definidos no arcabouço, envolvendo a decisão e o aprendizado e detalhando a identificação de situações críticas. Com isso, estamos colocando no arcabouço novas possibilidades, por meio da adição de técnicas adaptadas ao problema.

O monitoramento da pressão arterial ilustra bem os conceitos enfatizados no arcabouço e no mecanismo de Decisão. Assim, foram investigadas técnicas que lidam com as características dos dados sendo coletados. Destacamos, para tanto, o uso de lógica *Fuzzy* e da metodologia do aprendizado para propor ajustes ao sistema de inferência.

# Capítulo 5

## Avaliação do Mecanismo de Decisão

Este Capítulo apresenta a avaliação do mecanismo de Decisão por meio de testes com os Módulos de Inferência e de Aprendizado. No Módulo de Aprendizado, são testadas suas 3 fases (conforme Figura 4.7) e verifica-se a geração com os dados sintéticos.

Inicialmente, é preciso esclarecer que existem 3 tipos de testes importantes a serem feitos. O primeiro é a geração de cenários que simulem a necessidade de alarmes. Um segundo tipo é a comparação do mecanismo tradicional de análise de dados de MAPA com o mecanismo de Decisão de nosso trabalho. Essa comparação é conduzida durante todo o Capítulo, utilizando dados de MAPA de pacientes reais, os quais denominamos de dados originais. O terceiro tipo é a comparação entre as avaliações feitas por médicos e a avaliação feita pelo sistema.

Para viabilizar os testes iniciais, é necessária a geração de dados sintéticos para a criação de vários cenários. Outra necessidade para o uso de dados sintéticos é que as técnicas usadas no Aprendizado precisam de uma grande quantidade de dados de entrada para produzirem resultados consistentes na saída. Dessa forma, podemos realizar testes usando a simulação de vários dias de monitoramento, e ainda usar perturbações que simulem situações reais.

Os dados sintéticos são gerados com base nos dados originais de MAPA de 30 pacientes. O uso dos dados dos pacientes para essa pesquisa foi aprovado perante o Comitê de Ética em Pesquisa da Faculdade de Medicina/Hospital Universitário Antônio Pedro, da Universidade Federal Fluminense, por meio do parecer do CEP *n*.<sup>o</sup>103/09. Para cada registro de uma MAPA, novos valores de PAS, PAD e FC são gerados, mas o padrão da variável atividade é mantido. Essa estratégia está em sintonia com a nossa solução, pois associamos os dados fisiológicos ao comportamento. Ao contrário, caso uma nova






Figura 5.1: Médias de PA com os pacientes ordenados pela soma PAS e PAD

atividade seja gerada, perderemos a associação entre essas classes de variáveis.

A fim de dar suporte à análise dos dados, a Figura 5.1 apresenta as médias de pressão arterial e a sequência de pacientes ordenada crescentemente pela média geral de *PAS + PAD*. Essa sequência é respeitada em todos os gráficos dos testes. Os 4 primeiros pacientes possuem valores baixos de pressão arterial. Efetivamente, eles não são considerados hipotensos, pois as informações de pressão não estão associadas a um relato de sintoma. Assim, consideramos do 1º ao 15º paciente casos de normotensos e do 16º ao 30º casos de hipertensos.

A avaliação dos Módulos de Inferência e de Aprendizado é realizada nas Seções 5.1 e 5.2, respectivamente. A Seção 5.3 apresenta a avaliação médica. Por fim, são feitas conclusões no fim do Capítulo.

## 5.1 Avaliação do Módulo de Inferência

O objetivo da avaliação do Módulo de Inferência é verificar se os alarmes estão sendo identificados conforme ocorrem mudanças na entrada de dados. Assim, são submetidos diferentes conjuntos de dados ao Módulo de Inferência. Inicialmente, os dados originais de MAPA são submetidos ao Módulo.

A Tabela 5.1 apresenta os resultados do sistema de identificação de alarmes para os dados de MAPA pelo método tradicional e pelo sistema proposto neste trabalho (Módulo de Inferência). Os pacientes foram classificados considerando as diretrizes apresentadas em [101], que estabelecem como hipertensos no monitoramento residencial os pacientes com pressão arterial  $> 135/85\text{mmHg}$ . No método tradicional, todas as medições acima de  $135/85\text{mmHg}$  na vigília e  $120/70\text{mmHg}$  no sono são consideradas alertas. As emergências

id	Tradicional			Sistema			%alarmes	
	normais	alertas	emerg.	normais	alertas	emerg.	Tradic.	Sistema
1	76	3	-	59	19	1	4	34
2	70	11	-	54	25	2	16	50
3	48	10	-	41	16	1	21	41
4	53	3	-	45	9	2	6	24
5	53	22	-	57	16	2	42	32
6	66	12	-	66	11	1	18	18
7	50	29	-	58	20	1	58	36
8	39	26	-	49	13	3	67	33
9	50	21	-	56	8	7	42	27
10	16	65	-	67	14	0	406	21
11	33	45	-	50	22	6	136	56
12	20	41	-	41	18	2	205	49
13	19	38	-	37	15	5	200	54
14	15	42	-	34	23	0	280	68
15	8	56	-	46	18	0	700	39

a) pacientes normotensos

id	MAPA			Sistema			%alarmes	
	normais	alertas	emerg.	normais	alertas	emerg.	Tradic.	Sistema
16	6	69	-	58	14	3	1150	29
17	1	79	-	62	17	1	7900	29
18	7	54	-	37	22	2	771	65
19	6	75	-	45	36	0	1250	80
20	1	68	-	39	24	6	6800	77
21	8	71	-	35	41	3	888	126
22	2	77	-	53	26	0	3850	49
23	2	55	-	38	16	3	2750	50
24	8	50	-	25	32	1	625	132
25	3	77	-	58	22	0	2567	38
26	1	59	-	37	18	5	5900	62
27	1	57	-	32	25	1	5700	81
28	4	75	-	29	48	2	1875	172
29	1	45	-	20	26	0	4500	130
30	0	63	-	25	38	0	-	152

b) pacientes hipertensos

Tabela 5.1: Avaliação dos dados de MAPA pelo método tradicional e pelo sistema

não são identificadas e fica a cargo do médico fazer essa análise posteriormente. Adotamos aqui o termo “método tradicional”, porque se trata da forma atual de geração de relatórios por sistemas que processam os dados gerados pela MAPA.

Nesta pesquisa, definimos o percentual de alarmes como sendo:

$$\%alarmes = ((alertas + emergencias)/normais) * 100$$

O sistema acusou um percentual de alarmes maior do que o da análise tradicional de MAPA somente nos 4 primeiros pacientes, os quais possuem valores baixos de pressão. Isso ocorre porque o método tradicional de relatórios de MAPA não identifica os valores baixos de pressão. Já a alta quantidade de alarmes no método tradicional ocorre porque este não considera a atividade sendo praticada nem a média do paciente, entre outros fatores.

A seguir, são feitos testes com o Módulo de Inferência em duas partes. A primeira parte (Subseção 5.1.1) estabelece diferentes cenários para refinar e avaliar o sistema de identificação de alarmes. A distribuição usada nesse teste para a geração de dados sintéticos é a uniforme, a qual permite que sejam forçadas variações nos dados sintéticos com limites bem definidos para os dados fisiológicos. Com isso, a implementação pode ser mais facilmente testada, pois, ao mesmo tempo em que induzimos o sistema a gerar novos resultados, devemos ter a preocupação de simular situações reais de variações de dados fisiológicos.

A segunda parte (Subseção 5.1.2) testa o Módulo com dados sintéticos gerados conforme a metodologia apresentada na Subseção 4.3.3, em que os dados mantêm as características dos dados originais de MAPA e seguem a distribuição normal.

### 5.1.1 Testes com Diferentes Cenários

Para criar diferentes cenários de testes, perturbaremos cada medida dos dados de MAPA, de modo que os dados sintéticos sejam originários dos dados originais de MAPA do paciente. Cabe ressaltar que alguns dos dados de MAPA já trazem algumas possíveis interferências, entre as quais há dois tipos mais comuns: por erro no momento da medida, causado por um movimento de braço, um aparelho descalibrado etc.; ou pelo “efeito do avental branco”, quando uma pressão arterial um pouco mais elevada é verificada na presença de um profissional de saúde.

Essas interferências foram encontradas por médicos que analisaram os 30 exames de MAPA que utilizamos. Em um sistema real, é oportuno que se solicite uma nova medida quando a interferência é detetada. O fato é que, quando geramos dados sintéticos por intermédio de perturbações nos dados de MAPA, estamos reproduzindo essas interferências. Portanto, ao aumentarmos drasticamente em nossos testes a quantidade de dados por geração sintética, teremos mais dados que contêm os efeitos da interferência.

Esta Subseção apresenta quatro cenários de testes, que consistem em tomar cada medição de MAPA e gerar 20 novos pontos usando números aleatórios segundo a distribuição uniforme. Com isso, após a geração dos dados sintéticos, um paciente com 80 medições na MAPA terá 1600 pontos ( $80 * 20$ ), formando assim uma série de dados. O desdobramento de cada medição de MAPA em 20 novos pontos foi definido com base em um monitoramento que realize medições frequentes de pressão e frequência cardíaca a cada 10min por um período de 11 dias ou a cada 1 hora em um período de 70 dias.

Os testes desta Subseção são identificados por cenários, que são o tipo de perturbação aplicada nos dados de MAPA para gerar os dados sintéticos. O resultado para cada cenário é a quantidade de casos identificados como normais, alertas ou emergências - os quais constituem o estado do paciente.

Esses cenários testam limites e permitem avaliar se o estado do paciente muda. São então provocadas situações de alarme e verifica-se o aumento do percentual de alarmes sobre os casos normais. Os testes para cada paciente são repetidos 20 vezes, formando 20 séries, cada uma com uma semente de geração de números aleatórios diferente. Após isso, usamos um intervalo de confiança (i.c.) de 95% nos resultados.

#### ***Teste I: Cenário 5-3-4***

Como dito, a geração dos dados com a componente aleatória segue uma distribuição uniforme. Neste teste, foi aplicada uma variação que simula um erro de precisão de 3%

id	normais	i.c.	alertas	i.c.	emerg.	i.c.	nº ex.	%alarmes
1	1211	7	363	6	5	1	1579	30
2	1085	3	510	4	23	1	1618	49
3	835	5	324	5	0	0	1159	39
4	917	4	188	4	14	1	1119	22
5	1193	4	286	4	20	0	1499	26
6	1325	4	216	5	18	1	1559	18
7	1165	8	394	8	20	0	1579	36
8	982	5	263	5	53	2	1298	32
9	1122	4	270	5	27	2	1419	26
10	1325	7	294	7	0	0	1619	22
11	1021	6	482	6	56	1	1559	53
12	814	4	367	4	38	1	1219	50
13	739	3	347	3	53	2	1139	54
14	677	7	462	7	0	0	1139	68
15	947	3	332	3	0	0	1279	35

id	normais	i.c.	alertas	i.c.	emerg.	i.c.	nº ex.	%alarmes
16	1144	6	323	7	32	2	1499	31
17	1290	7	309	7	0	0	1599	24
18	792	5	406	5	20	1	1218	54
19	1069	10	550	10	0	0	1619	51
20	851	4	460	5	68	2	1379	62
21	827	6	730	6	22	1	1579	91
22	1093	6	486	6	0	0	1579	44
23	711	4	395	4	33	1	1139	60
24	566	5	590	6	3	1	1159	105
25	1183	8	416	8	0	0	1599	35
26	781	6	395	5	22	1	1198	53
27	768	6	382	6	9	1	1159	51
28	797	6	772	6	10	2	1579	98
29	502	7	417	7	0	0	919	83
30	493	10	766	10	0	0	1259	155

Tabela 5.2: Cenário 5-3-4

de um aparelho de medição<sup>1</sup>. O intervalo dos números aleatórios para cada sinal vital é o seguinte:  $PAS = [-5, 5]$ mmHg;  $PAD = [-3, 3]$ mmHg;  $FC = [-4, 4]$ bpm. A convenção 5-3-4 reflete a variação (ou intervalo de variação) dos dados. Por exemplo, à PAS é sempre somado um valor gerado entre  $-5$  e  $5$ . Os valores do intervalo foram obtidos com o arredondamento para cima do resultado de 3% na PAS e na PAD e 5% na FC com base nos valores:  $PAS = 135$ mmHg,  $PAD = 85$ mmHg e  $FC = 80$ bpm (esses valores médios de pressão arterial são limites para um normotenso e a FC é um valor médio entre 60 e 99bpm).

A Tabela 5.2 mostra os resultados do Teste I<sup>2</sup>, para o qual é razoável admitir que os resultados sejam semelhantes aos produzidos somente com os dados de MAPA (Figura 5.1). Esse resultado pode ser constatado se analisarmos a função de distribuição acumulada apresentada na Figura 5.2. A Figura mostra a diferença, em módulo e em pontos percentuais, entre o sistema com MAPA e o cenário 5-3-4. Essa diferença é menor que 10, em 80% dos pacientes.

Para exemplificar, o paciente '10' teve 21% fornecido pelo sistema como percentual de alarmes com os dados de MAPA (Tabela 5.1) e 22% de alarmes com dados sintéticos (Tabela 5.2), isto é, um aumento de apenas 1 ponto percentual.

Esse comportamento é interessante para o modelo, pois demonstra que pequenas alterações não determinam mudanças bruscas no estado do paciente. Os casos em que a diferença é maior são pacientes hipertensos, que geraram menos alarmes para o cenário

<sup>1</sup>O percentual de 3% é 1% maior do que a precisão apresentada pelo aparelho de aferição da pressão arterial WristClinic [62] – a precisão do WristClinic é de 3mmHg ou 2% (o que for maior) para a pressão arterial, e de 5% para a frequência cardíaca, conforme a especificação do fabricante. Definimos uma margem de segurança de 1% para abranger equipamentos com uma precisão pior.

<sup>2</sup>Na Tabela 5.2, “no ex.” denota o número total de exemplares para cada paciente.




Figura 5.2: Função de distribuição acumulada para a diferença entre os resultados do sistema somente para os dados de MAPA e os resultados do sistema com dados sintéticos e distribuição uniforme no cenário 5-3-4

5-3-4 do que para a MAPA.

O perfil desses pacientes hipertensos, que tiveram uma redução no número de alarmes no cenário 5-3-4, possui, em sua maioria, uma média de pressão alta e um desvio padrão significativo. Assim, muitas medidas são geradas resultando em uma classificação que está no limite entre normal e alerta. Um caso típico é o paciente que possui uma média de pressão alta e, eventualmente, é gerada uma medida de pressão considerada baixa, mas que se encaixa na faixa de normalidade das pessoas em geral. No módulo de Inferência, isso pode ser explicado por contemplar regras genéricas (válidas para todos os pacientes), que atenuam o efeito de um alerta.

Vemos também que o número de emergências aumentou bastante. Isso ocorre, conforme explicado anteriormente, porque as distorções que já existem nos dados iniciais são reproduzidas nos dados sintéticos e em maior quantidade.

### ***Teste II: Cenário 20-15-20***

As variações estabelecidas neste teste podem ser consideradas quase normais em indivíduos. No entanto, o conceito que adotamos de “alertas” significa um meio termo entre normal e emergência, a fim de que os desvios sejam detetados. Com isso, esperamos um

id	normais	i.c.	alertas	i.c.	emerg.	i.c.	nº ex.	%alarmes
1	884	26	675	25	20	4	1579	79
2	921	25	645	21	53	6	1619	76
3	669	17	474	16	16	3	1159	73
4	698	21	394	22	26	2	1118	60
5	848	30	622	29	29	2	1499	77
6	965	28	571	28	22	3	1558	61
7	839	28	704	26	36	3	1579	88
8	770	22	477	22	51	3	1298	69
9	803	22	539	20	77	5	1419	77
10	1002	27	608	26	9	2	1619	62
11	815	21	658	19	86	5	1559	91
12	672	14	502	12	44	3	1218	81
13	622	14	442	13	75	3	1139	83
14	645	10	478	9	16	3	1139	77
15	780	17	488	17	11	2	1279	64

id	normais	i.c.	alertas	i.c.	emerg.	i.c.	nº ex.	%alarmes
16	893	33	559	30	46	4	1498	68
17	1002	31	585	31	11	2	1598	59
18	640	19	539	18	40	4	1219	90
19	930	30	684	30	4	2	1618	74
20	638	14	661	13	80	5	1379	116
21	740	21	774	22	65	6	1579	113
22	871	26	695	26	13	3	1579	81
23	577	18	492	15	70	5	1139	97
24	471	14	626	13	61	7	1158	146
25	854	33	743	33	1	1	1598	87
26	565	19	584	17	50	4	1199	112
27	557	16	574	16	27	3	1158	108
28	684	16	829	14	65	6	1578	131
29	369	12	534	12	16	3	919	149
30	378	22	857	20	24	5	1259	233

Tabela 5.3: Cenário 20-15-20

aumento nos casos de alertas.

Os dados sintéticos neste teste se diferenciam do teste anterior somente no intervalo do dado gerado para cada sinal vital: PAS=[-20, 20]mmHg; PAD=[-15,15]mmHg; FC=[-20,20]bpm. Os resultados são mostrados na Tabela 5.3. O número de alertas aumentou significativamente em relação ao teste anterior. Em 8 pacientes, o número de alarmes já ultrapassa o número de casos normais, mas todos eles são pacientes considerados hipertensos (tabela da direita). Esse resultado mostra que o conceito de alerta pode ser usado de duas maneiras: para identificar as medidas que necessitam ser analisadas e para o sistema atuar no ambiente, evitando que ocorra uma emergência, quando os resultados de alerta são altos, estando próximos ao valor máximo 0,7.

### **Teste III: Cenário +30-0-0**

Neste teste, o intervalo do dado gerado na PAS=[0, 30]mmHg<sup>3</sup>. Com isso, provocamos somente o aumento da pressão sistólica em relação aos dados de MAPA, de modo que a PAD e FC permanecem inalteradas. Este caso, denominado de pressão sistólica isolada, é bem típico em pacientes idosos, cuja PAS, isoladamente, aumenta com a idade.

Como esperado, o cenário +30-0-0 (Tabela 5.4) apresenta um aumento significativo nos casos de alertas e emergências em relação aos cenários anteriores - 18 pacientes tiveram aumento em relação ao cenário 20-15-20. Se analisarmos somente as emergências, todos os pacientes tiveram um aumento do cenário +30-0-0 em relação ao 20-15-20. Os pacientes que tiveram um número alto de emergências são aqueles que já possuem uma PAS alta. Nesses casos, as regras de emergência foram acionadas<sup>4</sup>.

<sup>3</sup>O sinal de '+' na frente do número (+30-0-0) significa que a variação vai de 0 até o número.

<sup>4</sup>Dois fatores são determinantes para as emergências nesse caso: os pesos maiores nas regras de emergência em relação às demais e as "regras de reforço", que valem somente para os pacientes hipertensos.

id	normais	i.c.	alertas	i.c.	emerg.	i.c.	nº ex.	%alarmes
1	1121	10	385	6	72	5	1578	41
2	1090	13	464	12	65	3	1619	49
3	771	13	351	11	36	3	1158	50
4	828	12	247	11	43	2	1118	35
5	821	27	594	23	84	5	1499	83
6	1144	11	368	10	47	2	1559	36
7	781	28	725	24	72	5	1578	102
8	839	9	382	9	78	2	1299	55
9	895	15	413	11	110	5	1418	58
10	964	18	637	17	18	2	1619	68
11	851	9	584	6	123	5	1558	83
12	676	10	483	8	59	2	1218	80
13	547	10	472	7	121	5	1140	108
14	516	7	592	6	31	3	1139	121
15	619	16	610	13	49	5	1278	106

id	normais	i.c.	alertas	i.c.	emerg.	i.c.	nº ex.	%alarmes
16	894	15	472	9	133	8	1499	68
17	929	23	588	19	81	6	1598	72
18	571	13	532	7	116	7	1219	113
19	656	24	898	23	65	8	1619	147
20	795	10	425	6	158	6	1378	73
21	551	9	878	5	150	10	1579	187
22	722	20	805	16	52	4	1579	119
23	435	19	563	13	140	7	1138	162
24	375	12	637	3	147	11	1159	209
25	685	28	901	28	13	2	1599	133
26	612	7	493	4	94	5	1199	96
27	558	14	513	9	88	6	1159	108
28	649	10	728	6	202	13	1579	143
29	382	8	464	3	72	6	918	140
30	345	10	783	6	131	11	1259	265

Tabela 5.4: Cenário +30-0-0

**Teste IV: Cenário +50+30+40**

Neste teste, provocamos o aumento de todos os sinais vitais em cima dos dados de MAPA:

PAS=[0,50]mmHg, PAD=[0,30]mmHg e FC=[0,40]bpm. Queremos simular situações emergenciais, com um aumento significativo da pressão em direção a níveis de emergência. A Tabela 5.5 mostra os resultados obtidos. Para compararmos os quatro cenários, apresentamos na Figura 5.3 o percentual de alarmes sobre os casos identificados como normais em cada cenário. Com isso, podemos observar quais são os cenários que levam o paciente a ter situações mais críticas. É bem notório que o cenário +50+30+40 gerou uma grande quantidade de alertas e emergências.

Nesse cenário, houve um grande aumento dos casos de emergência, mas também de alertas. Consequentemente, a quantidade de casos normais é baixa, principalmente com a elevação da média da pressão arterial nos pacientes. Comportando-se dessa forma, o sistema produz informações importantes para uma avaliação médica, já que uma análise realizada por períodos pode comparar a quantidade de alarmes e identificar comportamentos, conforme os cenários que foram propostos nos testes.

É oportuno ainda um comentário geral sobre as emergências em todos os testes realizados com o Módulo de Inferência. O número elevado de emergências, mesmo com poucas variações, ocorre em pacientes com picos de pressão e, nesse caso, trata-se de pacientes com pressão arterial média considerada normal. Quando o paciente não identifica que a atividade nos minutos precedentes envolveu um esforço físico, essa falta de informação contribui para que a situação seja identificada como um alerta ou emergência. Além de picos naturais de pressão, que incluem, principalmente, as situações de estresse, as quais

id	normais	i.c.	alertas	i.c.	emerg.	i.c.	nº ex.	%alarmes
1	693	27	620	23	266	18	1579	128
2	546	24	732	34	340	23	1618	196
3	409	18	490	15	260	16	1159	183
4	387	21	525	24	207	17	1119	189
5	411	34	826	32	261	20	1498	264
6	512	34	721	35	326	23	1559	204
7	396	32	899	30	284	17	1579	299
8	370	23	605	25	324	21	1299	251
9	406	24	658	19	354	15	1418	249
10	298	24	968	32	353	26	1619	443
11	426	23	762	22	371	17	1559	266
12	307	16	606	17	306	14	1219	297
13	280	16	520	15	339	16	1139	307
14	219	13	589	19	331	19	1139	420
15	217	16	708	24	354	24	1279	489

id	normais	i.c.	alertas	i.c.	emerg.	i.c.	nº ex.	%alarmes
16	277	25	761	30	460	28	1498	441
17	267	33	857	39	474	37	1598	499
18	185	13	659	17	374	19	1218	558
19	269	20	860	26	489	31	1618	501
20	272	19	758	22	349	14	1379	407
21	240	12	786	28	553	30	1579	558
22	135	17	1010	35	434	32	1579	1070
23	245	21	534	20	360	16	1139	365
24	186	11	549	13	424	19	1159	523
25	299	26	978	41	322	36	1599	435
26	137	14	726	24	336	20	1199	775
27	110	12	725	24	324	21	1159	954
28	255	17	800	28	524	25	1579	519
29	108	8	526	19	284	18	918	750
30	197	14	667	20	395	23	1259	539

Tabela 5.5: Cenário +50+30+40




Figura 5.3: Percentual de alarmes nos diferentes cenários usando distribuição uniforme



não são tratadas por este trabalho, esses picos podem ser também causados pelo efeito do avental branco ou pelos erros no momento da medição. Como mencionado, os dados sintéticos reproduzem 20 vezes cada medida encontrada na MAPA.

O Módulo de Inferência mostrou atender as estratégias que definimos inicialmente, pois as três diferentes classes de variáveis podem ser contempladas pelas regras. Cada regra envolve poucas variáveis e pode ser tanto uma regra genérica quanto uma regra que considera a média do paciente. Todas essas características permitem que o sistema se adapte a diferentes tipos de pacientes e possa ser ajustado futuramente para distintos tipos de doenças e novas informações de contexto. No entanto, a quantidade de alarmes gerados é considerada elevada, pois estamos tratando de um monitoramento de longa duração. O Módulo de Aprendizado resolve esse problema por aumentar o grau de individualização do mecanismo de decisão.

### 5.1.2 Testes com Dados Sintéticos que Mantêm Características dos Dados Originais

Seguindo os testes com o Módulo de Inferência, nesta Subseção usaremos dados sintéticos gerados com distribuição normal e com a metodologia apresentada na Subseção 4.3.3. A primeira análise é feita pelo Módulo de Inferência (Tabela 5.6). O percentual de alarmes é uma métrica interessante para verificar se os dados de distribuição normal mantêm o mesmo percentual de quando usamos somente os dados de MAPA. Para complementar essa análise, a Figura 5.4 mostra a diferença do percentual de alarmes, em módulo, entre os resultados apresentados na Tabela 5.6 e os resultados da Tabela 5.1 (produzidos pelo sistema). O resultado mostra que em 80% dos pacientes temos uma pequena diferença, de até 15 pontos percentuais.

Para validar a hipótese de que os dados sintéticos refletem o comportamento dos dados originais, selecionamos três pacientes (Tabela 5.7). Decidimos selecionar esses casos por representarem diferentes níveis de PA: hipotenso<sup>5</sup>, normotenso e hipertenso de grau I. Em seguida, realizamos testes estatísticos.

A correlação entre PAS e PAD foi calculada tanto para os dados de MAPA quanto

---

<sup>5</sup>Nos referimos como hipotensos aos pacientes normotensos com média de pressão arterial menor do que 110/70mmHg. No entanto, não foi utilizada nenhuma informação de sintoma associado que configure episódios de hipotensão.

id	normais	i.c.	alertas	i.c.	emerg.	i.c.	nº ex.	%alarmes
1	1237	7	319	7	4	1	1560	26
2	1082	6	517	7	14	2	1613	49
3	890	7	248	6	9	1	1147	29
4	922	6	188	6	3	2	1113	21
5	1166	7	320	7	3	1	1489	28
6	1337	4	208	4	5	1	1550	16
7	1109	9	451	9	15	2	1575	42
8	917	6	356	5	18	2	1291	41
9	1008	7	349	7	43	3	1400	39
10	1242	8	366	7	0	1	1608	29
11	1018	10	424	8	81	4	1523	50
12	869	9	319	8	25	2	1213	40
13	710	8	359	7	62	3	1131	59
14	820	7	304	7	3	1	1127	37
15	948	9	317	8	3	1	1268	34

id	normais	i.c.	alertas	i.c.	emerg.	i.c.	nº ex.	%alarmes
16	1050	9	433	9	8	1	1491	42
17	1155	8	437	8	0	1	1592	38
18	721	10	431	9	19	2	1171	62
19	1081	7	527	7	1	1	1609	49
20	749	8	576	8	44	3	1369	83
21	879	7	668	7	28	2	1575	79
22	1063	7	510	7	0	1	1573	48
23	740	7	338	5	45	2	1123	52
24	662	8	446	8	32	3	1140	72
25	1197	8	394	8	0	0	1591	33
26	730	9	427	8	22	3	1179	62
27	686	9	455	9	14	2	1155	68
28	833	9	692	8	34	3	1559	87
29	481	6	427	5	5	1	913	90
30	596	6	639	5	10	1	1245	109

Tabela 5.6: Resultados do sistema com dados sintéticos de distribuição normal




Figura 5.4: Diferença em pontos percentuais de alarmes entre o sistema com dados sintéticos de distribuição normal e o sistema com dados de MAPA

Tabela 5.7: Pacientes e suas médias de pressão arterial em mmHg

Paciente	Classificação	Geral PAS/PAD	Vigília PAS/PAD	Sono PAS/PAD
2	hipotenso	107/69	109/71	85/48
14	normotenso	138/81	139/82	130/76
28	hipertenso	156/95	160/97	144/87

para as 20 séries de dados sintéticos (nesse último caso, um i.c. de 95% foi calculado). Os resultados mostrados na Tabela 5.8 permitem afirmar que os dados sintéticos praticamente preservam a correlação dos dados de MAPA nas variáveis PAS e PAD. Quanto à correlação de PAS-PAD nos dados de MAPA incluindo todos os pacientes, obtivemos como menor correlação 25,61%, e, como maior, 92,79%. Isso demonstra que os pacientes possuem algum grau de correlação e que o aprendizado com base em dados que a preservem pode obter melhores resultados, por serem dados mais realísticos.

Tabela 5.8: Correlação entre PAS e PAD nos dados de MAPA e nos dados sintéticos

Paciente	Corr. PAS-PAD MAPA	Corr. PAS-PAD sintéticos	i.c.
2	85,66	85,41	0,001
14	61,75	60,64	0,004
28	81,02	75,92	0,006

A análise multivariada de variância (MANOVA: *multivariate analysis of variance*) foi utilizada para comparar as diferenças de médias para as 3 variáveis dependentes (PAS, PAD e FC), com base no tipo de dado: originais ou sintéticos. A hipótese nula é que os grupos de cada variável têm a mesma média. Separamos os dados das atividades de repouso e dormindo para os 3 pacientes pré-selecionados. A limitação a essas duas atividades se deve a, em alguns exames de MAPA, somente essas atividades serem anotadas pelos pacientes. Os resultados da Tabela 5.9 mostram que os valores de  $p$ -valor são maiores do que 0,05 (nível de significância adotado), portanto não podemos rejeitar  $H_0$ . Logo, sendo as médias dos grupos significativamente similares, concluímos que podemos utilizar os dados sintéticos gerados por nosso mecanismo como um prolongamento realístico dos dados de MAPA.

Tabela 5.9: Comparativo entre os dados de MAPA e os dados sintéticos usando MANOVA

Paciente	<i>p</i> -valor para dormindo	<i>p</i> -valor para repouso
2	0,9033	0,9816
14	0,9328	0,95
28	0,6847	0,9356

## 5.2 Avaliação do Módulo de Aprendizado

O Módulo de Aprendizado, descrito por meio das fases apresentadas na Subseção 4.3.4, inicia após a seleção do subintervalo dos alertas, que define o valor mais alto do estado do paciente para ser considerado um alerta leve (variável *maxAlertaLeve*). Em nosso caso, usamos: *maxAlertaLeve* = 0,65, isto é, praticamente todo o intervalo de alertas (0,4..0,7). A decisão desse valor fica a cargo do médico. A segunda fase é encontrar um ponto representativo. Para isso, usamos dados sintéticos validados na Subseção 5.1.2. Esses dados são agregados aos dados de MAPA. Em seguida, cada uma das três técnicas testadas nesta Subseção encontrará pontos representativos para as variáveis PAS e PAD. As técnicas separam o conjunto de dados por atividade e trabalham somente com os casos em que o estado do paciente é (0,4..0,65).

Os testes com o Módulo de Aprendizado têm por objetivo validar o mecanismo de ajuste de regras. Como resultado, queremos definir uma melhor técnica entre as estudadas: MDP, FCM ou GK. A implementação da técnica MDP foi realizada usando código em C#; a implementação da técnica FCM foi feita no Matlab; já o algoritmo de GK foi implementado adaptando o código apresentado em [6].

A Tabela 5.10 apresenta os resultados do aprendizado para os 3 pacientes selecionados. Apresentamos somente os valores nas atividades dormindo e repouso. Em cada atividade, existem os valores propostos acima e abaixo da média do paciente, em cada uma das três técnicas. Temos então que observar os valores apresentados na Tabela 5.7, em relação à média geral desses pacientes: '2':107/69; '14':138/81; '28':156/95.

Na primeira linha da tabela (com PAS/PAD=23/22mmHg), a técnica de MDP propõe que, em uma regra de dormindo, o que é considerado normal passe a contemplar o valor de  $PAS = 84$  ( $107 - 23$ ) e  $PAD = 47$  ( $69 - 22$ ). Esse é um caso de um paciente cuja PA é muito baixa quando ele está dormindo. No caso da PAS, o ajuste é feito na variável 'desvioPASdormindo' (variável apresentada na Figura 4.2), que possui como núcleo do termo 'normal'  $-10$  e  $0$ . Esses parâmetros tornar-se-ão  $-23$  e  $0$  (*pontoRepresentativo* - *mediaDoPaciente*,  $84 - 107$ ). Além disso, são feitos os outros ajustes já explicados na

## Subseção 4.3.4.3.

Tabela 5.10: Ajustes propostos acima e abaixo da média PAS/PAD pelas 3 técnicas nos 3 pacientes

id	técnica	dormindo				repouso			
		acima		abaixo		acima		abaixo	
		PAS	PAD	PAS	PAD	PAS	PAD	PAS	PAD
2	MDP	-	-	23±0,21	22±0,20	17±0,46	19±0,31	15±0,19	13±0,27
	FCM	-	-	23	22±0,17	20±0,40	22±0,25	16±0,23	14±0,27
	GK	-	-	23	22±0,17	20±0,54	22±0,26	16±0,23	14±0,30
14	MDP	4±0,30	9±0,34	-	-	11±0,22	11±0,17	-	-
	FCM	-	-	-	-	16±0,82	15±0,44	-	-
	GK	6±0,61	-	-	-	16±0,52	11±0,33	-	-
28	MDP	9±0,30	6±0,27	20±0,52	15±0,36	12±0,21	8±0,13	7±0,35	-
	FCM	11±0,32	8±0,43	28±0,45	17±0,27	19±0,30	9±0,33	-	-
	GK	10±0,38	9±0,42	26±0,55	17±0,28	18±0,36	6±0,22	-	-

Os resultados em branco podem ser ocasionados por dois motivos. Ou pela falta de dados suficientes para ocorrer o aprendizado ou por a proposta não contribuir com o ajuste. Um exemplo do primeiro caso é o paciente '2', na situação de 'dormindo e acima', o qual apresenta poucos alertas quando está dormindo e com pressão alta, o que pode ser verificado pela baixa média de pressão durante o sono (85/48mmHg). Definimos então um mínimo de 20 casos para habilitar o aprendizado em cada situação. Outro caso para a inexistência de um ajuste é quando o valor proposto não contribui para modificar as variáveis das regras. Por exemplo, se for proposto um ajuste de 4mmHg para a variável de desvio de PAS no repouso, tal ajuste não será válido, porque a variável já possui como padrão para o caso normal  $[-5,5]$ . Portanto, para validar cada proposta de ajuste, é realizada uma verificação nos valores padrões de cada variável envolvida. Na prática, o que ocorre é o MDP resultar em valores em branco por causa da falta de dados, e as técnicas de agrupamento podendo ter como causa ou a falta de dados ou a não contribuição com o ajuste. Isso se deve ao fato de que o MDP, por tratar isoladamente PAS e PAD, separa totalmente os valores acima e abaixo da média e, assim, o resultado não sai do limite de cada grupo.

Os valores de ajuste da Tabela 5.10 apresentam valores muito próximos entre as 3 técnicas. Por isso, concentramo-nos em diferenças entre as técnicas que podem determinar uma melhor proposta de ajuste. Aproveitaremos também para ressaltar a correlação entre PAS e PAD.




Figura 5.5: Pontos centrais para o FCM no paciente '28' na atividade de dormindo. A média do paciente é 156/94 e os resultados obtidos foram: 168/102 e 130/77

A primeira diferença pode ser constatada entre o MDP e as técnicas de agrupamento. Um exemplo que pode ser visto na Tabela 5.10 está nos métodos FCM e GK para o paciente '28' na situação de repouso e abaixo da média, o que implicou não existirem propostas de ajustes.

As Figuras 5.5 e 5.6 apresentam os resultados da técnica FCM nas atividades de dormindo e repouso<sup>6</sup>. O círculo identifica a posição do ponto central/representativo. Na atividade de dormindo, os alertas estão bem divididos e o ponto representativo 130/77 reflete bem o maior distanciamento em relação à média do paciente nesta atividade. No entanto, na atividade de repouso, as técnicas de agrupamento não conseguem definir um valor baixo para a PAD. O valor 90 é muito próximo à média 94, o que sugere manter inalterado o valor. Já o MDP, como considera todos os valores que estão abaixo da média de PAS (94), mesmo os que ocorrem em conjunto com valores altos de PAS no 4º quadrante (todos esses pontos estão na área retangular), obtém um ajuste de 12, o que resulta no valor 82 ( $94 - 12$ ) para o ponto representativo da PAD abaixo da média.

Um segundo tipo de diferença pode ser observado entre os métodos de agrupamento. Tomemos os dados de outro paciente, o '24' (Figura 5.7). Nesse caso, vemos que o GK não atribuiu grande relevância ao conjunto disperso com valores baixos de PAS e de

<sup>6</sup>A partir desse teste, são usadas séries de dados sintéticos específicas, das 20 séries geradas.




Figura 5.6: Pontos centrais para o FCM no paciente '28' em repouso. A média do paciente é 156/94 e os resultados obtidos foram: 173/105 e 145/90. A área retangular mostra que, na técnica MDP, outros pontos seriam considerados para o cálculo de uma PAD abaixo da média

PAD (3º quadrante), não apresentando um ponto representativo para ajuste abaixo da média. Apesar de não propor um dos ajustes, isso pode ser entendido como um fator de estabilidade, pois não serão propostas mudanças com base em dados que pouco ocorrem. A correlação PAS-PAD dos dados sintéticos é de 86% e entre os pontos somente de alertas é de 69%.

Ao contrário do GK, o FCM cria pontos centrais em agrupamentos com poucos elementos a sua volta, o que também ocorreu no caso do paciente '23' (Figura 5.8), pois podemos notar uma alta correlação PAS-PAD de 93% nos dados sintéticos e, entre os pontos de alertas, 83%. No entanto, dependendo da série de dados (das 20 que testamos), o FCM pode gerar 2 pontos centrais para somente uma direção; no caso, para abaixo da média. Para resolver isso, definimos que, se existir pelo menos uma proposta de ajuste em qualquer série de dados que não gere um ponto em uma direção, então a proposta de ajuste é considerada inválida naquela direção.

Em outro paciente, '11' (Figura 5.9), vemos que o GK não atribuiu grande relevância ao conjunto disperso com valores baixos de PAS e PAD (3º quadrante). Esse paciente tem uma baixa correlação PAS-PAD nos dados sintéticos 34%, e de 18% entre os pontos




Figura 5.7: Pontos centrais do paciente '24' em repouso. A média do paciente é 142/99 e os resultados obtidos no FCM foram: 156/113 e 126/80, e no GK: 159/111 e 144/107




Figura 5.8: Pontos centrais do paciente '23' dormindo. A média do paciente é 139/101 e os resultados obtidos no FCM foram: 145/106 e 124/81, e no GK: 128/82 e 124/82






Figura 5.9: Pontos centrais do paciente '11' em repouso. A média do paciente é 135/73 e os resultados obtidos foram no FCM: 155/81 e 121/70, e no GK: 151/87 e 139/62

de alertas. Com isso, os pontos estão mais espalhados, tornando a definição do ponto representativo mais complexa.

Em uma terceira situação de diferença, percebemos que, mesmo considerando somente uma técnica de agrupamento, os resultados podem ser bem diferentes envolvendo séries diferentes de dados. As Figuras 5.10 e 5.11 mostram essa diferença. Enquanto na primeira série os dois pontos centrais estão bem distanciados, na segunda eles estão bem próximos, o que determina, nesse último caso, uma escolha de apenas uma PAS e uma PAD. Ambas as séries têm correlação maior que 80%.

Após a análise das diferenças, um último teste compara os resultados antes e depois do aprendizado, usando os dados sintéticos. Antes do aprendizado, temos um sistema de inferência *fuzzy* (uma configuração) para 20 séries de dados como entrada. Já na forma após o Aprendizado, o Módulo de Aprendizado gerou 20 configurações diferentes para o Módulo de Inferência. Com isso, cada uma dessas configurações é executada para as 20 séries de dados. O número de alertas é contabilizado no intervalo do estado do paciente (0,4..0,55] nas atividades de dormindo e repouso. O valor 0,55 representa o ponto médio do intervalo de alertas e, por isso, pode representar o conceito de alerta leve no sistema. Os valores são apresentados nas Tabelas 5.11 e 5.12.




Figura 5.10: Pontos centrais para o GK do paciente '23' em repouso usando uma 1ª série de dados. A média do paciente é 139/101 e os resultados obtidos foram: 153/116 e 122/85




Figura 5.11: Pontos centrais para o GK do paciente '23' em repouso usando uma 2ª série de dados. A média do paciente é 139/101 e os resultados obtidos foram: 156/115 e 146/112

id	Antes do aprendizado		Após o aprendizado					
	nº alertas	i.c.	MDP		FCM		GK	
			nº alertas	i.c.	nº alertas	i.c.	nº alertas	i.c.
1	335,30	6,09	64,81	1,61	54,87	1,37	49,72	0,99
2	502,00	7,02	64,24	1,96	51,39	0,79	51,73	1,08
3	244,45	4,83	61,96	1,41	47,08	1,23	47,60	1,13
4	179,80	4,75	42,83	0,69	36,89	0,61	37,20	1,16
5	330,20	5,93	89,74	2,64	59,04	1,68	59,23	1,86
6	233,60	4,32	55,62	1,18	45,92	0,87	46,08	0,89
7	466,45	7,43	179,76	3,85	135,36	2,63	136,84	2,72
8	347,65	5,86	126,51	2,53	95,33	1,42	95,96	1,58
9	343,15	6,68	149,63	2,20	133,06	2,78	129,45	4,62
10	363,30	6,64	122,73	3,22	78,70	3,79	106,79	12,40
11	385,85	6,94	181,56	1,23	169,35	2,72	167,15	5,68
12	315,90	8,56	143,85	1,83	115,23	2,45	120,92	2,62
13	333,75	6,45	177,65	1,85	131,56	2,67	139,16	3,34
14	307,25	6,53	170,94	2,00	121,96	10,32	172,33	5,59
15	289,60	7,01	152,60	2,36	127,96	4,11	160,06	7,52

Tabela 5.11: Comparação antes e após o Aprendizado para os dados sintéticos nos pacientes normotensos

id	Antes do aprendizado		Após o aprendizado					
	nº alertas	i.c.	MDP		FCM		GK	
			nº alertas	i.c.	nº alertas	i.c.	nº alertas	i.c.
16	438,85	7,04	280,01	1,61	151,78	6,74	174,30	34,34
17	440,35	7,30	226,78	1,77	104,28	12,56	144,21	21,38
18	416,35	7,90	235,31	2,91	234,73	7,45	256,09	4,52
19	539,70	6,69	320,96	3,49	147,53	13,40	256,54	30,76
20	587,60	8,60	225,88	2,32	196,28	3,69	194,16	3,28
21	659,35	6,21	419,82	7,92	341,84	8,17	359,98	9,72
22	499,15	7,25	279,71	4,44	260,79	10,54	306,11	9,20
23	345,40	5,34	205,94	4,14	83,85	4,48	166,50	14,95
24	418,25	6,83	247,07	3,88	119,17	3,93	249,18	9,25
25	350,40	7,02	171,77	2,72	113,60	3,28	120,96	4,11
26	340,80	6,54	180,91	2,50	144,67	1,06	145,62	1,12
27	438,40	7,39	246,47	2,77	190,62	4,87	231,22	7,87
28	669,75	6,53	359,39	3,88	272,15	7,95	372,01	6,96
29	424,40	4,80	238,46	3,30	139,31	3,37	160,03	10,44
30	644,95	5,84	322,44	3,84	254,17	5,29	287,21	5,68

Tabela 5.12: Comparação antes e após o Aprendizado para os dados sintéticos nos pacientes hipertensos

id	Antes do aprendizado			Após o aprendizado													
	nº alertas			MDP						FCM				GK			
	[0,4-0,55]	>0,55		[0,4-0,55]	i.c.	>0,55	i.c.	[0,4-0,55]	i.c.	>0,55	i.c.	[0,4-0,55]	i.c.	>0,55	i.c.		
1	17	1	0,9	0,63	0,3	0,2	0,55	0,38	0,3	0,2	0,45	0,32	0,3	0,2			
2	23	2	0,45	0,35	0,6	0,4	0,3	0,2	0,6	0,4	0,3	0,2	0,6	0,4			
3	15	1	1,2	0,8	0	0	0,85	0,58	0	0	0,85	0,58	0	0			
4	7	3	0,3	0,2	0,9	0,6	0,3	0,2	0,9	0,6	0,3	0,2	0,9	0,6			
5	14	3	1,1	0,75	0,6	0,4	0,35	0,25	0,6	0,4	0,35	0,25	0,6	0,4			
6	10	3	0,9	0,6	0,6	0,4	0,65	0,44	0,6	0,4	0,65	0,44	0,6	0,4			
7	17	4	2,4	1,61	1,2	0,8	2	1,36	1,2	0,8	2	1,36	1,2	0,8			
8	11	4	0,85	0,58	1,2	0,8	0,8	0,55	1,2	0,8	0,85	0,58	1,2	0,8			
9	7	8	0,4	0,29	2,4	1,61	0,4	0,32	2,4	1,61	0,4	0,32	2,4	1,61			
10	13	0	1,25	0,84	0	0	1,2	0,8	0	0	1,35	0,94	0	0			
11	16	10	2,65	1,78	2,7	1,81	2,45	1,64	2,7	1,81	2,7	1,81	2,7	1,81			
12	16	4	2,2	1,48	0,9	0,6	1,3	0,88	0,9	0,6	1,3	0,88	0,9	0,6			
13	11	8	1,8	1,23	2,4	1,61	0,9	0,6	1,8	1,21	0,95	0,64	1,8	1,21			
14	21	2	2,1	1,41	0,3	0,2	1,6	1,14	0,3	0,2	1,85	1,29	0,3	0,2			
15	15	1	1,8	1,21	0,3	0,2	1,9	1,32	0,3	0,2	2,1	1,42	0,3	0,2			

Tabela 5.13: Comparação antes e após o Aprendizado para os dados de MAPA nos pacientes normotensos

Vemos que as três técnicas reduzem substancialmente o número de alertas. Na maior parte dos casos, o MDP reduz pela metade a quantidade de alertas em relação a antes do aprendizado. Já as técnicas de agrupamento, nos pacientes normotensos, reduzem pela metade os casos de alertas em relação ao MDP. Nos pacientes hipertensos, uma redução também é detetada, mas não tão significativa quanto a anterior. Nesses mesmos pacientes, na maior parte dos casos, o FCM reduz mais do que o GK. No entanto, essa grande redução de alertas em pacientes hipertensos não é recomendada, por a situação já ser crítica.

Um último teste nesta Subseção é realizado para verificar o comportamento e o efeito do Módulo de Aprendizado, usando dados reais de MAPA. As Tabelas 5.13 e 5.14 mostram, respectivamente, a comparação antes e depois do aprendizado. Antes do aprendizado, temos um sistema de inferência *fuzzy* (uma configuração) para uma entrada com os dados de MAPA. Já na forma após o Aprendizado, temos as 20 configurações diferentes para o Módulo de Inferência, e cada uma dessas configurações é executada para os dados de MAPA. O número de alertas é contabilizado no intervalo do estado do paciente (0,4..0,55] e alarmes  $> 0,55$  nas atividades de dormindo e repouso. Tabelas 5.13 e 5.14.

Os resultados mostram que as três técnicas reduzem, em média, os alertas de até 0,55 a, no máximo, 3 casos para os normotensos (colunas em destaque da Tabela 5.13). Já nos hipertensos, a redução chega a 5 alertas (colunas em destaque da Tabela 5.14). Os alertas com o *estado*  $> 0,55$  não ultrapassam 3 casos por paciente. Mesmo com o número de alertas muito próximo entre as técnicas, a FCM foi a técnica mais tolerante, seguida da GK e, finalmente, da MDP, a mais rígida. A FCM, usando a distância Euclidiana no cálculo do ponto representativo, consegue posicionar, na maior parte das situações, dois pontos em dois quadrantes. Já na GK, usando a distância de Mahalanobis, quando há

id	Antes do aprendizado		Após o aprendizado											
	nº alertas		MDP				FCM				GK			
	[0,4-0,55]	>0,55	[0,4-0,55]	i.c.	>0,55	i.c.	[0,4-0,55]	i.c.	>0,55	i.c.	[0,4-0,55]	i.c.	>0,55	i.c.
16	14	4	3,3	2,21	1,2	0,8	1,1	0,76	0,9	0,6	1,65	1,42	0,95	0,64
17	17	2	3,85	2,58	0,6	0,4	2,25	1,51	0,3	0,2	2,95	2	0,35	0,25
18	21	3	4,2	2,81	0,65	0,44	4,5	3,02	0,6	0,4	4,95	3,32	0,6	0,4
19	35	1	5,7	3,82	0,3	0,2	2,15	1,67	0,3	0,2	3,55	2,61	0,3	0,2
20	21	9	2	1,34	2,4	1,61	2,4	1,62	2,1	1,41	2,35	1,59	2,1	1,41
21	41	4	7,6	5,13	0,9	0,6	5,5	3,74	0,9	0,6	6	4,05	0,9	0,6
22	24	2	3,35	2,25	0,6	0,4	3,15	2,15	0,6	0,4	3,8	2,57	0,6	0,4
23	11	9	1,95	1,34	2,4	1,61	0,6	0,4	1,85	1,24	2	1,5	2,05	1,38
24	27	10	3,85	2,58	2,6	1,75	2,85	1,91	0,9	0,6	4,35	2,93	1,8	1,21
25	20	0	2,5	1,68	0	0	1,5	1	0	0	1,5	1	0	0
26	15	5	2,35	1,58	1,5	1	2,1	1,41	1,2	0,8	2,1	1,41	1,2	0,8
27	23	4	3,2	2,15	0,9	0,6	2,7	1,81	0,9	0,6	3,25	2,21	1	0,68
28	42	7	5,55	3,72	2,1	1,41	3,2	2,15	1,9	1,28	5,7	3,82	1,95	1,31
29	23	3	3,3	2,22	0,9	0,6	1,2	0,8	0,9	0,6	1,65	1,21	0,9	0,6
30	33	3	4,85	3,25	0,9	0,6	3,45	2,31	0,9	0,6	4,2	2,81	0,9	0,6

Tabela 5.14: Comparação antes e após o Aprendizado para os dados de MAPA nos pacientes hipertensos

uma grande concentração de pontos em um quadrante, os pontos representativos tendem a ficar no mesmo quadrante. Com isso, A FCM propõe um valor acima e abaixo da média, o que possibilita abranger mais casos de alertas para tornarem-se normais. A MDP, apesar de geralmente propor valores acima e abaixo da média, possui o problema de tratar em separado a PAS e a PAD. Essa forma de tratamento faz com que o ponto representativo não seja resultado de pontos PAS-PAD que ocorreram em conjunto (conforme identificado na Figura 5.5).

## 5.3 Avaliação Médica

Para uma avaliação final do mecanismo de Decisão, dois médicos realizaram uma classificação dos dados originais de MAPA dos 30 pacientes. Os médicos (aqui denominados médico A e médico B) classificaram cada medida em normal, alerta ou emergência. Cabe ressaltar que o médico B teve o acompanhamento de mais um terceiro médico, mas a avaliação foi reunida em uma só. As avaliações médicas pressupuseram que as medidas de MAPA foram obtidas em momentos diferentes do dia. Para efeito de análise, isso quer dizer que a coleta de cada medida não obedece a um intervalo de tempo fixo entre as medidas.

Após a avaliação médica, o sistema realizou execuções nas seguintes situações: a) antes do uso do aprendizado; b) após o uso do aprendizado. A execução antes do uso do aprendizado compreende o conjunto de regras iniciais. Nessa situação, espera-se uma maior intolerância às variações de dados fisiológicos do paciente. Após o aprendizado, teremos as respostas das 3 técnicas propostas e uma expectativa de tolerância maior às variações.

O resultado esperado para o sistema é a identificação correta de casos normais (classe 'N'), alertas (classe 'A') e emergências (classe 'E'). Um fator crítico é o médico identificar uma emergência e o sistema identificar como normal, o que caracteriza um falso negativo. Por sua vez, o sistema identificar uma emergência não detetada pelo médico tende a ser menos prejudicial, mas caracteriza um falso positivo. Nesse caso, o sistema poderia solicitar uma nova medição para confirmar o resultado e só então tomar uma decisão quanto à emergência.

As Tabelas 5.15, 5.16, 5.17 e 5.18 apresentam as matrizes de confusão contendo as avaliações médicas (nas linhas) e os resultados do sistema (nas colunas). Por simplificação, nas tabelas “após o aprendizado” foram colocados os resultados do sistema somente para a técnica de FCM, já que os resultados obtidos são parecidos com as técnicas GK e MDP e podem ser explicados posteriormente. Para melhor entendimento, na Tabela 5.15 podemos ver que o médico A identificou 10 casos de emergência e o sistema classificou 1 deles como alerta. Já o médico B (Tabelas 5.17 e 5.18) não identificou casos de emergência.

Tabela 5.15: Matriz de Confusão - médico A, antes do aprendizado

<b>Avaliação Médica</b>	<b>Sistema</b>		
	<b>N</b>	<b>A</b>	<b>E</b>
<b>N</b>	1267	530	6
<b>A</b>	1	58	30
<b>E</b>	0	1	9

Tabela 5.16: Matriz de Confusão - médico A, após o aprendizado com FCM

<b>Avaliação Médica</b>	<b>Sistema</b>		
	<b>N</b>	<b>A</b>	<b>E</b>
<b>N</b>	1648	149	6
<b>A</b>	2	52	35
<b>E</b>	0	0	10

Tabela 5.17: Matriz de Confusão - médico B, antes do aprendizado

<b>Avaliação Médica</b>	<b>Sistema</b>		
	<b>N</b>	<b>A</b>	<b>E</b>
<b>N</b>	1268	560	17
<b>A</b>	0	29	28
<b>E</b>	0	0	0

Em todos os cenários, não estão presentes casos de falso negativo (emergências que o sistema classificou como normais). Esse é um ponto de extrema importância para o sistema, pois é um dos fatores para a sua confiabilidade.

Tabela 5.18: Matriz de Confusão - médico B, após o aprendizado com FCM

Avaliação	Sistema		
	N	A	E
Médica			
N	1647	175	23
A	3	26	28
E	0	0	0

A acurácia foi usada para comparar os resultados antes e após o aprendizado, sendo definida como a soma dos casos corretamente classificados (isto é, a soma da diagonal principal da matriz de confusão) dividida pelo número total de casos. Na situação antes do aprendizado, a acurácia do sistema é de 70% para o médico A e 68% para o médico B.

Para resolver isso, é então aplicado o aprendizado, usando as técnicas MDP, FCM e GK. O resultado alcançado no médico A foi de 90% de acurácia na técnica FCM, 88% na GK e 86% na MDP. Os resultados para o médico B são, exatamente, 2 pontos percentuais a menos do que os valores apresentados para o médico A. Se fizermos um teste selecionando somente os casos em que houve consenso entre os médicos na avaliação, obtemos uma acurácia de 91%.

Vemos então que uma acurácia de 70% foi melhorada para 90%. Uma consequência direta é a redução de alertas desnecessários, permitindo que o médico se detenha nos casos realmente importantes, a fim de tentar descobrir os motivos das variações. Os alertas estão associados à quantidade de falsos positivos (casos normais que o sistema classificou como alertas ou até mesmo emergências). Podemos comparar os resultados do sistema após o aprendizado (Tabelas 5.16 e 5.18) com o método tradicional de identificação de alarmes para o exame de MAPA (Tabela 5.1). O método tradicional que envolve todas as atividades sendo praticadas possui 2065 medidas e 1398 alertas (68% de alarmes), enquanto pelo sistema, após o aprendizado, temos um percentual de alarmes de 13%. Cabe ressaltar que, no médico A, os alarmes são de 5% e, no médico B, 3%. A proposta do sistema é direcionar a avaliação médica para os casos que apresentem desvios significativos de pressão. Assim, a solução torna-se adequada para o monitoramento de longa duração.

O número de emergências após o aprendizado se manteve igual ao número de casos antes do aprendizado. Assim, mesmo com o ajuste nos casos de alertas, o sistema cumpriu com sua proposta de manter a rigidez para os casos de emergências e, ao mesmo tempo, tolerar variações consideradas leves para o paciente do ponto de vista médico.

Após o aprendizado, podemos ver que existem ainda 2 casos (Tabela 5.16) e 3 casos (Tabela 5.18) considerados como alertas pelos médicos e classificados como normais pelo

sistema. Desses casos, existe somente 1 caso em que os dois médicos concordaram que se trata de um alerta. Esse caso é de uma PAD baixa em que o paciente informou que estava dormindo. Devido à atividade, o sistema classificou a situação no limite entre normal e alerta, 0,39. Como é a primeira medida que inicia o período de sono informado pelo paciente, pode ser que ainda ele não estivesse dormindo, o que resultaria um alerta pelo sistema. Os outros casos classificados como normais também se enquadram nessa possibilidade de uma entrada informada de forma incorreta pelo paciente.

A técnica de FCM obteve os melhores resultados, pois o número de casos detetados como alertas (e considerados normais pelos médicos) é menor do que a GK e a MDP (Tabelas 5.19, 5.20, 5.21 e 5.22). No ajuste do núcleo dos conjuntos normais em cada variável ajustada, a FCM faz um ajuste maior do que o realizado pelas demais técnicas. A razão para isso é que a FCM consegue um maior distanciamento entre os pontos propostos de ajuste, ao mesmo tempo em que acompanha a correlação entre PAS e PAD. O resultado intermediário da técnica GK demonstra que o acompanhamento da correlação também é mais efetivo do que simplesmente tomar a média dos pontos, como faz a MDP.

Tabela 5.19: Matriz de Confusão - médico A, após o aprendizado com GK, 88% de acurácia

Avaliação Médica	Sistema		
	N	A	E
N	1615	183	5
A	3	51	35
E	0	0	10

Tabela 5.20: Matriz de Confusão - médico B, após o aprendizado com GK, 86% de acurácia

Avaliação Médica	Sistema		
	N	A	E
N	1614	209	22
A	4	25	28
E	0	0	0

Tabela 5.21: Matriz de Confusão - médico A, após o aprendizado com MDP, 85% de acurácia

Avaliação Médica	Sistema		
	N	A	E
N	1551	246	6
A	2	50	35
E	0	0	10

Uma avaliação complementar é verificar o desempenho de cada técnica, considerando



Tabela 5.22: Matriz de Confusão - médico B, após o aprendizado com MDP, 83% de acurácia

Avaliação	Sistema		
	N	A	E
N	1553	268	24
A	0	28	28
E	0	0	0

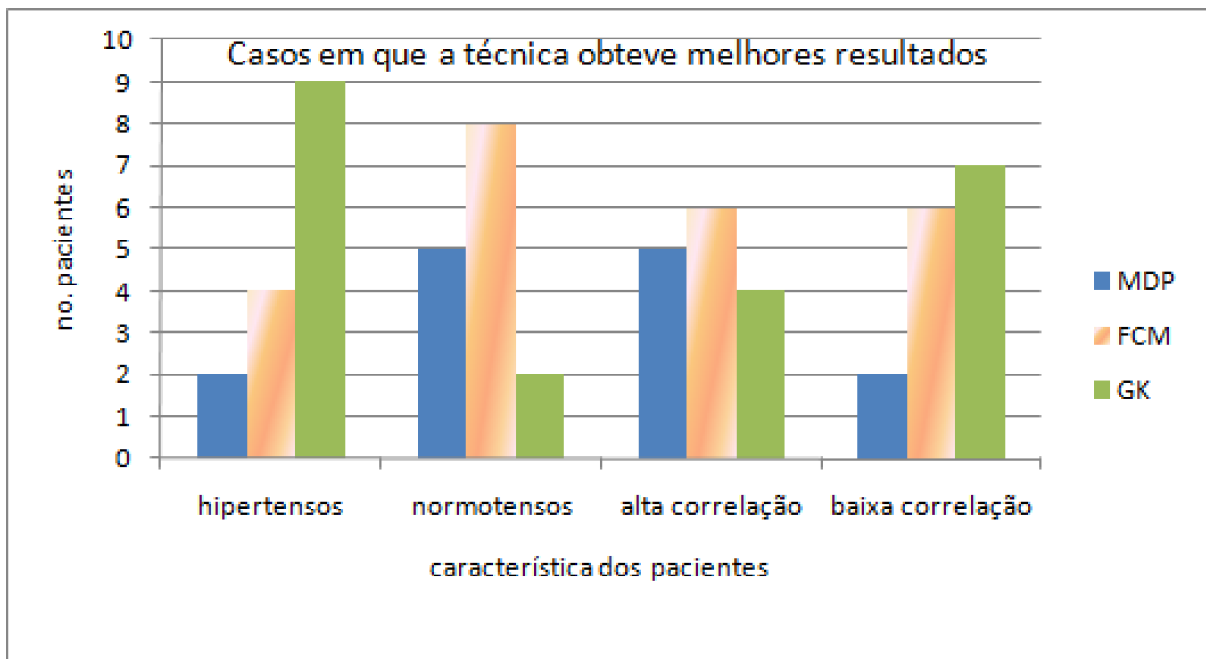


Figura 5.12: Desempenho das técnicas por característica do paciente

as características dos pacientes. A Figura 5.12 apresenta essa relação considerando pacientes hipertensos ou normotensos, com alta ou baixa correlação PAS-PAD.

A técnica de FCM mais uma vez obtém os melhores resultados, enquanto as técnicas de agrupamento mostram-se superiores que a MDP na quantidade de casos de sucesso e os pacientes com baixa correlação e hipertensos são mais bem atendidos pela técnica de GK. No entanto, é necessária uma avaliação com uma quantidade maior de dados de pacientes para confirmar os resultados obtidos.

## 5.4 Conclusões do Capítulo

Os resultados apresentados pelo Módulo de Inferência demonstram que o sistema possui características interessantes para o monitoramento de longa duração. A identificação de alarmes se concentra nas grandes variações, pois, além de usar a média do paciente,

respeita uma margem de tolerância que depende da atividade sendo praticada minutos antes da medição. Dessa forma, os pacientes hipertensos são tratados de forma diferenciada, permitindo que os médicos se concentrem nos casos que demandem uma análise das causas das variações de pressão arterial.

Em relação ao uso das técnicas, mostramos algumas evidências de ser possível associar as características de sinais vitais do paciente a determinadas técnicas. Testes iniciais mostraram ser mais interessante um agrupamento GK para pacientes hipertensos e com baixa correlação entre PAS e PAD. No entanto, mais testes são necessários.

Outra contribuição do Módulo de Inferência é a identificação de emergências que determinariam novas medições e talvez a notificação de profissionais de saúde. Portanto, o conceito de emergência é adicional à análise tradicional de MAPA e reforça nosso mecanismo de identificação de situações críticas.

Já a geração de dados de sinais vitais proposta neste Capítulo representa uma nova abordagem para melhorar a qualidade dos testes em aplicações de monitoramento domiciliar. Os dados sintéticos mantêm as características dos dados originais. Aprendendo com esses dados, o sistema está apto para novas situações parecidas com as que já ocorreram em uma atividade específica.

A geração de dados sintéticos se apoia nos dados estatísticos dos dados originais, além de preservar a correlação e de tratar os dados originais classificados pela variável atividade. Quanto maior for a relação entre os sinais vitais e as informações de contexto, mais consistentes serão os dados sintéticos. No entanto, os dados de MAPA possuem uma limitação devido ao fato de que as pessoas não anotam todas as atividades que elas estavam fazendo. Acreditamos que, com o uso de subsistemas que reconheçam de forma autônoma a atividade e, principalmente, a intensidade de movimentos, poderemos melhorar essa associação entre dados fisiológicos e comportamentais.

A intervenção do especialista é facilitada pela definição do limite usado no conceito de alertas leves, que restringe as medições a serem consideradas pelo processo de aprendizado – uma forma de o especialista expressar em um nível alto a tolerância para alertas leves. O objetivo é ajustar as regras para reduzir o número de alertas, personalizando o tratamento, sem deixar de lançar alertas para eventos importantes. Em outras palavras, trata-se de ajustar o modelo com base na relevância dos alertas, para cada paciente individualmente.

Esse compromisso entre a atuação do especialista e a automaticidade do mecanismo é equilibrada também pela adoção de técnicas de agrupamento. Em vez de ter que definir

o valor do desvio padrão para eliminação de dados no MDP, as técnicas de agrupamento realizam a definição da proposta de ajuste das variáveis de forma automática.

A comparação dos resultados do mecanismo de Decisão com a avaliação médica demonstrou que a solução é viável para o monitoramento de pacientes e que pode ser testada, com acompanhamento médico e devidas precauções, em ambientes reais. O principal fato é que o sistema identificou as emergências e alertas apontados pelos médicos, enquanto os casos pontuais de divergência (alertas tratados como normais) foram justificados pela provável entrada incorreta de informações no sistema em relação à atividade. Nesta avaliação, também foi verificado que as técnicas de agrupamento obtiveram os melhores resultados, contribuindo, assim, para concluir que uma solução que incorpore técnicas de agrupamento consegue atender as estratégias de projeto que foram estabelecidas.

A avaliação médica dos dados de pacientes é de extrema importância para a evolução do mecanismo de Decisão. Acreditamos que o aperfeiçoamento poderá ser obtido por uma melhor caracterização de cada paciente, acrescentando informações de idade, das atuais atividades físicas, de doenças relacionadas e da (in)tolerância de certas variações de sinais vitais, entre outros. O impacto de cada aspecto determinará principalmente regras de reforço que constituirão uma nova configuração para o paciente.

# Capítulo 6

## Conclusões e Trabalhos Futuros

A utilização dos conceitos de computação pervasiva em um cenário de assistência domiciliar tem um grande impacto na forma comumente adotada de telemonitoramento de pacientes. Assim, nossa contribuição inicial foi descrever os pontos de pesquisa, propostas e aplicações relevantes na área de tratamento de saúde com computação pervasiva, que demonstrou ser um importante complemento ao tratamento tradicional.

Identificamos uma oportunidade em detetar situações de alerta, o que pode evitar que se recorra a um atendimento somente quando a situação já é crítica. Da mesma forma, a notificação de emergências é outro recurso importante, principalmente no caso de idosos. Quanto ao aspecto médico, podemos aperfeiçoar a forma de interpretação dos dados, com relatórios contendo informações mais detalhadas do dia a dia do paciente.

O Arcabouço de Monitoramento e o seu mecanismo de Decisão, ilustrados, respectivamente, nas Figuras 3.1 e 4.7, constituem o suporte à identificação de situações críticas no monitoramento de saúde de um paciente em casa. O arcabouço integra os componentes essenciais para o suporte das aplicações de monitoramento de saúde. Além disso, a clara separação de papéis com funções de fusão de dados e de inferência no módulo de gerenciamento de contexto auxilia no desenvolvimento de aplicações, por estruturar de uma melhor forma as funcionalidades das aplicações.

O arcabouço contribui para uma visão holística do tratamento de saúde, enfatizando um mecanismo de Decisão que contempla a fusão dos dados ambientais, fisiológicos e comportamentais. Com isso, os alarmes tornam-se mais confiáveis, agregando ao monitoramento: a individualização, a relaxação dos limites de exames e a influência do comportamento e do ambiente nas variáveis fisiológicas.

A principal contribuição do trabalho é um mecanismo inédito de decisão para inferên-

cia de contexto em aplicações de monitoramento de saúde em ambientes pervasivos. Dessa forma, o sistema proporciona uma importante ferramenta para o apoio à análise médica, já que diversas variáveis podem ser contempladas na solução, devido à flexibilidade do sistema. A identificação de situações críticas é realizada em tempo real e contínua, sendo supervisionada pelo médico, o qual controla em alto nível (por meio do conceito de alertas leves) o desempenho do mecanismo de Decisão.

No entanto, o monitoramento de saúde só é efetivo se atendido o requisito de individualização do paciente. Em um sistema que utiliza regras, é necessário um aprendizado que não prejudique a interpretabilidade das regras. A solução apresentada resolve esse problema com um conjunto de medidas: o sistema de inferência usa poucas variáveis no antecedente de cada regra, os ajustes são realizados sob supervisão médica e, por último, o aprendizado ocorre com base em pontos representativos que servem para ajustar regras específicas. A estratégia de tornar normais os casos de alertas leves permite que o sistema seja utilizado no monitoramento individualizado de longa duração.

A avaliação do mecanismo de Decisão ocorreu por intermédio de um experimento, usando principalmente dados sintéticos. Com isso, foi possível testar uma das importantes contribuições da tese, que é o conjunto de regras elaborado. Da mesma forma, foram feitos testes com a metodologia de aprendizagem e os resultados foram comparados com uma avaliação médica. Tais testes comprovaram os resultados promissores da solução apresentada.

## 6.1 Trabalhos Futuros

Nosso trabalho claramente contribui para o avanço das investigações no âmbito do quinto grande desafio da Sociedade Brasileira de Computação (Desenvolvimento Tecnológico de Qualidade) [2], por buscar soluções para o projeto e o desenvolvimento de sistemas ubíquos e corretos. A ubiquidade mostra que novas aplicações serão criadas e o monitoramento de saúde em ambientes pervasivos demonstrou ser uma área com muita pesquisa ainda a explorar.

O sistema apresentado deve ser testado com muitos pacientes, em situações reais de monitoramento em casa. Notamos que inexistem bases de dados contendo o monitoramento diário de uma pessoa por um longo tempo. Para o aprendizado, tentamos diminuir essa falta de dados utilizando dados sintéticos que reproduzem o comportamento dos dados originais disponíveis em cada atividade. Isso pode reduzir o período de adaptação do

sistema para o indivíduo sendo monitorado, mas mais testes são necessários. Seguindo nesse caminho, pretendemos organizar um banco de dados de medidas e disponibilizar o conjunto de regras para o monitoramento da pressão arterial. Com isso, outros grupos de pesquisa podem propor mudanças, incluindo novas variáveis, como outros sinais vitais e atividades diárias do paciente, ou mesmo o controle de outras doenças crônicas.

A estrutura de nossa abordagem de monitoramento representada pelo arcabouço permite que novas técnicas sejam incorporadas ou que avaliações *off-line* sejam feitas no sentido de criar novas regras. Por exemplo, no componente de Análise de Contexto e Estabilidade, técnicas de aprendizado de máquina podem analisar situações de alertas, o que possibilita que novas regras sejam criadas.

Também encontramos um grande espaço de pesquisa na classe de variável “comportamento”, incluindo diferentes técnicas para o reconhecimento das atividades da vida diária. Esse avanço pode ser incorporado em nossa solução, com o aperfeiçoamento da variável atividade. Uma alternativa é modelar uma variável denominada de intensidade da atividade, representada por graus diferentes de movimentação, incluindo conceitos linguísticos como “parado”, “moderado” e “intenso”. Outra melhoria seria introduzir o conceito de duração da atividade, como apresentado em [122]. Em um nível mais alto, está um sistema de recomendação que consiga fazer análises com uma grande quantidade de dados. Algumas possibilidades podem ser a detecção de inatividade do paciente ou de tremores excessivos que fujam da normalidade.

Outra questão importante no monitoramento é o uso da variável tempo. Essa questão pode ser vista sob a ótica da coleta de dados, realizando, por exemplo, a sincronização de tempo para buscar dados de várias fontes de contexto [69]. Já sob a ótica da tomada de decisão, o tratamento do tempo pode ser modelado com variáveis *fuzzy* [85] e as mudanças de estados do paciente serem analisadas sob o aspecto temporal [14].

O Plano de Cuidados também representa um tópico que pode ser explorado sob vários aspectos. Um deles é o uso de técnicas inteligentes para atualização do plano, conforme [91], trazendo um grande impacto no tratamento de idosos com deficiências cognitivas. As técnicas podem ser empregadas na tarefa do Plano de Cuidados referente a fazer com que o paciente cumpra os horários de medicamentos, os momentos de exercícios, as recomendações de dietas, as tarefas da vida diária sem repetições desnecessárias, a medição adequada dos sinais vitais (por exemplo, com relação à posição do braço para medir a pressão arterial) etc.

Por fim, outra área relevante é a definição de arquiteturas adaptativas para o sistema

---

de monitoramento e, em especial, para o Plano de Cuidados [29] [71]. Dada a heterogeneidade de múltiplos ambientes onde o sistema será instalado, as aplicações devem se adaptar a essas condições. Essa investigação leva em conta as variações nos recursos e no contexto, os requisitos específicos funcionais e não funcionais das aplicações. Uma abordagem promissora para tratar esse problema encontra-se em [28], por meio da técnica de Linha de Produto de Software, a qual possibilita a criação de produtos para prover a personalização dos sistemas, atendendo as necessidades dos usuários específicas ao seu tratamento e aos recursos na residência.

## APÊNDICE A – Artigos Publicados

Este Apêndice apresenta os artigos publicados durante a elaboração da tese.

### Artigos publicados:

1. CARVALHO, S. T.; COPETTI, A.; LOQUES, O. **Um Sistema Computacional Inteligente de Assistência Domiciliar à Saúde**. In: Congresso Brasileiro de Informática em Saúde. Porto de Galinhas, Brasil, 2010 – Um dos 5 melhores artigos do Congresso.

O artigo apresenta um Sistema de Assistência Domiciliar à Saúde, com enfoque na integração entre o Plano de Cuidados e as funcionalidades para implementar um protótipo de monitoramento da pressão arterial.

2. CARVALHO, S. T.; ERTHAL, M.; MARELI, D.; Sztajnberg, A.; COPETTI, A.; LOQUES, O. G. **Monitoramento Remoto de Pacientes em Ambiente Domiciliar**. In: Salão de Ferramentas, Simpósio Brasileiro de Redes de Computadores. Gramado, Brasil, 2010.

Este artigo apresenta os detalhes da implementação do protótipo de monitoramento remoto, que compreende basicamente a Central de Supervisão Médica (CSM) e a Central de Supervisão Residencial (CSR).

O *download* do protótipo pode ser encontrado em:

<http://sites.google.com/site/sistemadetelesaude/downloads>.

3. SZTAJNBERG, A.; RODRIGUES, A. L. B.; BEZERRA, L. N.; LOQUES, O. G.; COPETTI, A.; CARVALHO, S. T. **Applying context-aware techniques to design remote assisted living applications**. International Journal of Functional Informatics and Personalised Medicine, v. 2, p. 358-378, 2009.

O artigo apresenta de forma detalhada uma infraestrutura de suporte à execução de aplicações pervasivas. Um estudo de caso para o monitoramento da pressão



arterial apresenta especificações para a notificação e coleta da pressão arterial e da temperatura ambiente (realizada por um agente de recursos). As classes e as mensagens usadas pelos serviços sensíveis ao contexto são apresentadas.

4. COPETTI, A.; LOQUES, O. G.; LEITE, J. C. B.; Barbosa, T. P. C.; NOBREGA, A. C. L. **Intelligent Context-Aware Monitoring of Hypertensive Patients**. In: Situation Recognition and Medical Data Analysis in Pervasive Health Environments, Pervasive Healthcare Conference. Londres, Reino Unido, 2009.

A *Pervasive Healthcare Conference* é o evento mais específico da área, que reúne os trabalhos integrando computação pervasiva com tratamento de saúde. Nesse artigo, apresentamos o módulo de Raciocínio com a maior parte das regras já definidas. Foram feitos testes com dados de pacientes reais. Um dos testes avaliou a importância do uso da variável *atividade* nas regras. Em outro teste, foi avaliada a saída do sistema com e sem o componente que realiza a análise dos casos mais frequentes.

5. RODRIGUES, A. L. B.; GOMES, I. C.; BEZERRA, L. N.; SZTAJNBERG, A.; CARVALHO, S. T.; COPETTI, A.; LOQUES, O. G. **Using Discovery and Monitoring Services to Support Context-Aware Remote Assisted Living Applications**. In: Workshop on Ubiquitous Computing, Management, and Embedded Applications in Healthcare, International Conferences on Embedded and Ubiquitous Computing. Vancouver, Canadá, 2009.

O artigo apresenta a infraestrutura de suporte à execução de aplicações pervasivas. Os principais serviços são o de Contexto, que provê acesso às informações de contexto, e de Descoberta de Serviços, que monitora o estado de dispositivos e sensores e provê acesso às funcionalidades desses recursos. Essa infraestrutura tem fundamental importância para generalizar a proposta deste trabalho, agregando conceitos de sistemas distribuídos e de computação pervasiva.

6. COPETTI, A.; LEITE, J.; LOQUES, O. G.; NOBREGA, A. C. L. ; BARBOSA, T. P. C. **Monitoramento Inteligente e Sensível ao Contexto na Assistência Domiciliar Telemonitorada**. In: Seminário Integrado de Software e Hardware, Congresso da Sociedade Brasileira de Computação. Belém, Brasil, 2008.

Este artigo foi publicado em um ano em que o SEMISH foi dedicado para os Grandes Desafios da SBC (2006-2016). Assim, foi apresentada uma visão de futuro englobando a computação pervasiva e o tratamento de saúde. A nossa proposta de um modelo de Decisão para o monitoramento remoto foi apresentada pela primeira vez.

Um teste analisou o comportamento do sistema quando associa o comportamento (atividade da pessoa) com os dados fisiológicos.

7. FREIRE, S.; SZTAJNBERG, A.; COPETTI, A.; LOQUES, O. **Utilizando o Modelo Dual para a Representação e Persistência de Contexto em Aplicações Ubíquas de Telemonitoramento**. In: Workshop de Informática Médica, Congresso da Sociedade Brasileira de Computação. Belém, Brasil, 2008.

Este artigo, ao contrário dos outros, é um resumo expandido. Ele apresenta uma proposta para a representação e persistência de dados clínicos e de contexto no desenvolvimento de aplicações de assistência domiciliar e de telemonitoramento. Geralmente cada sistema possui uma forma específica para armazenar dados, o que leva a um frequente retrabalho e uma total falta de interoperabilidade entre sistemas. A proposta se baseia no modelo dual da Fundação openEHR. Um dos conceitos usados é o de arquétipo, que determina como representar a informação. Os arquétipos podem ser associados a ontologias e incluir referências a sistemas terminológicos utilizados para codificar os seus dados.

8. COPETTI, A.; LOQUES, O. G.; LEITE, J. C. B. **Intelligent context-aware monitoring in home care**. In: Int. Conf. on E-Medical Systems. Sfax, Tunísia, 2008.

Neste trabalho, apresentamos os componentes principais de um arcabouço conceitual para o monitoramento inteligente de um paciente em casa. Para essa definição, foram investigadas as classes de variáveis e os principais problemas e desafios para a criação de uma proposta de monitoramento.

9. COPETTI, A.; LEITE, J. C. B.; LOQUES, O. G. **Localização Tolerante a Falhas de Usuários Móveis em Ambientes Fechados**. In: VII Workshop de Testes e Tolerância a Falhas, Simpósio Brasileiro de Redes de Computadores. Curitiba, Brasil, 2006.

Este artigo é o único que não está relacionado com saúde. No entanto, o artigo trata da localização de uma pessoa em ambientes fechados, importante recurso em aplicações de *pervasive home care*. As técnicas de redes neurais e *k-vizinhos mais próximos* foram testadas e implementadas em um dispositivo móvel.

## APÊNDICE B – Breve Introdução às Variáveis Fuzzy

Este Apêndice apresenta uma breve introdução às variáveis *fuzzy*, as quais fazem parte da lógica *fuzzy* criada por Zadeh [121].

Na teoria dos conjuntos, cada elemento pertence ou não pertence a um determinado conjunto (*crisp set*). Dado um universo  $U$  e um elemento particular  $x \in U$ , o grau de pertinência  $\mu_A(x)$  com respeito a um conjunto  $A \subseteq U$  é dado por [51]:

$$\mu_A(x) = \begin{cases} 1, & \text{se } x \in A \\ 0, & \text{se } x \notin A \end{cases}$$

Já na lógica *fuzzy*, um conjunto *fuzzy*  $A$  em um universo de discurso  $U$  é definido por uma função de pertinência  $\mu_A$  que assume valores em um intervalo  $[0,1]$ :

$$\mu_A : U \rightarrow [0,1]$$

onde  $\mu_A(x)$  indica quanto  $x$  é compatível com o conjunto  $A$ . Portanto, um conjunto *fuzzy*  $A$  é caracterizado pelo par  $(x, \mu_A(x))$ , no qual  $x$  é a variável, contínua ou discreta, e  $\mu_A$  é uma função cuja imagem está contida em  $[0,1]$  [82].

Determinado elemento pode pertencer a mais de um conjunto *fuzzy*, com diferentes graus de pertinência. Os graus de pertinência são obtidos através de funções de pertinência. Assim, podemos expressar o conjunto *fuzzy* por sua função de pertinência [82].

Um exemplo de conjunto *fuzzy* é o conceito de “alto” (também denominado termo linguístico) na variável “temperatura ambiente” — os termos linguísticos caracterizam a variável linguística. Se assumirmos que acima de  $30^{\circ}$  graus é uma temperatura alta, então uma abordagem rígida simplesmente interpreta  $29^{\circ}$  graus como uma temperatura não alta. No entanto, essa temperatura possui uma compatibilidade parcial com o conjunto “alto”. Na variável *fuzzy*, podemos usar uma função trapezoidal para definir o conjunto, como mostrado na Figura B.1.

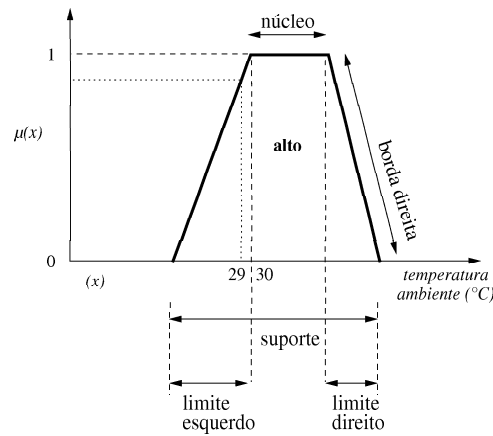


Figura B.1: Conjunto *fuzzy*

Nesse caso, um número *fuzzy* trapezoidal é definido pela quádrupla:

$$f(x; a, b, c, d) = \begin{cases} 0, & x < a \\ \frac{(x-a)}{(b-a)}, & a \leq x \leq b \\ 1, & b \leq x \leq c \\ \frac{(d-x)}{(d-c)}, & c < x < d \\ 0, & x \leq d \end{cases}$$

Um conceito relacionado é o conjunto *suporte* de um conjunto *fuzzy* A, que é o conjunto de elementos para os quais  $\mu_A(x) > 0$ .

As regras *fuzzy* usam o formato: *IF* <antecedente> *THEN* <consequente>. A regra é disparada quando o antecedente para as entradas atuais gera graus de pertinência não-nulos [95]. Assim, para um dado vetor de entrada que alimenta o sistema é feita uma avaliação do grau de compatibilidade de cada componente de entrada com os conjuntos *fuzzy* correspondentes ao seu domínio [79].

Um detalhamento das questões apresentadas nesse Apêndice e outros materiais sobre lógica *fuzzy* podem ser encontrados em [24] [66] [97].

## APÊNDICE C – Regras

Este Apêndice apresenta as regras utilizadas no mecanismo de Decisão proposto para o estudo de caso de monitoramento da pressão arterial. O valor entre parênteses no final da regra representa o peso da regra no sistema de inferência, o qual assume valores de 0 a 1. As regras estão no formato *if <antecedente> then <consequente> (<peso>)*:

if (atividade is dormir) and (desvioPASdormindo is muitoBaixo) then (acao is emergencia) (1)

if (atividade is dormir) and (desvioPASdormindo is baixo) then (acao is alerta) (0.3)

if (atividade is dormir) and (desvioPASdormindo is normal) then (acao is normal) (0.2)

if (atividade is dormir) and (desvioPASdormindo is alto) then (acao is alerta) (0.5)

if (atividade is dormir) and (desvioPASdormindo is muitoAlto) then (acao is emergencia) (1)

if (atividade is dormir) and (desvioPADdormindo is muitoBaixo) then (acao is emergencia) (1)

if (atividade is dormir) and (desvioPADdormindo is baixo) then (acao is alerta) (0.3)

if (atividade is dormir) and (desvioPADdormindo is normal) then (acao is normal) (0.2)

if (atividade is dormir) and (desvioPADdormindo is alto) then (acao is alerta) (0.5)

if (atividade is dormir) and (desvioPADdormindo is muitoAlto) then (acao is emergencia) (1)

if (atividade is repouso) and (desvioPASrepouso is muitoBaixo) then (acao is emergencia) (1)

if (atividade is repouso) and (desvioPASrepouso is baixo) then (acao is alerta) (0.3)

if (atividade is repouso) and (desvioPASrepouso is normal) then (acao is normal) (0.2)

if (atividade is repouso) and (desvioPASrepouso is alto) then (acao is alerta) (0.5)

if (atividade is repouso) and (desvioPASrepouso is muitoAlto) then (acao is emergencia) (1)

if (atividade is repouso) and (desvioPADrepouso is muitoBaixo) then (acao is emergencia) (1)

if (atividade is repouso) and (desvioPADrepouso is baixo) then (acao is alerta) (0.3)

if (atividade is repouso) and (desvioPADrepouso is normal) then (acao is normal) (0.2)

if (atividade is repouso) and (desvioPADrepouso is alto) then (acao is alerta) (0.5)

if (atividade is repouso) and (desvioPADrepouso is muitoAlto) then (acao is emergencia) (1)

if (atividade is comer) and (desvioPAScomendo is muitoBaixo) then (acao is emergencia) (1)

if (atividade is comer) and (desvioPAScomendo is baixo) then (acao is alerta) (0.3)

if (atividade is comer) and (desvioPAScomendo is normal) then (acao is normal) (0.2)

- if (atividade is comer) and (desvioPAScomendo is alto) then (acao is alerta) (0.5)
- if (atividade is comer) and (desvioPAScomendo is muitoAlto) then (acao is emergencia) (1)
- if (atividade is comer) and (desvioPADcomendo is muitoBaixo) then (acao is emergencia) (1)
- if (atividade is comer) and (desvioPADcomendo is baixo) then (acao is alerta) (0.3)
- if (atividade is comer) and (desvioPADcomendo is normal) then (acao is normal) (0.2)
- if (atividade is comer) and (desvioPADcomendo is alto) then (acao is alerta) (0.5)
- if (atividade is comer) and (desvioPADcomendo is muitoAlto) then (acao is emergencia) (1)
- if (atividade is caminhar) and (desvioPAScaminhando is muitoBaixo) then (acao is emergencia) (1)
- if (atividade is caminhar) and (desvioPAScaminhando is baixo) then (acao is alerta) (0.3)
- if (atividade is caminhar) and (desvioPAScaminhando is normal) then (acao is normal) (0.2)
- if (atividade is caminhar) and (desvioPAScaminhando is alto) then (acao is alerta) (0.5)
- if (atividade is caminhar) and (desvioPAScaminhando is muitoAlto) then (acao is emergencia) (1)
- if (atividade is caminhar) and (desvioPADcaminhando is muitoBaixo) then (acao is emergencia) (1)
- if (atividade is caminhar) and (desvioPADcaminhando is baixo) then (acao is alerta) (0.3)
- if (atividade is caminhar) and (desvioPADcaminhando is normal) then (acao is normal) (0.2)
- if (atividade is caminhar) and (desvioPADcaminhando is alto) then (acao is alerta) (0.5)
- if (atividade is caminhar) and (desvioPADcaminhando is muitoAlto) then (acao is emergencia) (1)
- if (atividade is ativDomestica) and (desvioPASativDomestica is muitoBaixo) then (acao is emergencia) (1)
- if (atividade is ativDomestica) and (desvioPASativDomestica is baixo) then (acao is alerta) (0.3)
- if (atividade is ativDomestica) and (desvioPASativDomestica is normal) then (acao is normal) (0.2)
- if (atividade is ativDomestica) and (desvioPASativDomestica is alto) then (acao is alerta) (0.5)
- if (atividade is ativDomestica) and (desvioPASativDomestica is muitoAlto) then (acao is emergencia) (1)
- if (atividade is ativDomestica) and (desvioPADativDomestica is muitoBaixo) then (acao is emergencia) (1)
- if (atividade is ativDomestica) and (desvioPADativDomestica is baixo) then (acao is alerta) (0.3)
- if (atividade is ativDomestica) and (desvioPADativDomestica is normal) then (acao is normal) (0.2)
- if (atividade is ativDomestica) and (desvioPADativDomestica is alto) then (acao is alerta) (0.5)
- if (atividade is ativDomestica) and (desvioPADativDomestica is muitoAlto) then (acao is emergencia) (1)
- if (freqCard is normal) then (acao is normal) (0.1)
- if (freqCard is baixa) then (acao is alerta) (0.1)
- if (freqCard is alta) then (acao is alerta) (0.1)
- if (atividade is dormir) and (freqCard is alta) then (acao is alerta) (0.7)
- if (freqCard is alta) and (temperaturaAmbiente is alta) then (acao is normal) (0.1)
- if (atividade is not dormir) and (PAS is normalVigilia) then (acao is normal) (0.4)
- if (atividade is dormir) and (PAS is normalSono) then (acao is normal) (0.4)
- if (atividade is not dormir) and (PAD is normalVigilia) then (acao is normal) (0.4)

- 
- if (atividade is dormir) and (PAD is normalSono) then (acao is normal) (0.4)
- (1) if (atividade is not dormir) and (desvioPASrepouso is muitoAlto) and (PAS is hipertenso) then (acao is emergencia)
- (1) if (atividade is not dormir) and (desvioPADrepouso is muitoAlto) and (PAD is hipertenso) then (acao is emergencia)
- (1) if (atividade is not dormir) and (desvioPASrepouso is muitoAlto) and (PAS is hipertenso) then (acao is emergencia)
- (1) if (atividade is not dormir) and (desvioPADrepouso is muitoAlto) and (PAD is hipertenso) then (acao is emergencia)

# Referências

- [1] Applications relating to health. Final Report. European Commission, 2004. [http://ec.europa.eu/information\\_society/activities/health/docs/publications/fp5-ehealth-applications-relating-to-health.pdf](http://ec.europa.eu/information_society/activities/health/docs/publications/fp5-ehealth-applications-relating-to-health.pdf).
- [2] Grandes Desafios da Pesquisa em Computação no Brasil 2006–2016, 2006. <http://www.sbc.org.br>.
- [3] Intel XScale Technology, 2007. <http://www.intel.com/design/intelxscale/>.
- [4] Crossbow, 2010. <http://www.xbow.com>.
- [5] SenseWear BMS Components, 2010. <http://sensewear.bodymedia.com>.
- [6] János Abonyi e Balázs Feil. *Cluster Analysis for Data Mining and System Identification*. Birkhäuser Basel, 2007.
- [7] K. P. Adlassnig, C. Combi, A. K. Das, E. T. Keravnou e G. Pozzi. Temporal representation and reasoning in medicine: Research directions and challenges. *Artificial Intelligence in Medicine*, 38(2):101–113, 2006.
- [8] I. Akyildiz e I. Kasimoglu. Wireless sensor and actor networks: research challenges. *Ad Hoc Networks*, 2(4):351–367, 2004.
- [9] F. Albinali, M. S. Goodwin e S. S. Intille. Recognizing stereotypical motor movements in the laboratory and classroom: a case study with children on the autism spectrum. In *Ubiquitous Computing*, pp. 71–80. ACM, 2009.
- [10] O. Amft e G. Tröster. Recognition of dietary activity events using on-body sensors. *Artificial Intelligence in Medicine*, 42(2):121–136, 2008.
- [11] C. Anagnostopoulos e S. Hadjiefthymiades. Advanced fuzzy inference engines in situation aware computing. *Fuzzy Sets Systems*, 161(4):498–521, 2010.
- [12] M. Anastasopoulos, C. Bartelt, J. Koch, D. Niebuhr e A. Rausch. Towards a reference middleware architecture for ambient intelligence systems. In *Workshop for Building Software for Pervasive Computing - 20th Conference on Object-Oriented Programming Systems, Languages and Applications (OOPSLA)*, Tóquio, Japão, 2005.
- [13] L. Atallah, M. ElHelw, J. Pansoit, D. Stoyanov, L. Wang, B. Lo e Guang-Zhong Yang. Behaviour profiling with ambient and wearable sensing. In *Wearable and Implantable Body Sensor Networks*, pp. 133–138, 2007.



- [14] J. C. Augusto. Temporal reasoning for decision support in medicine. *Artificial Intelligence in Medicine*, 33(1):1–24, 2005.
- [15] J. C. Augusto, C.D. Nugent, S. Martin e C. Olphert. Towards personalization of services and an integrated service model for smart homes applied to elderly care. In *Smart Homes and Health Telematic*, pp. 151–158, Sherbrooke, Canadá, 2005.
- [16] G. Bakris, M. Hill, G. Mancina, K. Steyn, H. R. Black, T. Pickering, S. De Geest, L. Ruilope, T. D. Giles, T. Morgan et al. Achieving blood pressure goals globally: five core actions for health-care professionals. A worldwide call to action. *Journal of Human Hypertension*, 22(1):63–70, 2007.
- [17] M. Balazinska, A. Deshpande, M. J. Franklin, P. B. Gibbons, J. Gray, M. Hansen, M. Liebhold, S. Nath, A. Szalay e V. Tao. Data management in the worldwide sensor web. *IEEE Pervasive Computing*, pp. 30–40, 2007.
- [18] T. S. Barger, D. E. Brown e M. Alwan. Health-status monitoring through analysis of behavioral patterns. *IEEE Transactions on Systems, Man and Cybernetics*, 35(1):22–27, 2005.
- [19] D. Bekele, B. Eshete, A. Villafiorita e K. Weldemariam. Context information refinement for pervasive medical systems. In *Digital Society*, pp. 210–215, 10-16 2010.
- [20] J. C. Bezdek. *Pattern Recognition with Fuzzy Objective Function Algorithm*. Plenum Press, Nova Iorque, EUA, 1981.
- [21] K. Birman. The untrustworthy web services revolution. *IEEE Computer*, 39(2):113–115, 2006.
- [22] O. Brdiczka, P. Reignier e J. L. Crowley. Automatic development of an abstract context model for an intelligent environment. In *Pervasive Computing and Communications Workshop*, pp. 35–39. IEEE, 2005.
- [23] T. Broens, A. van Halteren, M. van Sinderen e K. Wac. Towards an application framework for context-aware m-health applications. *International Journal of Internet Protocol Technology*, 2(2):109–116, 2007.
- [24] J.J. Buckley e E. Eslami. *An introduction to fuzzy logic and fuzzy sets*. Springer Berlin Heidelberg, 2002.
- [25] F. Buttussi e L. Chittaro. Mopet: A context-aware and user-adaptive wearable system for fitness training. *Artificial Intelligence in Medicine*, 42(2):153–163, 2008.
- [26] L. C., A. Sztajnberg e O. Loques. Self-adaptive applications using ADL contracts. In *Self-Managed Networks, Systems, and Services*, volume 3996 of *Lecture Notes in Computer Science*, pp. 87–101, Dublin, Irlanda, 2006.
- [27] Y. Cai. Empathic computing. *Ambient Intelligence for Everyday Life*, 3864, 2006.
- [28] S. T. Carvalho. Variabilidades dinâmicas em um sistema computacional inteligente de assistência domiciliar à saúde: uma abordagem baseada em linhas de produto e contratos arquiteturais (proposta de tese), 2010.

- [29] S. T. Carvalho, A. Copetti e O. Loques. Um sistema computacional inteligente de assistência domiciliar à saúde. In *XII Congresso Brasileiro de Informática em Saúde*, Porto de Galinhas, Brasil, 2010.
- [30] G. Castellano, A. M. Fanelli e C. Mencar. Design of transparent mamdani fuzzy inference systems. In *Hybrid Intelligent Systems*, volume 105 of *Frontiers in Artificial Intelligence and Applications*, pp. 468–477. IOS Press, 2003.
- [31] S. Chetan, A. Ranganathan e R. Campbell. Towards fault tolerant pervasive computing. In *IEEE Technology and Society*, volume 24, pp. 38–44, 2005.
- [32] A. Copetti, J. C. B. Leite e O. G. Loques. Localização tolerante a falhas de usuários móveis em ambientes fechados. In *VII Workshop de Testes e Tolerância a Falhas*, Curitiba, Brasil, 2006.
- [33] G. Coulouris, J. Dollimore e T. Kindberg. *Distributed systems: concepts and design*. Addison-Wesley Longman Publishing Co., Inc., Boston, EUA, 4a. edição, 2005.
- [34] P. Cuddihy, J. Weisenberg, C. Graichen e M. Ganesh. Algorithm to automatically detect abnormally long periods of inactivity in a home. In *Systems and Networking Support for Healthcare and Assisted Living Environments*, pp. 89–94, Nova Iorque, EUA, 2007. ACM.
- [35] C. A. da Costa, A. C. Yamin e C. F. R. Geyer. Toward a general software infrastructure for ubiquitous computing. *Pervasive Computing*, 7(1):64–73, 2008.
- [36] A. C. L. da Nobrega. The subacute effects of exercise: concept, characteristics, and clinical implications. *Exercise and Sport Sciences Reviews*, 33(2):84–87, 2005.
- [37] S. K. Das e D. J. Cook. Designing and modeling smart environments. In *World of Wireless, Mobile and Multimedia Networks (WoWMoM)*, pp. 490–494, 2006.
- [38] I. Derbel, N. Hachani e H. Ounelli. Membership functions generation based on density function. In *Computational Intelligence and Security*, volume 1, pp. 96–101. IEEE, 2008.
- [39] A. Dey. Understanding and using context. *Personal and Ubiquitous Computing*, 5(1):4–7, 2001.
- [40] M. C. Domingo. Managing healthcare through social networks. *Computer*, 43:20–25, 2010.
- [41] F. Duchêne, C. Garbay e V. Rialle. Learning recurrent behaviors from heterogeneous multivariate time-series. *Artificial intelligence in Medicine*, 39(1):25–47, 2007.
- [42] E. El-Samahy, M. Mahfouf e D. A. Linkens. A closed-loop hybrid physiological model relating to subjects under physical stress. *Artificial Intelligence in Medicine*, 38(3):257–274, 2006.
- [43] M. ElHelw, J. Pansiot, D. McIlwraith, R. Ali, B. Lo e L. Atallah. An integrated multi-sensing framework for pervasive healthcare monitoring. In *Pervasive Computing Technologies for Healthcare*, pp. 1–7, 1-3 2009.

- [44] C. R. Baker et al. Wireless sensor networks for home health care. In *Advanced Information Networking and Applications Workshops*, pp. 832–837, Washington, EUA, 2007.
- [45] A. Folling, C. Grimme, J. Lepping e A. Papaspyrou. Robust load delegation in service grid environments. *Parallel and Distributed Systems*, 21:1304–1316, 2010.
- [46] S. Freire, A. Sztajnberg, A. Copetti e O. G. Loques. Utilizando o modelo dual para a representação e persistência de contexto em aplicações ubíquas de telemonitoramento. In *8st Workshop de Informática Médica*, Belém, Brasil, 2008.
- [47] R. K. Ganti, P. Jayachandran, T. F. Abdelzaher e J. A. Stankovic. SATIRE: a software architecture for smart AtTIRE. In *Mobile Systems, Applications and Services*, pp. 110–123, Nova Iorque, EUA, 2006.
- [48] B. Gavish, I. Z. Ben-Dov e M. Bursztyn. Linear relationship between systolic and diastolic blood pressure monitored over 24 h: assessment and correlates. *Journal of Hypertension*, 26(2):199, 2008.
- [49] Sean N. Ghazavi e Thunshun W. Liao. Medical data mining by fuzzy modeling with selected features. *Artificial Intelligence in Medicine*, 43(3):195–206, 2008.
- [50] C. Glaros e D. I. Fotiadis. *Intelligent paradigms for healthcare enterprises: systems thinking (Studies in Fuzziness and Soft Computing)*, chapter Wearable Devices in Healthcare, pp. 237–264. Springer-Verlag, 2005.
- [51] F. Gomide e R. Gudwin. Modelagem, controle, sistemas e lógica fuzzy. *Controle e Automação*, 4(3):97–115, 1994.
- [52] S. Guillaume. Designing fuzzy inference systems from data: An interpretability-oriented review. *IEEE Transactions on Fuzzy Systems*, 9(3):426–443, 2001.
- [53] E. E. Gustafson e W. C. Kessel. Fuzzy clustering with a fuzzy covariance matrix. In *Decision and Control*, volume 17, pp. 761–766, 1979.
- [54] M. Hebert, B. Korabek e R. Scott. Moving research into practice: a decision framework for integrating home telehealth into chronic illness care. *International Journal of Medical Informatics*, 75(12):786–794, 2006.
- [55] F. Hoffmann. Evolutionary algorithms for fuzzy control system design. *Proceedings of the IEEE*, 89(9):1318–1333, 2001.
- [56] A. Hristova, A. M. Bernardos e J. R. Casar. Developing an ambient home care system: context toolkit-based design and implementation. In *Parallel and Distributed Computing, Applications and Technologies*, pp. 455–461. IEEE, 2008.
- [57] Y. Hsu, C. Yang, T. Tsai, C. Cheng e C. Wu. Development of a decentralized telehomecare monitoring system. *Telemed J E Health*, 13(1):69–78, 2007.
- [58] R. P. Huang. Adaptive fuzzy control: a GA approach. In *Fuzzy Systems*, volume 2, pp. 1266–1272, 1996.

- [59] M. C. Huebscher e J. A. McCann. A learning model for trustworthiness of context-awareness services. In *Pervasive Computing and Communications Workshops*, pp. 120–124. IEEE, 2005.
- [60] E. Hughes, M. Masilela, P. Eddings, A. Rafiq, C. Boanca e R. Merrell. Vmote: a wearable wireless health monitoring system. In *e-Health Networking, Application and Services*, pp. 330–331, 2007.
- [61] IBGE. Instituto Brasileiro de Geografia e Estatística - Indicadores Sociodemográficos e de Saúde no Brasil, 2009. <http://www.ibge.gov.br>.
- [62] Telcomed Advanced Telemedicine Industries. Wristclinic - the all-in-one wireless remote medical monitoring revolution, 2007. <http://www.telcomed.ie>.
- [63] R. Jafari, R. Bajcsy, S. Glaser, B. Gnade, M. Sgroi e S. Sastry. Platform design for health-care monitoring applications. In *High Confidence Medical Devices, Software, and Systems and Medical Device Plug-and-Play Interoperability*, pp. 88–94, 2007.
- [64] R. Jafari, W. Li, R. Bajcsy, S. Glaser e S. Sastry. Physical activity monitoring for assisted living at home. In *Wearable and Implantable Body Sensor Networks*, volume 1, pp. 213–220, Aachen, Alemanha, 2007.
- [65] V. R. Jakkula, D. J. Cook e G. Jain. Prediction models for a smart home based health care system. In *Advanced Information Networking and Applications Workshops*, volume 2, pp. 761–765, Washington, EUA, 2007.
- [66] G.J. Klir, T.A. Folger e R. Kruse. *Fuzzy sets, uncertainty, and information*, volume 159. Prentice Hall Englewood Cliffs, 1988.
- [67] V. Koutkias, I. Chouvarda e N. Maglaveras. A multiagent system enhancing home-care health services for chronic disease management. *IEEE Transactions on Information Technology in Biomedicine*, 9(4):528–537, 2005.
- [68] C. B. Laramee, L. Lesperance, D. Gause e K. Mcleod. Intelligent alarm processing into clinical knowledge. In *Engineering in Medicine and Biology Society*, pp. 6657–6659, 2006.
- [69] H. Lee, K. Park, B. Lee, J. Choi e R. Elmasri. Issues in data fusion for healthcare monitoring. In *Pervasive Technologies Related to Assistive Environments*, pp. 1–8, Nova Iorque, EUA, 2008. ACM.
- [70] P. Leijdekkers, V. Gay e E. Lawrence. Smart homecare system for health tele-monitoring. *Digital Society*, 2007.
- [71] O. G. Loques e A. Sztajuberg. Adaptation issues in software architectures of remote health care systems. In *ICSE Workshop on Software Engineering in Health Care*, Cidade do Cabo, África do Sul, 2010. ACM.
- [72] D. Loures, I. Sant’Anna, C. Baldotto, E. Sousa e A. Nóbrega. Estresse mental e sistema cardiovascular. *Arquivos Brasileiros de Cardiologia*, 78(5):525–530, 2002.

- [73] J. Maitland, S. Sherwood, L. Barkhuus, I. Anderson, M. Hall, B. Brown, M. Chalmers e H. Muller. Increasing the awareness of daily activity levels with pervasive computing. In *Pervasive Computing Technologies for Healthcare*, pp. 1–9, 2006.
- [74] P. J. Marrón, D. Minder e The Embedded WiSeNts Consortium. *Embedded WiSeNts Research Roadmap*. Logos Verlag, Berlim, Alemanha, 2007.
- [75] M. Marschollek, W. Ludwig, I. Schapiewksi, E. Schriever, R. Schubert, H. Dybowski, H. M. zu Schwabedissen, J. Howe e R. Haux. Multimodal home monitoring of elderly people—first results from the lass study. In *International Workshop on Smart Homes for Tele-Health*, pp. 815–819, Washington, EUA, 2007.
- [76] D. Mion, W. Oigman e F. Nobre. *MAPA: Monitorização Ambulatorial da Pressão Arterial*. Atheneu RJ, 3 edição, 2004.
- [77] B. Mutlu, A. Krause, J. Forlizzi, C. Guestrin e J. Hodgins. Robust, low-cost, non-intrusive sensing and recognition of seated postures. In *User Interface Software and Technology*, pp. 149–158, Nova Iorque, EUA, 2007.
- [78] M. Nam, M. Z. Al-Sabbagh e C. Lee. Combined scheduling of sensing and communication for real-time indoor tracking in assisted living. In *Real-Time Systems Symposium*, pp. 281–290, Washington, EUA, 2006.
- [79] L. Neto, P. Coelho, J. do Amaral e M. de Mello. Minicurso de sistema especialista nebuloso. In *Simpósio Brasileiro de Pesquisa Operacional*, 2006.
- [80] P. R. Norris. *Toward New Vital Signs: Tools And Methods For Physiologic Data Capture, Analysis, And Decision Support In Critical Care*. PhD thesis, Biomedical Informatics, Vanderbilt University, Nashville, EUA, 2006.
- [81] J. O’Donoghue, J. Herbert, R. Fensli e S. Dineen. Sensor validation within a pervasive medical environment. *Sensors*, pp. 972–975, 2006.
- [82] H. A. E. Oliveira, M. A. S. Machado, A. M. Caldeira, R. C. Souza e R. Tanscheit. *Inteligência Computacional aplicada à Administração, Economia e Engenharia em Matlab*. Cengage Learning, São Paulo, 2007.
- [83] ONU. Population Division of the Department of Economic and Social Affairs of the United Nations Secretariat - World Population Prospects: The 2008 Revision, 2009.
- [84] C. Orwat, A. Graefe e T. Faulwasser. Towards pervasive computing in health care – a literature review. *BMC Medical Informatics and Decision Making*, 8(1):26, 2008.
- [85] A. Otero, P. Félix, S. Barro e F. Palacios. Addressing the flaws of current critical alarms: a fuzzy constraint satisfaction approach. *Artificial Intelligence in Medicine*, 47(3):219–238, 2009.
- [86] C. Otto, A. Milenkovic, C. Sanders e E. Jovanov. System architecture of a wireless body area sensor network for ubiquitous health monitoring. *Journal of Mobile Multimedia*, 1(4):307–326, 2006.

- [87] Amir Padovitz, Arkady Zaslavsky, Seng Wai Loke e Bernard Burg. Maintaining continuous dependability in sensor-based context-aware pervasive computing systems. In *System Sciences*, p. 290.1, Washington, EUA, 2005.
- [88] F. Paganelli, E. Spinicci e D. Giuli. ERMHAN: a context-aware service platform to support continuous care networks for home-based assistance. *International Journal of Telemedicine and Applications*, 2008:1–13, 2008.
- [89] W. Pentney, A. M. Popescu, S. Wang, H. Kautz e M. Philipose. sensor-based understanding of daily life via large-scale use of common sense. In *Proceedings of American Association for Artificial Intelligence*, Boston, EUA, 2006.
- [90] A. Pitsillides, G. Samaras, B. Pitsillides, D. Georgiades, P. Andreou e E. Christodoulou. Virtual collaborative healthcare teams for home healthcare. *Journal of Mobile Multimedia*, 2(1):23–36, 2006.
- [91] M. E. Pollack. Intelligent technology for an aging population: the use of ai to assist elders with cognitive impairment. *Artificial Intelligence Magazine*, 26(2):9–24, 2005.
- [92] J. Pärkkä, J. Merilahti, E. M. Mattila, E. Malm, K. Antila, M. T. Tuomisto, A. V. Saarinen, M. van Gils e I. Korhonen. Relationship of psychological and physiological variables in long-term self-monitored data during work ability rehabilitation program. *Information Technology in Biomedicine*, 13(2):141–151, 2009.
- [93] C. Ramos, J. C. Augusto e D. Shapiro. Ambient intelligence—the next step for artificial intelligence. *IEEE Intelligent Systems*, 23(2):15–18, 2008.
- [94] A. Ranganathan, J. Al-Muhtadi e R. H. Campbell. Reasoning about uncertain contexts in pervasive computing environments. *IEEE Pervasive Computing*, pp. 62–70, 2004.
- [95] S. Rezende. *Sistemas Inteligentes: fundamentos e aplicações*. Editora Manole Ltda, 2003.
- [96] A. C. Rice e A. R. Beresford. Dependability and accountability for context-aware middleware systems. In *Pervasive Computing and Communications Workshops*, pp. 5–382. IEEE, 2006.
- [97] T. Ross. *Fuzzy logic with engineering applications*. McGraw-Hill, Nova Iorque, EUA, 1995.
- [98] G. Roussos e A. Marsh. A blueprint for pervasive self-care infrastructures. In *Pervasive Computing and Communications Workshops*, p. 479, Washington, EUA, 2006. IEEE Computer Society.
- [99] J. Ruscio e N. Haslam. *Introduction to the Taxometric Method: A Practical Guide*. Lawrence Erlbaum, 2006.
- [100] SBC. Sociedade Brasileira de Cardiologia. IV Diretriz para uso da Monitorização Ambulatorial da Pressão Arterial. II Diretriz para uso da Monitorização Residencial da Pressão Arterial. *Arquivos Brasileiros de Cardiologia*, 85(Supl II):1–18, 2005.

- [101] SBC. V Diretrizes Brasileiras de Hipertensão Arterial. *Arquivos Brasileiros de Cardiologia*, 89(3):1–56, 2007.
- [102] SBC. VI Diretrizes Brasileiras de Hipertensão. *Arquivos Brasileiros de Cardiologia*, 95(1 supl. 1):1–51, 2010.
- [103] C. Scanaill, S. Carew, P. Barralon, N. Noury, D. Lyons e G. Lyons. A review of approaches to mobility telemonitoring of the elderly in their living environment. *Annals Biomedical Engineering*, 34(4):547–563, 2006.
- [104] S. Sneha e U. Varshney. Enabling ubiquitous patient monitoring: model, decision protocols, opportunities and challenges. *Decision Support Systems*, 46(3):606–619, 2009.
- [105] J. A. Stankovic. When sensor and actuator networks cover the world. *ETRI Journal*, 30(5):627–633, 2008.
- [106] J. A. Stankovic, Q. Cao, T. Doan., L. Fang, Z. He, R. Kiran, S. Lin, S. Son, R. Stoleru e A. Wood. Wireless sensor networks for in-home healthcare: potential and challenges. In *High Confidence Medical Device Software and Systems (HCMDSS) Workshop*, Philadelphia, EUA, 2005.
- [107] A. Sztajnberg, A. L. B. Rodrigues, L. N. Bezerra, O. G. Loques, A. Copetti e S. T. Carvalho. Applying context-aware techniques to design remote assisted living applications. *International Journal of Functional Informatics and Personalised Medicine*, 2(4):358–378, 2009.
- [108] H. Takagi. Integration of fuzzy systems and neural networks, and fuzzy systems and genetic algorithms. *Hybrid Intelligent Engineering Systems*, p. 11, 1997.
- [109] S. Thiemjarus e G. Yang. *Body Sensor Networks*, chapter Context-aware sensing, pp. 287–331. Springer-Verlag, 2006.
- [110] M. G. Tsipouras, C. Voglis e D. I. Fotiadis. A framework for fuzzy expert system creation-application to cardiovascular diseases. *IEEE Transactions on Biomedical Engineering*, 54(11):2089, 2007.
- [111] K. J. Turner, G. A. Campbell e F. Wang. Policies for sensor networks and home care networks. In *New Technologies for Distributed Systems*, pp. 273–284, 2007.
- [112] P. Vajirkar, S. Singh e Y. Lee. Context-aware data mining framework for wireless medical application. *Lecture Notes in Computer Science*, 2736:381–391, 2003.
- [113] M. J. van Sinderen, A. T. van Halteren, M. Wegdam, H. B. Meeuwissen e E. H. Eertink. Supporting context-aware mobile applications: an infrastructure approach. *IEEE Communications Magazine*, 44(9):96–104, 2006.
- [114] L. M. Vaquero, L. R. Merino, J. Caceres e M. Lindner. A break in the clouds: towards a cloud definition. *SIGCOMM Comput. Commun. Rev.*, 39(1):50–55, 2009.
- [115] A. Veselý, J. Zvárová, J. Peleska, D. Buchtela e Z. Anger. Medical guidelines presentation and comparing with electronic health record. *International Journal of Medical Informatics*, 75(3–4):240–245, 2006.

- [116] V. Vieira, P. Tedesco, A. C. Salgado e P. Brézillon. Investigating the specifics of contextual elements management: the CEManTIKA approach. In B. Kokinov et ali, editor, *Interdisciplinary Conference on Modeling and Using Context*, volume 4635 of *Lecture Notes in Computer Science*, pp. 493–506, Roskilde, Dinamarca, 2007.
- [117] F. Wang, L. S. Docherty, K. J. Turner, M. Kolberg e E. H. Magill. Services and policies for care at home. In *Pervasive Computing Technologies for Healthcare*, pp. 7.1–7.10, Aberdeen, Reino Unido, 2006.
- [118] Q. Wang, W. Shin, B. Alshebli, M. Caccamo, C. Gunter, E. Gunter, J. Hou, K. Karahalios, X. Liu, C. Oh, L. Sha e Z. Zeng. An open system architecture for assisted living. In *IEEE Transactions on Systems, Man and Cybernetics*, Taipei, Taiwan, 2006.
- [119] M. Weiser. The computer for the twenty-first century. In *Scientific American*, volume 265, pp. 94–104, 1991.
- [120] A. Wood, G. Virone, T. Doan, Q. Cao, L. Selavo, Y. Wu, L. Fang, Z. He, S. Lin e J. Stankovic. Alarm-net: wireless sensor networks for assisted-living and residential monitoring. Technical Report 7, Department of Computer Science, University of Virginia, 2006.
- [121] L. A. Zadeh. Fuzzy sets. *Information and Control*, 8(3):338–353, 1965.
- [122] S. Zhang, S. McClean, B. Scotney, P. Chaurasia e C. Nugent. Using duration to learn activities of daily living in a smart home environment. In *Pervasive Computing Technologies for Healthcare (PervasiveHealth)*, pp. 1–8, 22-25 2010.
- [123] G. Zhou, C. Wan, M. D. Yarvis e J. A. Stankovic. Aggregator-centric QoS for body sensor networks. In *Information Processing in Sensor Networks*, pp. 539–540, Nova Iorque, NY, EUA, 2007.
- [124] B. Ziebart, D. Roth, R. Campbell e A. Dey. Learning automation policies for pervasive computing environments. *Autonomic Computing*, pp. 193–203, 2005.



# Livros Grátis

( <http://www.livrosgratis.com.br> )

Milhares de Livros para Download:

[Baixar livros de Administração](#)

[Baixar livros de Agronomia](#)

[Baixar livros de Arquitetura](#)

[Baixar livros de Artes](#)

[Baixar livros de Astronomia](#)

[Baixar livros de Biologia Geral](#)

[Baixar livros de Ciência da Computação](#)

[Baixar livros de Ciência da Informação](#)

[Baixar livros de Ciência Política](#)

[Baixar livros de Ciências da Saúde](#)

[Baixar livros de Comunicação](#)

[Baixar livros do Conselho Nacional de Educação - CNE](#)

[Baixar livros de Defesa civil](#)

[Baixar livros de Direito](#)

[Baixar livros de Direitos humanos](#)

[Baixar livros de Economia](#)

[Baixar livros de Economia Doméstica](#)

[Baixar livros de Educação](#)

[Baixar livros de Educação - Trânsito](#)

[Baixar livros de Educação Física](#)

[Baixar livros de Engenharia Aeroespacial](#)

[Baixar livros de Farmácia](#)

[Baixar livros de Filosofia](#)

[Baixar livros de Física](#)

[Baixar livros de Geociências](#)

[Baixar livros de Geografia](#)

[Baixar livros de História](#)

[Baixar livros de Línguas](#)

[Baixar livros de Literatura](#)  
[Baixar livros de Literatura de Cordel](#)  
[Baixar livros de Literatura Infantil](#)  
[Baixar livros de Matemática](#)  
[Baixar livros de Medicina](#)  
[Baixar livros de Medicina Veterinária](#)  
[Baixar livros de Meio Ambiente](#)  
[Baixar livros de Meteorologia](#)  
[Baixar Monografias e TCC](#)  
[Baixar livros Multidisciplinar](#)  
[Baixar livros de Música](#)  
[Baixar livros de Psicologia](#)  
[Baixar livros de Química](#)  
[Baixar livros de Saúde Coletiva](#)  
[Baixar livros de Serviço Social](#)  
[Baixar livros de Sociologia](#)  
[Baixar livros de Teologia](#)  
[Baixar livros de Trabalho](#)  
[Baixar livros de Turismo](#)