



UNIVERSIDADE FEDERAL DO AMAZONAS  
INSTITUTO DE COMPUTAÇÃO  
DOUTORADO EM INFORMÁTICA

# Sistema Integrado de Mensagens para Auxiliar na Aderência à Medicação

Vandermi João da Silva

Manaus – AM  
Outubro de 2018

Vandermi João da Silva

## Sistema Integrado de Mensagens para Auxiliar na Aderência à Medicação

Tese de Doutorado submetida à Banca Examinadora apresentada ao Programa de Pós-Graduação em Informática da Universidade Federal do Amazonas, como requisito parcial para obtenção do título de Doutor em Informática, área de concentração: Ciência da Computação.

Orientador

Prof. Dr. -Ing. Vicente Ferreira de Lucena Júnior

Universidade Federal do Amazonas – UFAM

Instituto de Computação – IComp

Manaus – AM

Outubro de 2018

### Ficha Catalográfica

Ficha catalográfica elaborada automaticamente de acordo com os dados fornecidos pelo(a) autor(a).

S586s Silva, Vandermi João da  
Sistema Integrado de Mensagens para Auxiliar na Aderência à  
Medicação / Vandermi João da Silva. 2018  
110 f.: il. color; 31 cm.

Orientador: Vicente Ferreira de Lucena Júnior  
Tese (Doutorado em Informática) - Universidade Federal do  
Amazonas.

1. Ambientes inteligentes. 2. Contexto da Informação. 3. Adesão  
a medicamentos. 4. Healthcare. I. Lucena Júnior, Vicente Ferreira  
de II. Universidade Federal do Amazonas III. Título



PODER EXECUTIVO  
MINISTÉRIO DA EDUCAÇÃO  
INSTITUTO DE COMPUTAÇÃO

PROGRAMA DE PÓS-GRADUAÇÃO EM INFORMÁTICA



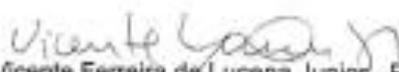
UFAM

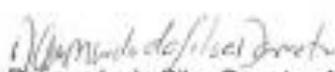
## FOLHA DE APROVAÇÃO

**"Sistema Integrado de Mensagens para Auxiliar na Aderência à  
Medicação"**

**VANDERMI JOÃO DA SILVA**

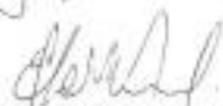
Tese de Doutorado defendida e aprovada pela banca examinadora constituída pelos Professores:

  
Prof. Vicente Ferreira de Lucena Junior - PRESIDENTE

  
Prof. Raimundo da Silva Barreto - MEMBRO INTERNO

  
Prof. Eduardo James Pereira Scoto - MEMBRO INTERNO

  
Prof. José Parente de Oliveira - MEMBRO EXTERNO

  
Prof. Eduardo Lázaro Martins Naves - MEMBRO EXTERNO

Manaus, 08 de Outubro de 2018

## Agradecimentos

A Deus o grande criador e arquiteto do universo que oferece o ar que eu respiro e a minha saúde perfeita para suportar as adversidades da vida. Aos meus familiares, pelo apoio dado durante este trabalho e por acreditarem em meu potencial. A todos os meus amigos que torcem por mim. Aos meus alunos do curso de Sistemas de Informação, Engenharia de Software e Engenharia de Produção do ICET-UFAM especialmente a turma do laboratório 303 PiXgo e 301 PCTIS, vocês tem meu apreço e minha consideração. A todos os professores e a coordenação técnica do Programa de Doutorado em Informática da UFAM por contribuírem direta e indiretamente para minha formação acadêmica. Ao professor Raimundo Barreto, pelo apoio dado durante o trabalho. A meu amigo e Irmão Fagner Cunha pela ajuda e apoio moral. Ao meu orientador, professor Vicente Ferreira de Lucena Junior, por todo suporte dado durante o Doutorado, principalmente pelas cobranças dos artigos científicos, que contribuíram para minha formação acadêmica. Ao CNPq, CAPES, FAPEAM, UFAM, CETELI e SAMSUNG, pelo apoio financeiro por meio de bolsa de estudo e laboratórios pra desenvolvimento da pesquisa.

*Não é preciso ter olhos abertos para ver o sol, nem é preciso ter ouvidos afiados para ouvir o trovão. Para ser vitorioso você precisa ver o que não está visível.*

Sun Tzu

# Sistema Integrado de Mensagens para Auxiliar na Aderência à Medicação

Autor: Vandermi João da Silva

Orientador: Prof. Dr. -Ing. Vicente Ferreira de Lucena Júnior

## RESUMO

O uso do contexto em aplicações interativas é cada vez mais presente e necessita de um estudo mais aprofundado especialmente nos casos em que os cenários estão em constantes mudanças, por exemplo, os que envolvem *Ambient Intelligence* (Aml) e computação ubíqua. Os sistemas de automação tradicionais necessitam da intervenção humana e muitas vezes devem ser pré-ajustados usando controles remotos ou mesmo por aplicativos embarcados em dispositivos móveis. No entanto, o contexto do ambiente e preferências do usuário não é levado em consideração. Um sistema que integre os serviços de *healthcare* necessita acessar diversas bases de dados e a maioria não é contextualizada, dificultando assim a agregação de serviços personalizados a cada usuário do sistema. Técnicas de inteligência computacional e computação ubíqua somada a uma base de dados contextual podem facilitar a disponibilização de serviços customizados de acordo com as características do usuário e dados provenientes de sensores. Este trabalho tem como objetivo especificar, construir e validar um Sistema Integrado de Mensagens para Auxiliar na Aderência à Medicação baseado em dados contextualizados de pacientes, por meio de um sistema automatizado, que considera os dados da receita médica, o ambiente e os dados de sensores e de dispositivos móveis da residência. O sistema possui uma camada de razão composta por algoritmos de árvore de decisão para auxiliar médicos e equipes de saúde no acompanhamento da adesão de medicamentos com acurácia de 96%.

*Palavras-chave:* Ambientes inteligentes, contexto da informação, adesão a medicamentos, *healthcare*.

# Integrated Messaging System to Assist in Adherence to Medication

Author: Vandermi João da Silva

Advisor: Prof. Dr. –Ing. Vicente Ferreira de Lucena Júnior

## ABSTRACT

The use of context and interactive applications is increasingly present and needs further study especially where the scenarios are constantly changing, for example, those involving Ambient Intelligence (AmI) and ubiquitous computing. Traditional automation systems require human intervention and often must be preset using remote controls or even embedded applications on mobile devices. However, the environmental context and user preferences are not taken into consideration. A system that integrates the healthcare services, entertainment, health and safety, among others, need to access several databases and most are not contextualized, hindering the aggregation of personalized services to each system user. Computational intelligence techniques and ubiquitous computing coupled with a contextual database can facilitate the provision of customized services according to user characteristics and data from sensors. The aim of this work is to specify, develop and validate a Patient Information System to assist in the contextualized medical data of patients, through an automated system, which considers medical prescription data, environment and sensor and device data furniture of the residence. The system counts with a template of measures for health and auxiliary of nursing to follow up of 96%.

*Keywords:* Ambient intelligence, context-aware information, medicine adherence, healthcare.

## Lista de figuras

Figura 1. Descrição do Cenário para o Problema. ....	21
Figura 2. Fluxo da metodologia do trabalho .....	26
Figura 3. Gráfico demonstrando a quantidade de artigos na área de pesquisa.....	28
Figura 4. Visão geral de AmI na perspectiva de IA.....	31
Figura 5. Visão geral das aplicações m-health integradas à cidades inteligentes ..	34
Figura 6. Espaço de objetos classificados em duas classes.....	36
Figura 7. Fluxo do processo de um aprendizado de máquina supervisionado.....	37
Figura 8. Um cenário básico de aprendizado por reforço. ....	39
Figura 9. Gráfico da curva ROC dos resultados de um Classificador.....	44
Figura 10. DOMOSEC´s Plataforma para sistemas de domótica. ....	48
Figura 11. Caso de uso para um sistema de redes de sensores inteligente. ....	49
Figura 12. Gráfico com a avaliação e comparação das duas fases do experimento.	51
Figura 13. Combinações de atividades individuais. ....	52
Figura 14. Exemplo de uma requisição feita com base nas informações de contexto. .....	54
Figura 15. Arquitetura do RuCAS. ....	54
Figura 16. Arquitetura do sistema de lembretes.....	57
Figura 17. Fluxo do processo de coleta, treinamento e detecção da adesão .....	58
Figura 18. Etapas do Sistema de Detecção .....	59
Figura 19. Visão Geral da Arquitetura.....	64
Figura 20. Exemplo de um encadeamento de regras.....	69
Figura 21. Algoritmo genérico para árvore de decisão.....	71
Figura 22. Árvore de decisão para o problema de tomada de medicamentos.....	72
Figura 23. Armário de medicamentos e protótipo de coleta de dados.....	75
Figura 24. Protótipos desenvolvidos para coleta de dados.....	76

Figura 25. Informação do padrão de ingestão do medicamento acessado via web...	77
Figura 26. Conteúdo da mensagem SMS em XML.....	78
Figura 27. Mensagem enviada pelo aplicativo Telegram.....	78
Figura 28. Modelo para envio de Mensagens SMS.....	79
Figura 29. Modelo de envio de mensagens para a TVDi.....	80
Figura 30. Integração dos subsistemas com a Arquitetura.....	81
Figura 31. Parte da base de dados preparada para os experimentos.....	86
Figura 32. Interface Gráfica da ferramenta de mineração de dados.....	87
Figura 33. Gráfico de barras que apresentam o desempenho dos algoritmos.....	89
Figura 34. Gráfico Split 50% da base de dados para treinamento.....	90
Figura 35. Gráfico contendo os resultados do Split com 70% da base de dados .....	91
Figura 36. Gráfico contendo os resultados do Split com 80% da base de dados .....	92
Figura 37. Gráfico contendo a média dos erros quadráticos dos algoritmos avaliados.....	93
Figura 38. Gráfico demonstrando os algoritmos testados.....	99
Figura 39. Gráfico que demonstra os valores do índice phi para cada algoritmo testado.....	99

## Lista de tabelas

Tabela 1. Resultado geral de publicações referentes ao tema.....	28
Tabela 2. Exemplo de uma Matriz de Confusão.....	43
Tabela 3. Comparação entre os trabalhos relacionados e a Tese.....	62
Tabela 4. Uma amostra do conjunto de dados da prescrição eletrônica. ....	67
Tabela 5. Representação dos dados de acesso à residência e ao armário de medicamentos. ....	68
Tabela 6. Tecnologias de Hardware utilizadas nos Experimentos .....	85
Tabela 7. Resultado dos testes com Cross-Validation .....	88
Tabela 8. Resultado dos testes usando 50% da base de dados para treinamento.....	89
Tabela 9. Resultado dos testes com 70% da base de dados .....	90
Tabela 10. Resultados dos testes com 80% da base de dados .....	91
Tabela 11. Extrato da base de dados com os dados brutos e não classificados. ....	94
Tabela 12. Extrato da base de dados já classificada .....	94
Tabela 13: Resultado dos testes com validação cruzada .....	95
Tabela 14: Resultado dos testes com 70% da base para treinamento .....	95
Tabela 15. Resultado dos algoritmos escolhidos para a camada de decisão. ....	98

## Lista de abreviaturas e siglas

AmI	<i>Ambient Intelligence</i>
IoT	<i>Internet of Things</i>
TI	<i>Tecnologia da Informação</i>
IP	<i>Internet Protocol</i>
TVDi	<i>Televisão Digital Interativa</i>
GR	<i>Gateway Residencial</i>
RFID	<i>Radio Frequency Identification</i>
DAB	<i>Departamento de Atenção Básica a saúde</i>
UN	<i>Nações Unidas</i>
IBGE	<i>Instituto Brasileiro de Geografia e Estatística</i>
MS	<i>Ministério da Saúde</i>
UBS	<i>Unidades Básicas de Saúde</i>
IEEE	<i>Institute of Electrical and Electronic Engineers</i>
KNN	<i>k-Nearest Neighbors</i>
ACM	<i>Association for Computing Machinery</i>
CETELI	<i>Centro de P&amp;D em Tecnologia Eletrônica da Informação</i>
IA	<i>Inteligência Artificial</i>
m-health	<i>Mobile Healthcare</i>
ECG	<i>Eltrocardiograma</i>
AM	<i>Aprendizado de Máquina</i>
ID3	<i>Iterative Dichotomiser 3</i>
AR	<i>Aprendizado por Reforço</i>
ROC	<i>Receiver Operating Characteristic Curve</i>
WHO	<i>World Health Organization</i>
HTTP	<i>Hypertext Transfer Protocol</i>
UDP	<i>User Datagram Protocol</i>
SHAP	<i>Superior Home Automation</i>
TCP	<i>Transmission Control Protocol</i>
IP	<i>Internet Protocol</i>
FPGA	<i>Field Programmable Gate Array</i>
POOSL	<i>Parallel Object-Oriented Specification Language</i>
SVM	<i>Support Vector Machines</i>

<i>SMS</i>	<i>Short Message Service</i>
<i>XML</i>	<i>Extensible Markup Language</i>
<i>USB</i>	<i>Universal Serial Bus</i>
<i>JVM</i>	<i>Java Virtual Machine</i>
<i>GSM</i>	<i>Global System for Mobile Communications</i>
<i>NCL</i>	<i>Nested Context Language</i>
<i>LUA</i>	<i>Linguagem de Programação LUA</i>
<i>STB</i>	<i>Set top Box para Tv digital</i>

# Sumário

<b>Capítulo 1 Introdução .....</b>	<b>17</b>
1.1 Contextualização .....	17
1.2 Problema de Pesquisa.....	19
1.3 Cenários para o Entendimento do Problema .....	21
1.3.1 Cenário para um Paciente Idoso Hipertenso.....	21
1.3.2 Cenário para um Médico Especialista.....	22
1.3.3 Considerações Sobre os Cenários Apresentados .....	22
1.4 Motivação.....	23
1.5 Objetivo Geral .....	24
1.5.1 Objetivos Específicos.....	24
1.6 Metodologia de Desenvolvimento da Pesquisa .....	25
1.7 Organização do Trabalho .....	29
<b>Capítulo 2 Referencial Teórico .....</b>	<b>30</b>
2.1 Ambientes Inteligentes.....	30
2.1.1 Principais Áreas de Aplicações de AmI.....	31
2.2 Context-aware.....	32
2.2.1 Características de Contexto.....	32
2.5 Aprendizado de Máquina.....	35
2.5.1 Tipos de Aprendizado de Máquina .....	36
2.5.2 Algoritmos de AM Baseados em Buscas.....	39
2.6 Medidas de Desempenho em AM.....	43
2.7 Adesão a Medicamentos .....	44
2.7.1 Taxa de Adesão a Medicamentos .....	45
2.8 Considerações Finais sobre o Capítulo.....	46

<b>Capítulo 3 Trabalhos Relacionados</b> .....	<b>47</b>
3.1 DOMOSEC´s Plataforma para Sistemas de Domótica .....	47
3.2 Assistente Pervasivo para Médicos e Enfermeiros .....	48
3.3 Análise e Modelagem de Redes de Sensores em AmI .....	49
3.4 Ambientes Inteligentes e Tecnologias de Agentes .....	50
3.5 Modelagem de Situações em Casas Inteligentes.....	51
3.6 Framework para Gerenciamento de Contexto Baseado em Web Services Heterogêneos.....	53
3.7 Armário de Medicamentos Inteligente para Auxiliar na Adesão.....	55
3.8 MediFrame: Uma Aplicação para Lembretes Planejamento e Acompanhamento de Idosos .....	55
3.9 Sistema de Lembretes Móvel para Promover a Adesão do Paciente ao Tratamento .....	56
3.10 Uma Abordagem de AM para Monitorar a Adesão .....	57
3.11 Classificação de Uso de Medicamentos em Redes Sociais.....	58
3.12 Melhoria da Acurácia da Predição em Árvore de Decisão .....	59
3.13 Contribuições dos Trabalhos Relacionados .....	60
3.14 Considerações Finais sobre o Capítulo .....	63
<b>Capítulo 4 Concepção da Arquitetura</b> .....	<b>64</b>
4.1 Visão Geral da Arquitetura.....	64
4.2 Camada de Entrada de Dados.....	65
4.3 Camada de Pré-processamento.....	65
4.3.1 Análise e Filtros .....	66
4.3.2 Conjunto de Dados .....	66
4.4 Camada de Inteligência.....	69
4.4.1 Regras de Decisão .....	69
4.4.2 Modelos de Decisão ou Classificação.....	70

4.5 Camada de Serviços .....	73
4.6 Desenvolvimento dos Protótipos Baseados na Arquitetura .....	73
4.6.1 Gateway Residencial .....	74
4.6.2 Protótipo para Coleta e Armazenamento de Dados.....	74
4.6.3 Protótipo Desenvolvido para a TV Digital e <i>Smartphone</i> .....	76
4.6.4 Modelo de Comunicação Desenvolvido para a TVDi, Web e Smartphone .	77
4.6.5 Integração dos Protótipos do Sistema .....	80
4.6 Considerações Finais sobre o Capítulo.....	82
<b>Capítulo 5 Experimentos Realizados.....</b>	<b>84</b>
5.1 Protocolo Experimental.....	84
5.1.1 Ambiente de Experimentação e Tecnologias Utilizadas.....	84
5.1.2 Base de Dados e Ferramenta de Mineração .....	85
5.2 Execução dos Experimentos e Análise dos Resultados.....	87
5.2.1 Experimento Inicial para a Escolha dos algoritmos da Camada de Inteligência .....	88
5.2.2 Experimento com Envio de Mensagens .....	93
<i>Avaliação dos Resultados dos Algoritmos</i> .....	94
<i>Considerações sobre o Experimento</i> .....	95
5.2.3 Experimento Usando a Abordagem de Votação entre os Algoritmos. ....	96
<i>Resultados com o Algoritmo J48</i> .....	97
<i>Resultados com o Algoritmo RandomTree</i> .....	97
<i>Resultados com o Algoritmo RepTree</i> .....	97
<i>Avaliação do Experimento</i> .....	98
5.3 Considerações Finais sobre o Capítulo.....	100
<b>Capítulo 6 Conclusão.....</b>	<b>101</b>
6.1 Contribuições deste Trabalho .....	103
6.2 Limitações e Trabalhos Futuros .....	104

<b>Referências .....</b>	<b>105</b>
<b>Apêndice .....</b>	<b>111</b>
<b>Principais publicações.....</b>	<b>111</b>

# Capítulo 1 Introdução

## 1.1 Contextualização

O uso de dados de contexto em aplicações interativas se faz necessário no cenário tecnológico e necessita ser estudado mais profundamente, especialmente nos casos em que os sistemas estão em constantes mudanças, por exemplo, os que envolvem AmI, computação ubíqua e *context-aware*, (ABOWD et al., 1997). Ambientes inteligentes estão inseridos na vida das pessoas por meio de dispositivos móveis, da domótica e de sistemas de automação inteligentes.

No cenário atual, o conceito de coisas conectadas está em pleno desenvolvimento e diversos dispositivos estão sendo preparados para interagir com a rede mundial de computadores. *A Internet of Things*, (IoT) emergiu da internet convencional como uma arquitetura que facilita a troca de dados e serviços entre dispositivos conectados e propõe uma infraestrutura de Tecnologia da Informação (TI) em que objetos troquem informações na rede de forma segura e facilitada (WEBER, 2010).

Os ambientes baseados em IoT permitem que qualquer dispositivo ou eletrodoméstico de uma residência possa receber um endereço de *Internet Protocol* (IP) e então se comunicar com a WEB, permitindo o controle de dispositivos local ou remotamente. É possível que os ambientes conectados usem as tecnologias de redes atuais e acessem serviços de utilidade pública tais como, agendamentos de visita médica, alarmes de diversos tipos, envio de mensagens automáticas, entre outros, e os disponibilize para equipes de saúde e pacientes. Por exemplo, a Televisão Digital Interativa (TVDi) e as *smart tv* podem receber eventos personalizados pelo usuário e executar pequenas tarefas em conjunto com outros eletrodomésticos da casa, desde que esses dispositivos estejam integrados e conectados à rede de computadores.

Um sistema que integre os serviços de *healthcare* necessita acessar diversas bases de dados e a maioria não é contextualizada, dificultando

assim a agregação de serviços personalizados a cada usuário do sistema. Técnicas de aprendizado de máquina somadas a uma base contextual facilitarão a disponibilização de serviços customizados de acordo com as características do usuário por meio de sensores e dispositivos instalados na residência.

Por exemplo, um serviço disponibilizado a um usuário por meio de um sistema integrado de *healthcare*, com eletrodomésticos e *smartphone*, pode estar disponível em uma *smart tv* ou TVDi, sincronizando avisos para um paciente ingerir medicamentos nos horários corretos. Os alertas provenientes de sensores de uma residência conectados a um *Gateway Residencial* (GR) e com acesso à nuvem possibilitam que diversas aplicações acessem informações remotamente.

Uma das atividades principais em *Ambience Intelligence* (AmI) e ciência do contexto (*context-aware*) é a localização de usuários em um determinado ambiente do termo em inglês *indoor location*. Essa técnica descrita em (CHAI, 2007), permite o uso de tecnologias de redes sem fio para verificar o posicionamento de pessoas em um ambiente, utilizando *Radio Frequency Identification* (RFID) e outras tecnologias, tais como os padrões *Bluetooth*, IEEE 802.15.1, e *ZigBee*, IEEE 802.15.4.

Nos trabalhos de Chai (2007) e Honkavirta (2009) são apresentados os conceitos e as principais técnicas para localização, que consiste basicamente em utilizar a triangulação do sinal de rádio, e aplicar algoritmos da vizinhança mais próxima *k-Nearest Neighbors* (KNN) seguido de modificações do algoritmo aplicando técnicas de predição baseadas nos locais mais comuns que o usuário esteve, coletadas por meio de dispositivos móveis. Também é utilizado o mapeamento de pontos de referência para ser aplicado na base de treinamento de um sistema de localização por meio de técnicas baseadas em filtros de *Kalman* (ALI-LOYTTY, 2009).

Em um ambiente inteligente o contexto da informação, como localização do indivíduo, suas ações, comportamentos e interação com os objetos que o cercam, podem ser armazenados em uma base de dados que, após analisada e processada servirá para sistemas de recomendação (ADOMAVICIUS, 2011).

Para que isso aconteça é necessário que uma nova abordagem de sistema considere as informações contextuais e seja capaz de acessar os dados de localização de sistemas de localização existentes para construir ou aprimorar os serviços de *healthcare*, tais como os de adesão a medicamentos prescritos com intuito de monitorar o padrão de ingestão e auxiliar na tomada de decisão das equipes de saúde quando esse padrão for modificado.

Serviços baseados em dados comuns a diversos sistemas podem dificultar o gerenciamento das informações e muitas vezes levar a inconsistências, informações incorretas ou incompletas (STRONG, 1997). Para minimizar esse problema é necessário um sistema que concentre os dados os recupere e os valide por meio de uma base de regras e algoritmos de decisão.

## 1.2 Problema de Pesquisa

Existem diversos desafios para conceber um método que integre vários sistemas, principalmente quando se leva em consideração as informações contextuais. Nesse caso, os dados contextualizados podem melhorar a precisão da informação e auxiliar outros sistemas especialistas e podem ser coletados a partir de dispositivos móveis e de sensores projetados para este fim.

Um desafio importante a ser observado na arquitetura e na construção de um sistema baseado em contexto, são os requisitos dessa modalidade de sistema. Nestes casos, são considerados dados de aquisição, recomendação, reconhecimento e inferências em informações provenientes de sensores, eletrodomésticos, etc. (OTEBOLAKU, 2014).

Uma aplicação reativa ao contexto integrada a um sistema de *healthcare* possibilitaria que um smartphone transporte informações de receitas médicas de um sistema maior para a residência do usuário. Tal sistema acessaria as informações de uma receita médica online por meio de dispositivos móveis, armazenaria a receita em uma base de dados para mais tarde atualizar um armário de medicamentos inteligente, gerenciado por um GR.

Todos esses equipamentos podem no futuro ser instalados na residência do usuário considerando que os problemas de infraestrutura tais como, conexão com a internet, cabeamento lógico e redes sem fio sejam resolvidos.

Identificar corretamente o comportamento do usuário no ambiente em que está inserido, não é uma tarefa trivial, uma vez que diversas atividades de outros usuários ocorrem em paralelo (HAGRAS et al., 2004). Nesse caso há a necessidade de analisar as entradas de dados comportamentais do usuário, por exemplo, horário de chegada à residência, horário de saída, horário de ingestão de medicamentos, acompanhamento do status da receita, etc.

Os sistemas tradicionais necessitam da intervenção humana e muitas vezes devem ser pré-ajustados usando controles remotos ou mesmo aplicativos embarcados em dispositivos móveis. No entanto, em muitos deles, o contexto do ambiente e as preferências do usuário não são considerados.

Preparar um ambiente residencial conectado e oferecer serviços personalizados de forma transparente ao usuário esbarra em uma problemática investigada neste trabalho, apresentada a seguir.

*Como integrar a infraestrutura residencial existente aos dispositivos móveis e sistemas de healthcare, considerando um modelo de tratamento e armazenamento de dados e mensagens para auxiliar na adesão da medicação?*

A partir desse questionamento faz-se necessário a construção da hipótese para ser confrontada no decorrer deste trabalho.

H1 – É possível que um ambiente residencial provido de uma infraestrutura de redes interconectadas, auxilie na aplicação de serviços de mensagens eletrônicas para acompanhar a adesão a medicamentos de pacientes em tratamento na residência.

Para que H1 seja verdadeira, verifica-se a necessidade de modelar as informações das ações provenientes de sensores e dispositivos instalados na

residência e do comportamento do usuário por meio de cenários.

### 1.3 Cenários para o Entendimento do Problema

Para entender melhor a problemática tratada neste trabalho de pesquisa foram desenvolvidos dois cenários apresentados a seguir, exemplificados pela Figura 1.

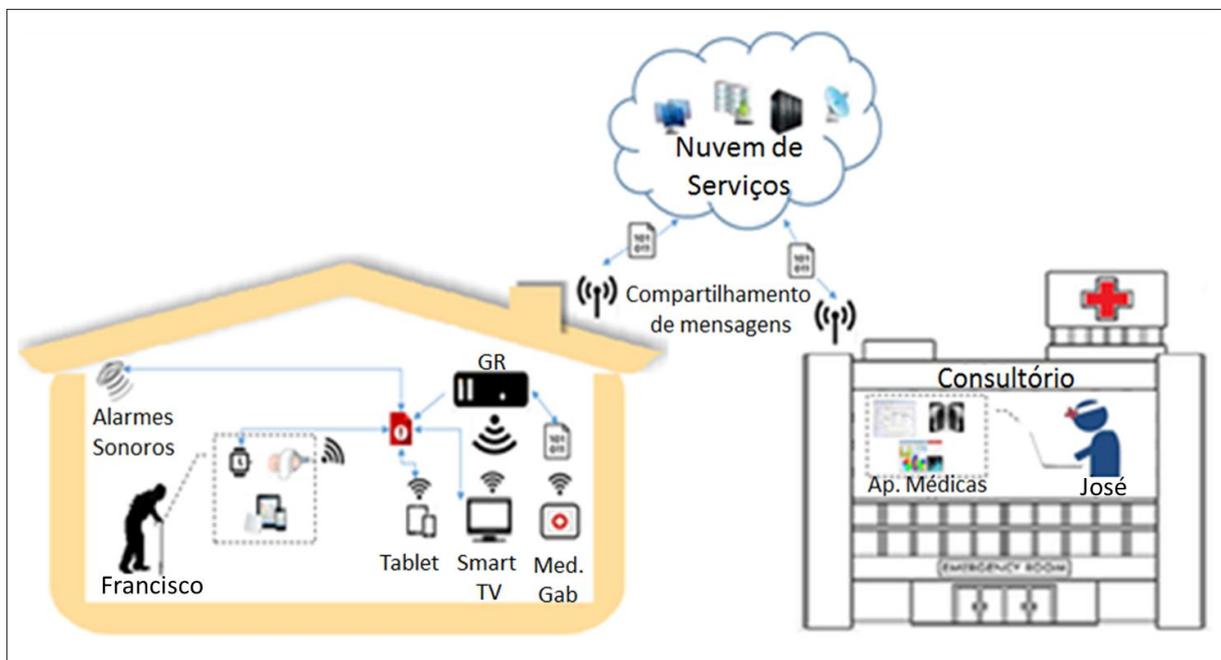


Figura 1. Descrição do Cenário para o Problema.  
Fonte: Elaborado pelo Autor.

#### 1.3.1 Cenário para um Paciente Idoso Hipertenso

Francisco, um paciente idoso hipertenso, não consegue tomar seus remédios prescritos pelo médico nos horários corretos como discriminados na receita. Isso ocorre porque Francisco se esquece de tomar seus medicamentos nos horários pré-determinados ocasionando a diminuição dos efeitos durante o tratamento.

O médico de Francisco possui um sistema que registra a receita a partir dos dados do paciente, mas não gera lembretes para que o paciente tome o remédio na hora certa. Pensando em Francisco e em vários pacientes nesta mesma situação, uma empresa desenvolveu um sistema inteligente para

criar lembretes a partir dos dados da receita de forma autônoma e distribuí-los aos diversos dispositivos da residência do paciente.

O sistema consiste em um arcabouço de tecnologias que integram um armário de medicamentos automatizado e um servidor de dados e de aplicações que recebe as receitas atualizadas via *smartphone* e gera os alarmes específicos para os dispositivos da residência.

### 1.3.2 Cenário para um Médico Especialista

Doutor José, é um médico especialista em problemas cardíacos e utiliza um sistema de prontuário médico para acompanhamento de pacientes que frequentam seu consultório. José sempre tem dificuldade em acompanhar o tratamento de seus pacientes, principalmente no caso de pacientes idosos. O maior problema é quanto ao esquecimento da tomada de medicamentos nos horários prescritos na receita. José precisa saber se realmente os remédios foram tomados ou não e qual a frequência que isso ocorre. Ele gostaria de interagir com o paciente para melhorar a adesão aos medicamentos receitados. José também gostaria de ter a possibilidade de acessar um relatório da adesão dos medicamentos por meio de nuvem de dados para posteriormente fazer intervenções no tratamento quando fosse necessário.

### 1.3.3 Considerações Sobre os Cenários Apresentados

Os cenários um e dois apresentados são distintos, nele se vê a interação entre dois sistemas integrados em uma arquitetura cliente servidor, tendo a nuvem como compartilhamento de dados.

No cenário um observa-se a necessidade de sincronismo entre os diversos sistemas principalmente durante a atualização das receitas e alarmes nos dispositivos. Observa-se também a necessidade de verificar a localização do paciente para determinar em qual dispositivo os avisos serão apresentados. Por exemplo, se o paciente não estiver em casa o sistema deverá deduzir que os avisos serão direcionados para seu dispositivo móvel, *smartphone* ou *tablet*. Do contrário, o sistema envia os avisos ou mensagens para a TVDi ou outro dispositivo da residência.

No Cenário dois observa-se que o médico necessita ter acesso às informações do paciente de qualquer lugar e de maneira transparente, nesse caso, usando as tecnologias de nuvem disponíveis. Também é necessária a geração de relatórios de acompanhamento do paciente e esses relatórios, no cenário apresentado, são baseados em dados provenientes do armário de medicamentos e do *gateway* residencial na residência do usuário, sendo importante uma camada de decisão baseadas em regras e em dados para gerir as informações e apresentá-las o mais confiável possível ao profissional de saúde.

## 1.4 Motivação

Segundo o relatório técnico das Nações Unidas, a população de idosos em 2050 chegará a um quinto da população mundial (UN, 2018). Isso implica na busca por serviços especializados para esta população principalmente os que necessitam controlar doenças por meio de medicamentos tomados diariamente, como é o caso dos pacientes hipertensos e diabéticos.

No Brasil o cenário não é muito diferente, dados do Instituto Brasileiro de Geografia e Estatística, (IBGE), apontam para a expansão do número de idosos considerando a faixa etária a partir de 60 anos, obrigando o governo a mudar as regras de aposentadorias por idade e tempo de serviço na esperança de manter essa população ativa e produtiva (IBGE, 2017; PREVIDENCIA, 2018).

De acordo com Miranda (2016), o envelhecimento da população não significa necessariamente adoecer. Se o idoso não possui doença, o envelhecimento está associado a um bom nível de saúde. Além disso, os avanços no campo da saúde e da tecnologia permitiram para a população com acesso a serviços públicos ou privados adequados, uma melhor qualidade de vida nessa fase.

O sistema de saúde brasileiro não acompanhou a mudança da faixa etária apresentada nas pesquisas, seja com sistemas mais inteligentes para prevenção de diversas doenças ou com sistemas de acompanhamento de

tratamento usando os dados espalhados por diversos sistemas proprietários, ou mesmo usando novas tecnologias como sistemas móveis, nuvem de dados e sistemas sensíveis a contexto.

No Brasil há uma iniciativa por parte do Ministério da Saúde (MS), quanto a esse tipo de sistema que é o e-SUS (DAB, 2018). Esse sistema faz parte da estratégia do governo por meio do Departamento de Atenção Básica a saúde (DAB) e permite a integração de sistemas proprietários com prontuários eletrônicos do SUS que por sua vez, usa uma arquitetura cliente servidor para disponibilizar os dados para o MS e integrar Unidades Básicas de Saúde (UBS), com sistemas maiores. No entanto o sistema e-SUS não considera os dados contextuais e não possui um método para acompanhamento de tratamento, apenas disponibiliza relatórios que auxiliam em novas políticas das áreas de saúde.

Logo, proporcionar a melhoria da qualidade de vida para as pessoas, prover dispositivos para geração de serviços de mensagens baseados em dados contextuais e da ingestão de medicamentos, aplicar sistemas automatizados de maneira transparente para o usuário, são motivos fortes para enfrentar os desafios impostos que a pesquisa de ponta nas áreas de AmI, *context-aware* e aprendizado de máquina possuem. Bem como, a necessidade de disponibilizar serviços que integrem dispositivos de forma ubíqua sendo esta a motivação principal para desenvolver este trabalho.

## 1.5 Objetivo Geral

Comprovar que um sistema integrado de mensagens é capaz de gerenciar recomendações de serviços baseados em informações contextualizadas com o intuito de auxiliar na adesão de medicamentos para pacientes em tratamento.

### 1.5.1 Objetivos Específicos

- Gerar uma base contendo dados coletados de sensores instalados em um armário inteligente de medicamentos;

- Extrair as características de identificação, comportamento do usuário e de sua receita médica a partir das informações armazenadas na base de dados;
- Definir regras para envio de mensagens de acordo com o padrão da ingestão de medicamentos;
- Construir modelos para informar médicos e equipes de saúde se o paciente adere ou não à medicação.

## 1.6 Metodologia de Desenvolvimento da Pesquisa

A metodologia para o desenvolvimento da pesquisa consiste em seis etapas divididas em investigação e experimentos com desenvolvimento de protótipos para coleta de dados de sensores, dispositivos e base de dados de prescrições médicas. Na Figura 2 é apresentado o fluxo das fases da metodologia desenvolvidas no decorrer do trabalho.

Na primeira fase da pesquisa foram utilizados os métodos de mapeamento sistemático apresentada no trabalho de Mafra e Travassos (2006). O mapeamento sistemático requer um esforço considerável quando comparado com uma revisão informal da literatura.

De acordo com Mafra e Travassos (2006), enquanto a revisão de literatura informal é conduzida de forma *ad-hoc*, sem planejamento e critérios de seleção estabelecidos a priori, o mapeamento sistemático segue um protocolo formal para conduzir uma pesquisa sobre um determinado tema, com uma sequência bem definida de passos metodológicos.

A execução do mapeamento ocorreu de agosto de 2013 a maio de 2018 e as publicações foram classificadas de acordo com os padrões estabelecidos nos critérios de inclusão e exclusão definidos no protocolo. As *strings* de buscas foram executadas nas bases de dados do IEEE, *Scopus* e ACM.

Foram aplicados dois filtros nas publicações retornadas, e o primeiro filtro consistiu na leitura dos *abstracts*, resumos e palavras chaves das publicações para em seguida analisá-los de acordo com os critérios de exclusão e inclusão listados a seguir.

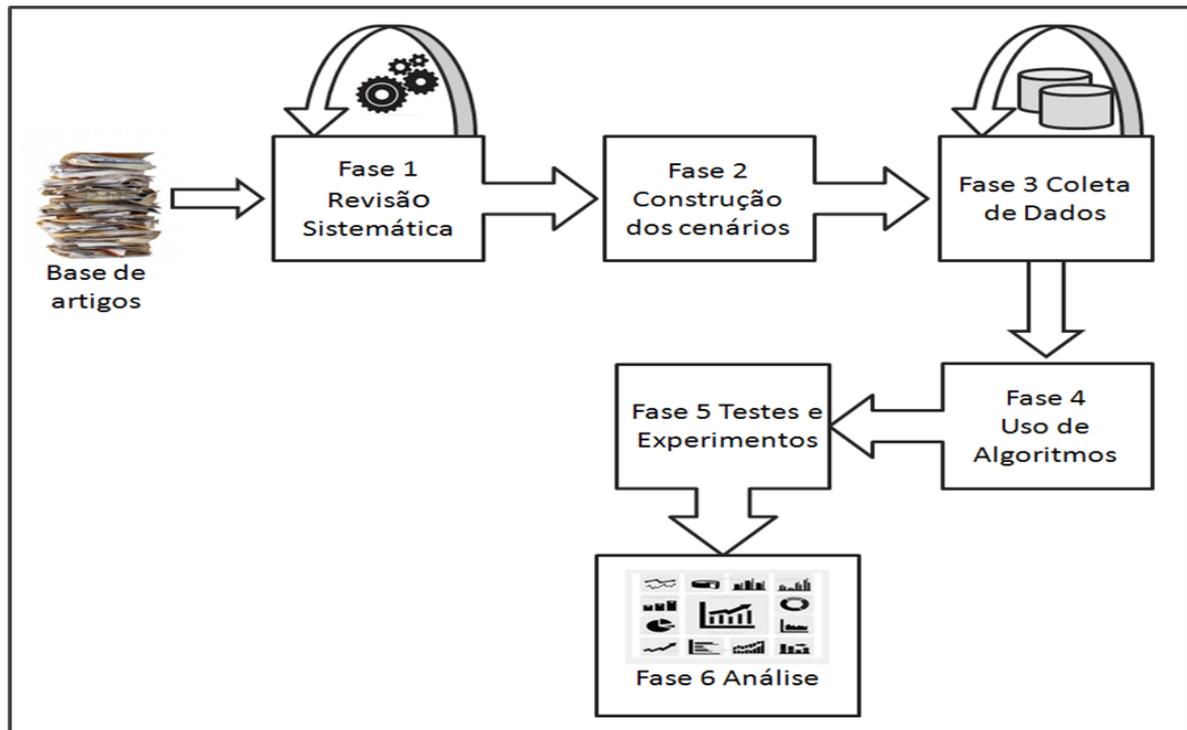


Figura 2. Fluxo da metodologia do trabalho  
Fonte: Elaborado pelo autor

Crítérios de Exclusão do primeiro filtro:

- CE1-01:** Não serão selecionadas as publicações em que as palavras chaves de busca não apareçam no título, resumo ou texto da publicação;
- CE1-02:** Não serão selecionadas publicações que descrevam *keynotes*, tutoriais, cursos e minicursos e similares;
- CE1-03:** Não serão selecionadas publicações em que a contextualização das palavras-chave utilizadas não demonstram que o trabalho cita a abordagem de AmI, *context-aware* e adesão à medicação;
- CE1-04:** Não serão selecionadas publicações em que a contextualização das palavras-chave utilizadas não demonstra que o trabalho cita aprendizado de maquina e localização.

Crítérios de Inclusão primeiro filtro:

- CI1-01:** Podem ser selecionadas publicações em que o contexto das palavras-chave utilizadas citem uma abordagem do uso de *context-aware* e

AmI nas aplicações de automação residencial e de escritório com aplicações em *healthcare*;

**-CI1-02:** Podem ser selecionadas publicações em que o contexto das palavras-chave utilizadas cite uma abordagem do uso de localização nas aplicações de automação residencial e de escritório e em sistemas de *healthcare*.

**-CI1-03:** Podem ser selecionadas publicações em que o contexto das palavras-chave utilizadas cite uma abordagem do uso de sistemas com aprendizado de máquina e aplicações em *healthcare*.

O segundo filtro consistiu em ler os artigos classificados no primeiro filtro na íntegra e classificá-los de acordo com os critérios do segundo filtro. O objetivo do segundo filtro foi identificar os artigos que se relacionavam com AmI, *context-aware*, localização e *healthcare* com ênfase em adesão à medicação e os critérios de exclusão são apresentados a seguir.

Critérios de Exclusão:

**-CE2-01:** Não serão selecionadas publicações em que a contextualização das palavras-chave utilizadas não demonstram que o trabalho cita a abordagem de AmI na automação de ambientes residenciais e de escritório;

**-CE2-02:** Não serão selecionadas publicações em que a contextualização das palavras-chave utilizadas não demonstra que o trabalho cita a abordagem de localização na automação de ambientes residenciais, escritório e *healthcare* com adesão a medicação;

**-CE2-03:** Não serão selecionadas publicações em que a contextualização das palavras-chave utilizadas não demonstra que o trabalho cita a abordagem de *context-aware* na automação de ambientes residenciais e de escritório.

Os dados de cada artigo classificado foram extraídos em formato de ficha com a preocupação de eliminar os artigos repetidos. A partir dos resultados das buscas nas bibliotecas digitais do IEEE, ACM e *Scopus* os resultados gerais foram tabulados no qual foi feita a classificação inicial por ano de publicação e abordagem, conforme apresentados na Tabela 1.

Foram estudados artigos com foco em Aml, artigos com foco em *context-aware*, sistemas de *healthcare* e adesão a medicamentos. Em seguida, as informações com datas de publicação dos artigos para verificação do Referencial Teórico foram plotados em um gráfico de linhas conforme apresentado na Figura 3.

Tabela 1. Resultado geral de publicações referentes ao tema.

Máq. de busca	Tot. publicações	Primeiro Filtro	Segundo Filtro
IEEEExplore	130	50	15
Scopus	70	30	10
ACM	91	35	12
Totais	291	115	37

Observando o gráfico apresentado na Figura 3, verifica-se que as pesquisas envolvendo o conjunto de temas Aml, *context-aware*, localização, adesão a medicamentos e sistemas de *healthcare* tiveram seu ápice em 2007 com decréscimo em 2009 e continuaram a crescer em 2010. De 2011 a 2013 houve um decréscimo dos artigos publicados na área, no entanto, a partir de 2014 a 2018, período de fechamento do mapeamento sistemático, os trabalhos pesquisados voltaram a apresentar os temas da pesquisa, indicando que a área é promissora e continua atual.

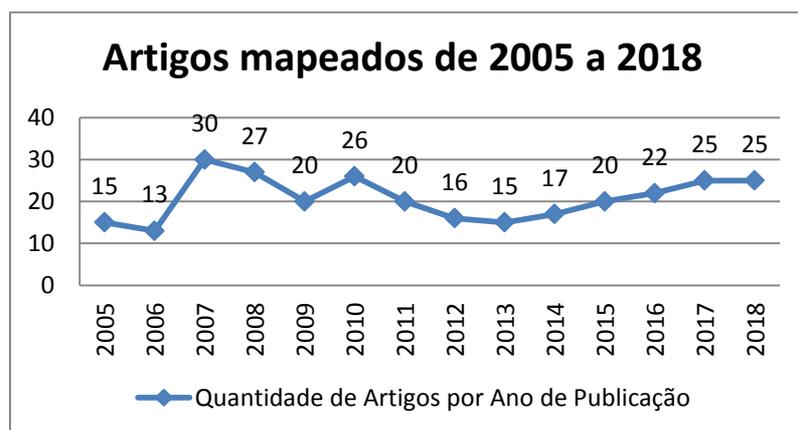


Figura 3. Gráfico demonstrando a quantidade de artigos na área de pesquisa.  
Fonte: Elaborado pelo autor.

Na fase dois, após a fase de revisão sistemática, os cenários para aplicar os experimentos relacionados com o estado da arte foram

construídos usando a infraestrutura do laboratório de TV Digital e Sistemas Embarcados do CETELI, e os dispositivos de *hardware* disponíveis no laboratório.

Na fase três, foram coletados os dados de sensores e dispositivos a fim de construir uma base de dados e gerar experimentos com essa base aplicando modelos de arquitetura desenvolvidos para experimentar com os protótipos e escrever artigos científicos na área da pesquisa. Para esta fase foi necessário à codificação dos protótipos de coleta de dados e armazenamento em banco de dados.

Na fase quatro foram usados algoritmos que dão suporte a informações de contexto e árvore de decisão para em seguida integrá-los aos protótipos desenvolvidos.

Na fase cinco foi desenvolvida uma arquitetura, finalizada e testada em um ambiente integrado com sistema de avisos usando a TVDi, *smartphones* e *tablets* a partir de dados de prescrições médicas de um armário de medicamentos conectado a internet. Com esses passos cumpriram-se as etapas de pesquisa, coleta de resultados e escrita de artigos e da Tese.

## 1.7 Organização do Trabalho

O trabalho foi dividido em seis Capítulos descritos a seguir: Neste Capítulo foram apresentados a introdução a contextualização do problema os objetivos e a justificativa. No Capítulo 2 será apresentado o referencial teórico englobando o estado da arte, conceitos e definições sobre ambientes inteligentes *AmI*, *context-aware*, sistemas de *healthcare* e adesão a medicamentos. No Capítulo 3 serão apresentados os trabalhos relacionados a este trabalho finalizando com uma comparação das tecnologias e dos métodos utilizados por eles e os deste trabalho. No Capítulo 4 será apresentada a concepção da arquitetura para desenvolver a proposta de trabalho. No Capítulo 5 serão discutidos os resultados dos experimentos e as contribuições da Tese de Doutorado, finalizando com o Capítulo 6 onde serão apresentadas as limitações, conclusões e os trabalhos futuros.

## Capítulo 2 Referencial Teórico

Neste capítulo serão apresentados os conceitos inerentes a ambientes inteligentes com as definições, características, principais áreas de aplicações, sistemas baseados em *context-aware*, *healthcare*, adesão a medicamentos e aprendizado de máquina. Esses conceitos são necessários para o bom entendimento da questão de pesquisa da Tese.

No decorrer da apresentação das seções, serão vistos os conceitos principais com um breve resumo de cada componente do referencial teórico extraindo principalmente as características e aplicações dos algoritmos para tomada de decisão e os conceitos de adesão à medicação.

### 2.1 Ambientes Inteligentes

Os Ambientes Inteligentes são descritos na literatura como uma visão do futuro onde as tecnologias estarão sempre presentes no dia a dia das pessoas, automatizando tarefas corriqueiras por meio da utilização dos dados de sensores, aplicados a um determinado contexto (YACHIR, 2016).

Segundo Ramos, Augusto e Shapiro (2008), um ambiente inteligente requer um esforço considerável para desenvolver aplicações. A abordagem de AmI requer conceitos de Inteligência Artificial (IA) e isso segundo os autores levarão a evolução da IA para o próximo passo como a evolução dos ambientes inteligentes. Os autores apresentaram as características de AmI combinando as técnicas de IA por meio do ponto de vista de uma arquitetura em camadas. Tal arquitetura integra dispositivos, tecnologias e ações sobre o ambiente, incorporando métodos de IA em uma camada de inteligência que interage com a camada de *hardware* e o ambiente por meio de sensores e atuadores.

A Figura 4 apresenta uma visão geral de AmI adaptada de Ramos, Augusto e Shapiro (2008). Dentre as questões tratadas destacam-se o planejamento das ações de decisão do sistema, o aprendizado sobre o ambiente e seus aspectos sociais, a interação humano versus computador e

as ações tomadas de acordo com os eventos internos e externos do ambiente inteligente.

Observando a Figura 4, nota-se que AmI tem a característica geral de envolver o ser humano com o ambiente. O humano interage com AmI por meio de sensores e ações. Os sistemas AmI reagem aos eventos externos com ações no ambiente usando camadas de inteligência para tratar os dados recebidos e interagir com o usuário. Essa interação envolve sensores e atuadores instalados no ambiente que executam as ações de forma automática.

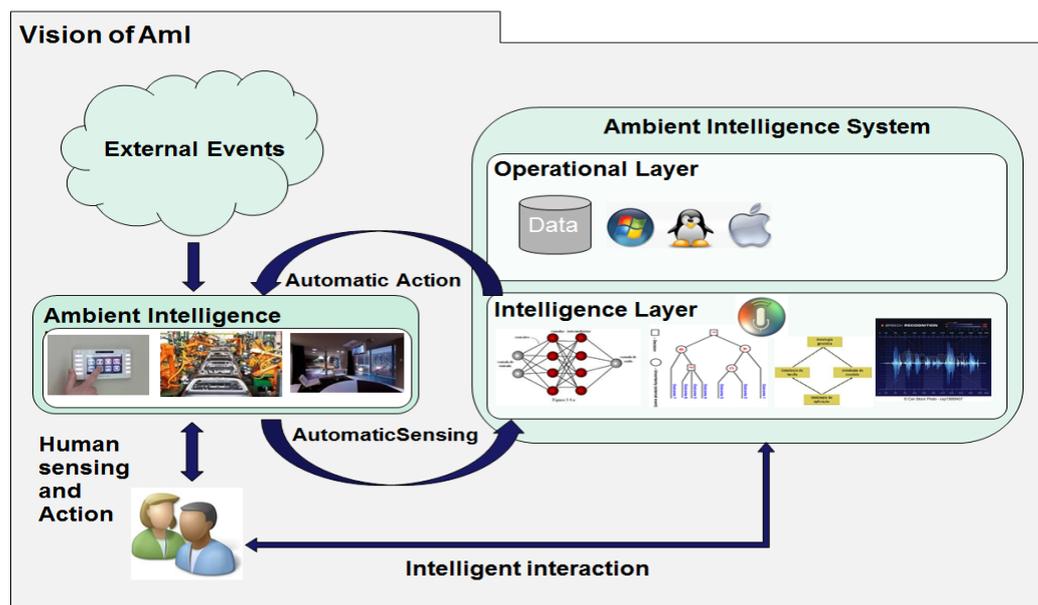


Figura 4. Visão geral de AmI na perspectiva de IA.  
Fonte: Adaptado de Ramos et al., (2008).

### 2.1.1 Principais Áreas de Aplicações de AmI

As áreas promissoras para a aplicação de AmI são as cidades inteligentes que integram escritórios e residências por meio das novas tecnologias de redes atuais (O'GRADY, 2012).

Algumas aplicações já estão planejadas e outras presentes no dia a dia, tais como, salas de cinema inteligente, automatização inteligente de processos de pagamentos, integração com sistemas de segurança e iluminação, transporte inteligente, dentre outros (KOMNINOS, 2014).

O conceito de interatividade está em alta e vem sendo utilizado como forma de divulgação em diferentes tipos de negócios, por exemplo, propagandas, cinema, teatro, etc., que são usados como um meio de atrair o público para os eventos e também para divulgação de produtos.

Isso também é uma forma de aplicar Aml, não só na automação mas nos próprios serviços de *software* integrados com agentes inteligentes, por exemplo, o que facilita a integração entre homem-máquina, máquina-máquina (COOK, 2009).

Com o avanço das tecnologias de aprendizado de máquina e novos dispositivos inteligentes disponíveis no mercado, a automação de tarefas do dia a dia de uma residência está cada vez mais presente. Assim com a melhoria das redes de comunicação e aumento da velocidade de conexão agora é possível o compartilhamento de dados em diferentes provedores criando oportunidades de negócios inovadores como os de *healthcare*.

## 2.2 Context-aware

O termo “contexto” segundo Dey (2001), Zimmer (2004) e Ranganathan (2003) é um conjunto de informações que caracterizam a interação entre o usuário e a aplicação. Informações sobre a localização, temperatura, luminosidade e atividade do usuário podem ser consideradas como informações de contexto e qualquer informação que possa ser usada para caracterizar objetos e atividades que envolva diretamente o usuário.

Um sistema é classificado como sensível ao contexto quando apresenta informações relevantes de serviços destinados ao usuário baseado na tarefa que este está desempenhando (DEY, 2001).

### 2.2.1 Características de Contexto

As aplicações reativas ao contexto são as que se adaptam às mudanças do ambiente e podem ser classificadas segundo Dey (2001) em contexto de baixo nível: quando a informação é obtida diretamente de sensores ou por meio de processamento simples; contexto de alto nível: se a informação for

obtida por meio dos dados coletados da informação de contexto de baixo nível ou requer processamento mais avançado.

Quando se tem necessidade de usar informações de tempo, localização, atividades, por exemplo, a definição de uma agenda social automatizada ou um *status* “em reunião”, “recebendo medicação”, “cozinhando”, etc., é necessária a modelagem do contexto em alto nível (ADOMAVICIUS, 2011; DEY, 2001).

Outra classificação de contexto é dada por Chen (2000) que o classifica como ativo: quando a informação é crítica e utilizada pela aplicação para adaptar seu comportamento; e passivo quando a informação não é crítica para a adaptação da aplicação, mas aumenta a compreensão da situação atual do usuário.

No trabalho de Abowd (1997) a informação contextual é classificada como “cinco Ws”, conforme destacados a seguir:

- Who (quem): são as variáveis de identificação do usuário, pessoas e dispositivos próximos;
- What (o que): são as variáveis para identificar as atividades do usuário, exemplo, comendo, trabalhando, tomando medicamentos, assistindo TV ;
- Where (onde): localização, em casa, em deslocamento, no trabalho;
- When (quando): tempo, tempo que permaneceu em determinado local, quando chegou, quando saiu;
- Why (por que): informações que caracterizam o estado do usuário, exemplo, por que está na sala?

Nesta relação, o contexto de baixo nível fornece dados oriundos de sensores e perfis ao contexto de alto nível. Este, por intermédio de um processador, provê a informação contextual (onde, que, quando, por que, etc.) que será usada de maneira ativa ou passiva pela aplicação, possibilitando assim a adaptação do seu comportamento (DEY, 2001). As aplicações dessa modalidade de sistemas permitem que decisões automáticas sejam tomadas reduzindo o envolvimento excessivo do usuário.

Nas aplicações de *healthcare*, o uso de contexto é observado em trabalhos como o de Solanas et al. (2014) que faz um levantamento do uso de contexto em aplicações de *mobile healthcare*, (*m-health*), com aplicações práticas em cidades inteligentes e demonstra como os serviços de saúde podem se beneficiar dessa abordagem conceitual que integra sistemas de lembretes para tomada de medicamento, acesso a serviços de saúde com hospitais e ambulâncias interligados possibilitando que o paciente tenha acesso aos serviços de saúde no próprio dispositivo móvel. A Figura 5 apresenta o cenário das aplicações *m-health* no contexto de cidades inteligentes.

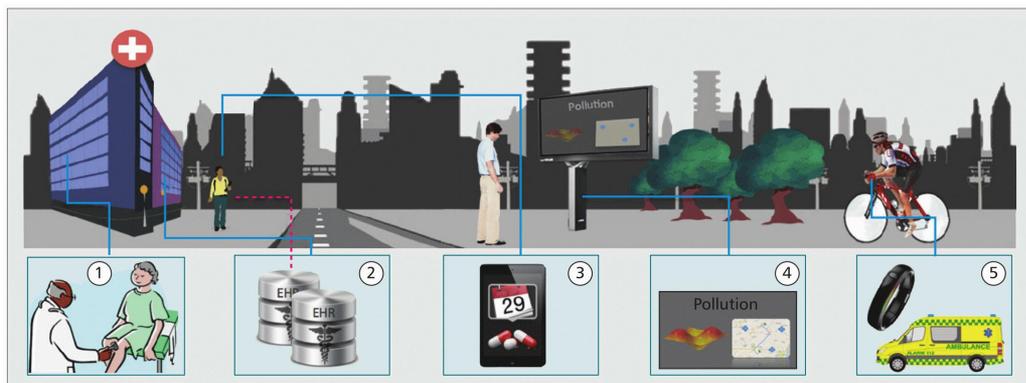


Figura 5. Visão geral das aplicações m-health integradas às cidades inteligentes  
Fonte: Solanas et al., (2014).

Observando a Figura 5 nota-se a diversidade de aplicações em cidades inteligentes iniciando com o atendimento do paciente pelo médico, Figura 5 (1) com os dados sendo enviados a um sistema de banco de dados compartilhado, Figura 5 (2), sistemas de agendamento e de alarmes para acompanhamento da adesão, Figura 5 (3), além da integração com outras aplicações, por exemplo, o monitoramento do nível de poluição e transporte, Figuras 5 (4) e (5).

No trabalho de Miao (2015) é apresentado um sistema vestível baseado em contexto que coleta e monitora eletrocardiograma (ECG) remotamente usando um *smartphone* para reconhecer as atividades físicas do paciente e um sensor de batimentos cardíacos desenvolvido com tecnologia *bluetooth* de

baixo consumo de energia. O sistema móvel monitora as atividades do paciente e avalia o EGC em tempo real disponibilizando os dados na nuvem.

## 2.5 Aprendizado de Máquina

Segundo Brink e Richards (2014), Aprendizado de Máquina (AM) é considerado um ramo da IA com especialização na codificação de sistemas capazes de aprender de maneira automática baseado em dados do passado.

As atividades de memorização, observação e exploração das situações para aprender fatos e melhorar habilidades motoras e cognitivas por meio da prática é considerada essencial para a aprendizagem (GAMA, 2015). Isso é interessante quando se pretende aplicar o AM para auxiliar na resolução de problemas do cotidiano.

Os sistemas preditivos baseados no histórico usam base de dados específicas para treinamento e teste de hipóteses com objetivo de aprender padrões para classificação e rotulação de dados.

Segundo Dietterich (1998), um algoritmo de aprendizado de máquina preditivo consiste em uma função, que dado um conjunto de exemplos rotulados constrói um estimador. O rótulo identifica valores conhecidos do domínio da informação que se quer estimar. Se o domínio do problema for um conjunto de valores nominais, ele é tratado como um problema de classificação. No entanto, se o domínio for um conjunto infinito de valores então é tratado como um problema de regressão.

A definição formal do domínio da informação  $\mathbf{D}$  é dada pela equação (1). Onde  $f$  é uma função desconhecida, utilizada para que um algoritmo de AM aprenda por aproximação, permitindo estimar o valor de  $f^{\wedge}$  que permite estimar o valor de  $f$  para novas observações de  $x_i$  (LORENA, 2011).

$$D = \{x_i, (f(x_i)), i = 1, \dots, n\} \quad (1)$$

Nas equações 2 e 3, é possível observar duas situações diferentes dependendo do tipo de dado aplicado à  $f$ . A classificação que assume valores em um conjunto discreto e a regressão que trabalha com valores em

um conjunto infinito. Ou seja, a técnica utilizada, classificação ou regressão, depende do conjunto de dados de entrada.

$$y_i = f(x_i) \in [c_1, \dots, c_m] \quad (2)$$

$$y_i = f(x_i) \in \mathfrak{R} \quad (3)$$

A Figura 6 apresenta um gráfico com exemplos de duas classes previstas por meio da técnica de classificação. Observa-se que neste caso, a distribuição foi separada em duas classes. Isso acontece porque o classificador usou um conjunto de dados com apenas dois resultados possíveis, continua ou suspende o tratamento. Neste caso, os dados do espaço de objetos foram aplicados ao problema para suspender ou continuar o tratamento de um determinado paciente usando a abordagem de classificação.

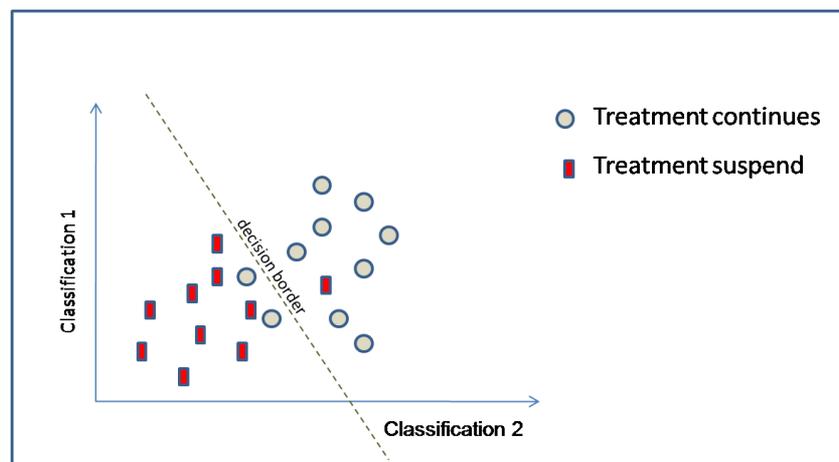


Figura 6. Espaço de objetos classificados em duas classes.  
Fonte: Elaborado pelo autor baseado em Lorena, (2011).

### 2.5.1 Tipos de Aprendizado de Máquina

O aprendizado de máquina é uma área central da pesquisa em inteligência artificial. De acordo com dados rotulados ou dados não rotulados em conjuntos de treinamento, o tipo de aprendizado de máquina pode ser dividido em aprendizado não supervisionado, aprendizado

supervisionado, aprendizado semi-supervisionado e aprendizado por reforço (DING, 2017).

### **Aprendizagem Supervisionada**

Segundo Kotsiantis (2007), o aprendizado de máquina supervisionado consiste na busca por algoritmos que aprendam a partir de instâncias fornecidas externamente para então produzir hipóteses gerais capazes de fazerem previsões sobre instâncias futuras, com o objetivo de construir um modelo conciso da distribuição dos rótulos de classe em termos de recursos da previsão.

O classificador resultante é então usado para atribuir rótulos de classe às instâncias de teste onde os valores dos recursos do algoritmo preditor são conhecidos, mas o valor do rótulo da classe é desconhecido, (ZHANG et al., 2002). Na Figura 7 observa-se o fluxo de processo do método de aprendizado de máquina supervisionado.

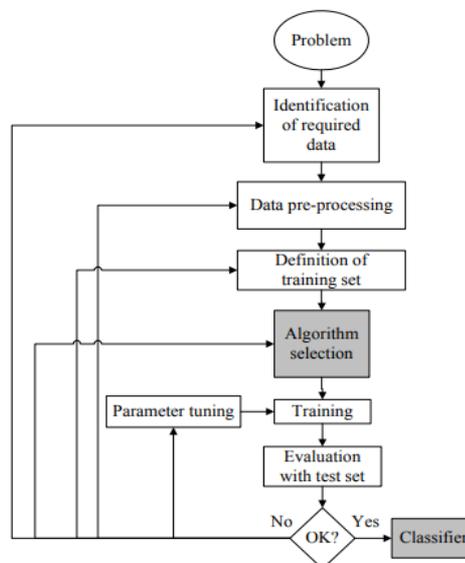


Figura 7. Fluxo do processo de um aprendizado de máquina supervisionado.  
Fonte: Zhang et al., (2002) .

O primeiro passo do algoritmo é coletar o conjunto de dados. Se um requisito especialista está disponível, então ele pode sugerir quais atributos ou recursos são os mais informativos. Se não o algoritmo usa “força bruta” para medir tudo o que está disponível na esperança de que as características relevantes possam ser isoladas (Zhang et al., 2002).

No aprendizado supervisionado é fornecida uma característica do objeto a ser alcançada, ou seja, o algoritmo recebe o valor da saída desejada para conferir com a entrada apresentada.

### ***Aprendizagem Semi-Supervisionada***

A aprendizagem semi-supervisionada é o foco da pesquisa de aprendizado de máquina nos últimos anos (Zhang et al., 2002). É um método que combina aprendizado não supervisionado e aprendizado supervisionado.

A ideia básica é usar um grande número de dados não rotulados para ajudar o método de aprendizado supervisionado a melhorar a efetividade (ZHANG, 2013).

No aprendizado semi-supervisionado há um conjunto de dados rotulados dado por  $L = \{(x_1, y_1), (x_2, y_2), \dots, (x_l, y_l)\}$  e um conjunto não rotulado dado por  $U = \{x'_1, x'_2, \dots, x'_u\}$  e espera-se uma função de  $x \rightarrow y$  que poderia prever com precisão um rótulo para o um dado  $x$ , (DING, 2017).

### ***Aprendizagem não Supervisionada***

Na aprendizagem não supervisionada, há apenas alguns dados de entrada, e o algoritmo não supervisionado busca encontrar a estrutura oculta ou o comportamento dos dados de entrada por meio da utilização de um determinado método de aprendizagem. Os algoritmos de agrupamentos são exemplos de métodos de aprendizado não supervisionado (DING, 2017).

### ***Aprendizagem por reforço***

O aprendizado por Reforço (AR) modela o sistema aprendiz dinamicamente e permite que o sistema adquira a capacidade de conhecer o ambiente em tempo de execução (SUTTON, 1998).

Segundo o trabalho de Szepesvári (2010), formalmente AR possui uma estrutura de estado, ações e recompensas. O modelo possui agentes que atuam no ambiente por meio de um conjunto de estados possíveis. Pode executar uma ação para cada estado, ou um conjunto de ações, e recebe um reforço para cada vez que executa a ação. Ao longo do tempo o processo constrói sequências (estado, ação, reforço) para ser aprendido em longo

prazo. A Figura 8 apresenta um cenário básico para o aprendizado por reforço.

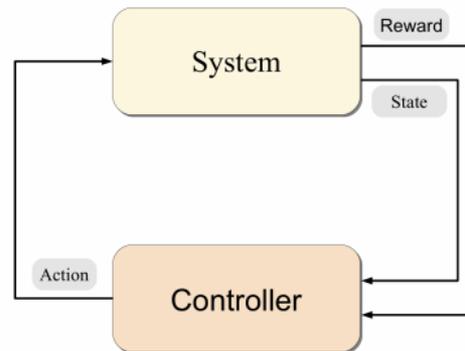


Figura 8. Um cenário básico de aprendizado por reforço.  
Fonte: Szepesvári, (2010).

O aprendizado por reforço refere-se a algoritmos orientados por objetivos, que aprendem como atingir uma meta complexa ou maximizar ao longo de uma determinada dimensão ao longo de vários passos; por exemplo, maximizar os pontos ganhos em um jogo em muitos movimentos (SZEPEŠVÁRI, 2010).

Especificamente neste trabalho de doutorado será aplicada a abordagem de aprendizado supervisionado mais precisamente usando os algoritmos de AM baseados em busca, tais como os de árvore de decisão e regras, para tanto, eles serão apresentados a seguir.

### 2.5.2 Algoritmos de AM Baseados em Buscas

Os algoritmos de AM baseados em busca são os de árvores de decisão e regressão. Neste trabalho será dada ênfase nos modelos de árvores de decisão.

#### **Árvores de Decisão**

As árvores de decisão usam o paradigma de divisão e conquista apresentado no trabalho de Smith (1986), que consiste em dividir o problema maior em instâncias menores similares ao problema original e

depois combina as soluções para resolver o problema maior de maneira recursiva.

No caso das árvores de decisão, as soluções do subproblema resolvido são combinadas na forma de uma árvore que divide o espaço de instâncias em subespaços e cada subespaço pode ser ajustado usando diferentes modelos (LORENA, 2011).

Algoritmos baseados nesse modelo, tais como o ID3 (QUINLAN, 1986), CART (BREIMAN et al., 1984) e C4.5 (QUINLAN, 1993) e mais recentemente o algoritmo C5.0 (PANDYA, 2015), com uma versão comercial do C4.5 com novas funcionalidades e otimizações, implementam esse paradigma de divisão e conquista.

Os modelos em árvores são subdivididos em modelos de árvore de decisão, para os casos de classificação, e modelos de árvore de regressão para os problemas de regressão (LORENA, 2011).

### **Algoritmo ID3**

O algoritmo *Iterative Dichotomiser 3* (ID3) segundo Quinlan (1986), constrói uma árvore multivariada que verifica cada nó de maneira gulosa, na qual produzirá o maior ganho de informação. As árvores são construídas em seu tamanho máximo e, em seguida, uma etapa de poda é aplicada para melhorar a capacidade de generalizar o modelo para dados diferentes do conjunto de treinamento.

O algoritmo inicia com o conjunto de dados  $S$  como o nó raiz. Para cada iteração do algoritmo, verifica-se cada atributo não utilizado do conjunto  $S$  e calcula-se a entropia de  $S$ ,  $H(S)$  ou o ganho de informação de  $S$ ,  $IG(S)$  daquele atributo. Em seguida, o atributo que possui a menor entropia ou o maior ganho de informação é selecionado. O conjunto  $S$  é então dividido pelo atributo selecionado (por exemplo, a idade é menor que 50, a idade é entre 50 e 100, a idade é maior que 100), para produzir subconjuntos dos dados considerando apenas os atributos nunca selecionados antes.

O cálculo da entropia e do ganho da informação utilizados pelo algoritmo para mensurar a quantidade de incerteza no conjunto de dados são apresentados nas equações 4 e 5.

$$H(S) = -\sum_i p_i \times \log_2 p_i \quad (4)$$

Onde  $S$  é conjunto de dados para o qual a entropia está sendo calculada e se altera em cada iteração do algoritmo ID3,  $p$  é a probabilidade de se observar cada valor de  $p$ . A entropia é medida em *bits* usando o logaritmo na base 2.

O ganho da informação é dado pela diferença entre a entropia do conjunto de exemplos e a soma ponderada da entropia das partições. A construção da árvore de decisão é guiada pelo objetivo de reduzir a entropia (QUINLAN, 1986).

$$IG = H(S) - \sum_{t \in T} p(t)H(t) \quad (5)$$

#### **Algoritmo C4.5**

O algoritmo C4.5 é o sucessor do algoritmo ID3, foi proposto por (QUINLAN, 1993) e também utiliza o conceito de entropia. A principal diferença do C4.5 para o ID3 é que o C4.5 converte as árvores treinadas em conjuntos de regras *if-then*. A precisão de cada regra é avaliada para determinar qual a ordem que deve ser aplicada. A remoção da regra é feita removendo a pré-condição de uma regra se a precisão geral das regras for melhor sem a regra candidata a ser removida. Uma implementação do C4.5 muito utilizada é o J48 (BHARGAVA, 2013), implementado em Java e disponível na ferramenta Weka, (HALL et al., 2009).

O algoritmo C4.5 constrói árvores de decisão a partir de um conjunto de dados de treinamento da mesma maneira que o ID3, usando o conceito de entropia de informações. Em cada nó da árvore gerada, o C4.5 escolhe o

atributo dos dados que divide mais efetivamente seu conjunto de amostras em subconjuntos. O atributo com o maior ganho de informação normalizado é escolhido para tomar a decisão (BHARGAVA, 2013).

A principal desvantagem dos conjuntos de regras do C4.5 é a quantidade de tempo e memória da CPU que ele exige. Em um experimento apresentado no trabalho de Wu et al. (2008) foi comprovado com amostras variando de 10.000 a 100.000 casos de um grande conjunto de dados, que houve o aumento do consumo de ciclos de CPU. Para árvores de decisão, a passagem de 10k para 100K casos aumentou o custos do algoritmo.

### ***Algoritmo RepTree***

O algoritmo RepTree constrói uma árvore de decisão usando o ganho de informação e variância, usa a poda com erro reduzido com *backfitting*, uma técnica utilizada para ajustar um modelo aditivo generalizado, (MEERAGANDHI, 2010). É mais utilizado para classificar valores com atributos numéricos. Os valores ausentes são tratados dividindo-se as instâncias correspondentes em partes como no C4.5.

### ***Algoritmo Random Tree***

O algoritmo *Random Tree* (árvore aleatória) é usado para construir uma árvore que considera  $k$  atributos aleatoriamente escolhidos em cada nó. Não executa poda e também tem uma opção para permitir a estimação de probabilidades de classe em um conjunto de dados e *backfitting* (CHAUHAN, 2013).

### ***Algoritmo Random Forest***

O *Random Forest* é uma abordagem poderosa para dados, análise e modelagem preditiva que usa recursividade e particionamento para gerar um conjunto de árvores e em seguida agrega os resultados. Usa a técnica de *bagging* classificadores e cada árvore é construída de forma independente usando uma amostra dos dados para classificar o atributo alvo (CHAUHAN, 2013).

## 2.6 Medidas de Desempenho em AM

Em Aprendizado de Máquina são usadas medidas para avaliação do desempenho dos classificadores. Dentre essas medidas podem ser destacadas: taxa de acerto, taxa de erro e curva *Receiver Operating Characteristic Curve* (ROC) (LORENA, 2011).

As principais métricas para avaliar o poder de classificação dos modelos de predição são: Acurácia, Sensibilidade, Especificidade, Verdadeiro Preditivo Positivo e Verdadeiro Preditivo Negativo. Essas métricas são extraídas da matriz de confusão, apresentada no exemplo da Tabela 2.

Tabela 2. Exemplo de uma Matriz de Confusão.

	Valor Observador Verdadeiro		
	Y=1	Y=1	Y=0
Valor Predito	Y=0	VP FN	FP VN

A matriz de confusão é dada por uma tabela de contingência em que na linha está o valor previsto e na coluna o valor verdadeiro observado e o cálculo da acurácia *ACC*, sensibilidade *SENS*, especificidade *ESPEC*, verdadeiro positivo também chamado de “Recall” *VPP* e verdadeiro negativo, *VPN* são dadas nas equações (6),(7),(8),(9) e (10), (POWERS, 2011; FAWCETT, 2006 ).

$$ACC = (VP + VN)/(P+N) \quad (6)$$

$$SENS = VP/(VP+FN) \quad (7)$$

$$ESPEC=VN/(VN+FP) \quad (8)$$

$$VPP=VP/(VP+FP) \quad (9)$$

$$VPN=VN/(VN+FN) \quad (10)$$

Além das medidas de desempenho apresentadas, os gráficos da curva ROC são úteis para organizar os classificadores e visualizar seu desempenho. Os gráficos ROC são comumente usados na tomada de decisões médicas. Nos últimos anos têm sido usados cada vez mais em aprendizado de máquina e mineração de dados (FAWCETT, 2006).

Os gráficos ROC são gráficos bidimensionais nos quais a taxa de VP é plotada no eixo Y e taxa FP é plotada no eixo X. Um gráfico ROC descreve as compensações relativas entre benefícios (verdadeiros positivos) e custos (falsos positivos).

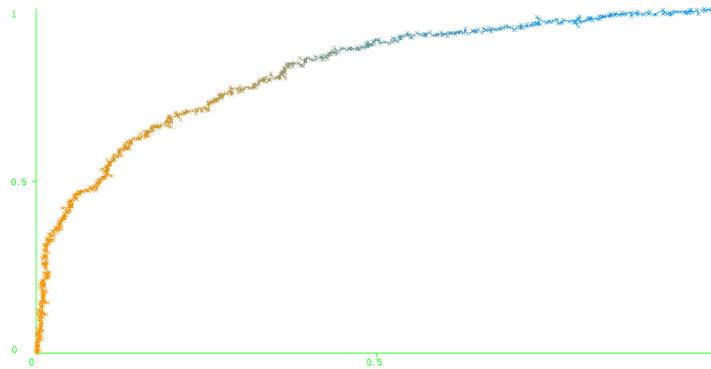


Figura 9. Gráfico da curva ROC dos resultados de um Classificador.  
Fonte: Adaptado de Fawcett, (2006).

A Figura 9 apresenta a plotagem da curva ROC em uma base de dados de testes. Quanto mais próximo do ponto inferior esquerdo (0, 0) significa que classificação tem um menor número de falsos positivos. O ponto mais próximo do par (0, 1) representa o quanto o classificador se adequa aos dados indicando o percentual de falsos positivos e negativos durante toda a classificação dos dados, (POWERS, 2011; FAWCETT, 2006).

## 2.7 Adesão a Medicamentos

Segundo a *World Health Organization* WHO, (2017) a adesão à medicação é definida como um grau em que o comportamento de um paciente corresponde às recomendações sobre a ingestão de medicamentos prescritos por um médico.

A adesão difere da conformidade. A conformidade implica na obediência do paciente a autoridade do médico, no entanto, a adesão significa que o paciente e médico colaboram para melhorar a saúde do paciente integrando tanto a opinião médica quanto o estilo de vida do paciente e, principalmente, nos valores e preferências do paciente por determinada medicação (JIMMY et al., 2011).

Segundo Lam (2015), a não adesão por outro lado, pode ser classificada, por tipos descritos a seguir:

- Não adesão do cumprimento da prescrição que ocorre quando os médicos escrevem a prescrição, mas a medicação nunca é ingerida.
- Não persistência no tratamento, quando o paciente decide parar de tomar uma medicação após iniciá-la, raramente é intencional e podem ocorrer por diversos problemas tais como acesso ao medicamento, custo, esquecimentos por parte do paciente, doses erradas, efeitos adversos, etc.
- O terceiro tipo de não adesão é conhecido como não conforme e inclui uma variedade de formas em que a medicação não é tomada seguindo a prescrição. Esse comportamento pode variar desde o paciente deixar de tomar algumas doses, tomar medicamentos em horários incorretos ou em doses incorretas e até mesmo tomar mais do que é prescrito ocasionando a toxicidade ou superdosagem.

Melhorar a adesão de pacientes a medicamentos é um desafio. A baixa adesão ao tratamento de doenças crônicas é um problema mundial de grande magnitude e a adesão à terapia de longo prazo para doenças crônicas em países desenvolvidos é em média de 50% e as consequências são o comprometimento severo da eficácia do tratamento e a piora dos índices de perspectiva da qualidade de vida do cidadão (WHO, 2017).

### 2.7.1 Taxa de Adesão a Medicamentos

Segundo Jimmy et al. (2011), a taxa de adesão a medicamentos é uma medida da porcentagem da dose prescrita e a ingerida pelo paciente durante um período específico do tratamento e em diversos estudos varia dependendo do desenvolvimento cultural do país e da idade do paciente.

Por exemplo, os estudos apresentados em Carter (2003) e WHO (2017) revelam que em países desenvolvidos a média da adesão chega a 50%. Os outros 50% dizem respeito a não adesão onde a metade da não adesão é intencional enquanto que a outra metade tem a ver com o regime de

prescrição dos medicamentos que torna muito complexo o processo de acompanhamento.

As taxas de adesão tipicamente são mais altas em pacientes com condições agudas quando comparadas com pacientes crônicos, isso quer dizer que os pacientes crônicos tendem a abandonar a medicação (JACKEVICIUS, 2002; HAYNES, 2002).

Como consequência do baixo índice de adesão observa-se o desperdício de medicamentos, a piora da doença, a redução das habilidades funcionais, a diminuição da qualidade de vida, mais internações e mais ocupações de casas para idosos (WHO, 2017).

## 2.8 Considerações Finais sobre o Capítulo

Neste Capítulo foram apresentados os conceitos relacionados com a Tese de Doutorado. As tecnologias e os conceitos que fazem parte do escopo deste trabalho, tais como *context-aware*, ambientes inteligentes, aprendizado de máquina e adesão a medicamentos, foram discutidos e delimitados de acordo com o tema proposto.

A importância deste capítulo foi no mapeamento do estado da arte e dos conceitos relacionados necessários para o embasamento teórico do trabalho e o direcionamento da investigação dos trabalhos relacionados que serão apresentados no Capítulo 3. As contribuições para a Tese foram o entendimento da dimensão do problema de pesquisa no tocante a escolha dos modelos para ser aplicada no módulo de inteligência do sistema de mensagens, a especificação da base de dados para os experimentos e a decisão de integrar os algoritmos de árvore de decisão nos protótipos que serão apresentados no decorrer deste trabalho.

## Capítulo 3 Trabalhos Relacionados

Os trabalhos relacionados apresentados nessa seção foram catalogados a partir da base de dados classificada no mapeamento sistemático de maneira a apresentar as características de AmI e *context-aware* e adesão a medicação, quanto a arquitetura, as ferramentas e as técnicas utilizadas além de verificar como os trabalhos se integram a sistemas de *healthcare* e *e-health*.

### 3.1 DOMOSEC's Plataforma para Sistemas de Domótica

Uma arquitetura para automação com localização indoor em ambientes inteligentes foi apresentada no trabalho de Zamora-Izquierdo et al. (2010). A arquitetura é composta por um sistema de monitoramento e controle por meio de vários dispositivos embarcados conectados a sensores e atuadores e centralizados em uma casa inteligente.

O trabalho de Zamora-Izquierdo et al. (2010) suporta uma infraestrutura de segurança e acesso remoto via internet por meio de dois protocolos, *Hypertext Transfer Protocol* (HTTP), usado para comunicação com um *gateway* de monitoramento local, e o protocolo *User Datagram Protocol* (UDP), para se comunicar com módulos de segurança e servidores remotos.

Os autores propuseram um sistema tolerante a falhas no qual foi desenvolvido um protocolo próprio de segurança chamado de *Superior Home Automation* (SHAP) na camada de *Transmission Control Protocol* (TCP) sobre os endereços de *Internet Protocol* (IP). A Figura 10 apresenta a arquitetura definida no trabalho.

Observa-se que a arquitetura é descrita em dois grandes módulos baseados em camadas que se conectam por meio da internet e permitem acesso local e remoto para o usuário da residência e para as empresas de monitoramento e segurança. O sistema é capaz de conectar diversos dispositivos residenciais tais como câmera IP, acesso a painel de controle de eletrodomésticos tais como ar-condicionado e TV usando uma interface com

o protocolo de comunicação entre dispositivos eletrônicos, (X10), usados na automação residencial, ou redes de sensores com comunicação ZigBee.

Foi possível integrar os módulos de automação de forma transparente no trabalho de Zamora-Izquierdo et al. (2010). No entanto, o trabalho não aplica nenhuma camada de inteligência na definição da arquitetura e a maior contribuição é exatamente o protocolo de comunicação e segurança SHAP desenvolvido pelos autores.

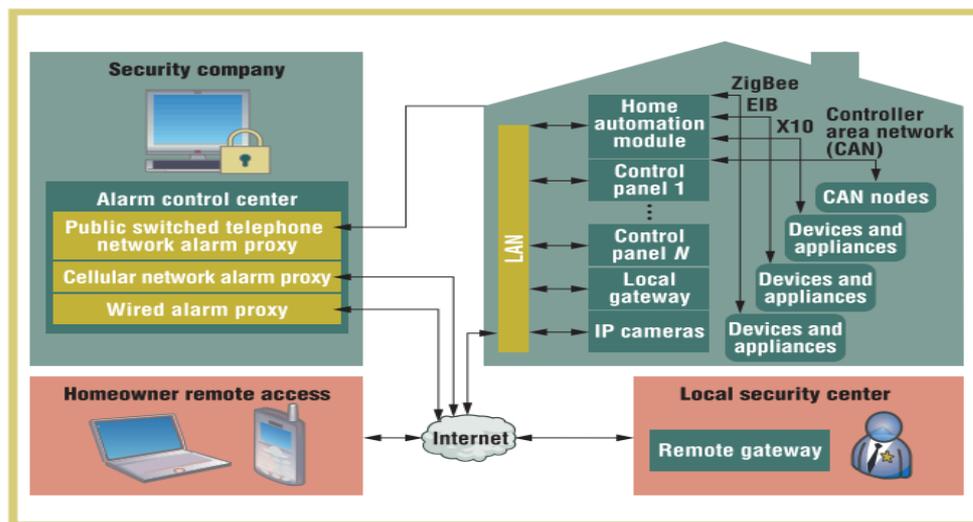


Figura 10. DOMOSEC's Plataforma para sistemas de domótica.  
Fonte: Zamora-Izquierdo et al., (2010).

### 3.2 Assistente Pervasivo para Médicos e Enfermeiros

No trabalho de Dingli, Abela e D'Ambrogio (2011) foi apresentada uma arquitetura para ambientes inteligentes que utiliza a semântica WEB para melhorar a qualidade dos serviços de *healthcare*. A arquitetura é descentralizada e baseada em três camadas: camada de dispositivos, que coleta os dados de entrada usando sistemas de tempo real, camada de gerência de dispositivos, que sincroniza a coleta dos dados, e a camada de conhecimento, que gera a base de conhecimentos de acordo com os dados coletados do ambiente.

A aquisição das informações de contexto foi modelada por meio de ontologias inter-relacionadas para construir as relações entre as classes permitindo que o sistema determine diferentes ações a serem tomadas em relação ao paciente monitorado. O sistema utilizou pulseiras com RFID,

*smartphones* e câmeras para inferir o posicionamento do paciente dentro de um hospital utilizando um sistema de localização *indoor*.

Como resultado do trabalho, o sistema desenvolvido foi testado em ambiente real e conseguiu detectar pessoas em áreas não autorizadas, direcionando-as para a saída mais próxima e alertando enfermeiros e equipe médica sobre a condição dos pacientes monitorados.

Apesar de o sistema possuir as características de um sistema inteligente ainda depende da geração manual das regras de ontologia e de um especialista revisando as regras, além de empregar recursos caros como os portais RFID para leitura de etiquetas por aproximação.

### 3.3 Análise e Modelagem de Redes de Sensores em AmI

No trabalho de Xiaolong Zeng et al. (2013), AmI é abordada na perspectiva de sensores inteligentes, capazes de coletar e fazer fusão de dados a partir do mapeamento de cenários, serviços disponíveis, compartilhamento de informações e interações entre o usuário e os dispositivos. A Figura 11 apresenta um estudo de caso da coleta de dados feita por uma rede de sensores inteligentes que processa as informações para identificar comportamentos do usuário.

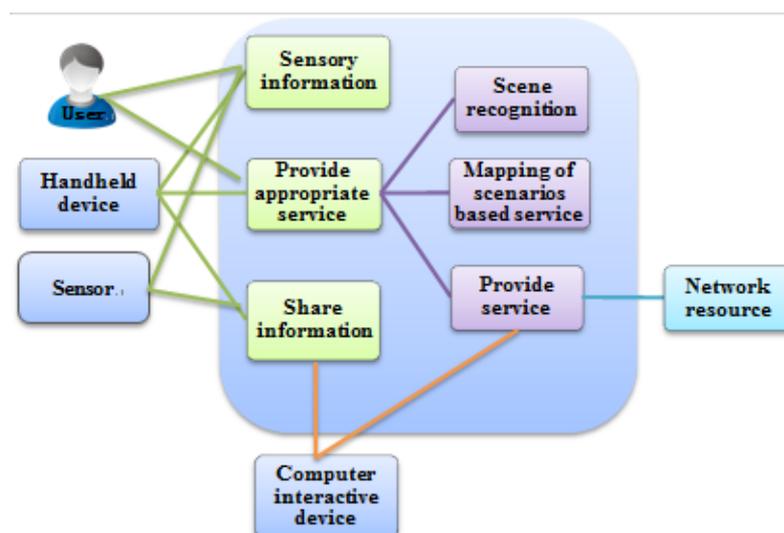


Figura 11. Caso de uso para um sistema de redes de sensores inteligente.  
Fonte: Xiaolong Zeng et al., (2013)

Os autores propuseram um sistema de rede de sensores inteligentes de maneira experimental dividido em três partes: Unidades de sensores conectados via *bluetooth* com *smartphones* para acesso a serviços de dados e voz que coletam, armazenam e processam dados automaticamente; Uma rede dedicada aos serviços de comunicação entre os dispositivos de AmI e as transmissões de dados para a internet, quando necessário; E uma unidade de processamento e controle construída sobre a tecnologia *Field Programmable Gate Array* (FPGA), para controlar os sensores, dispositivos e eletrodomésticos da casa inteligente.

O sistema foi modelado usando *Parallel Object-Oriented Specification Language* (POOSL), para analisar parâmetros de *hardware* e *software* com regras semânticas em ambiente simulado, contudo nada foi construído em ambiente real apenas foram feitas simulações do sistema.

Os autores discutiram sobre AmI e suas características, casos de uso foram apresentados, no entanto, os resultados foram somente de simulações com redes de sensores e um FPGA para processamento e controle.

### 3.4 Ambientes Inteligentes e Tecnologias de Agentes

O trabalho apresentado em Spanoudakis e Moraitis (2015) mostrou como modelar e construir um sistema AmI, utilizando a tecnologia de agentes inteligentes. Foi aplicada a metodologia de Engenharia de Sistemas (ASEME), uma abordagem de engenharia de *software* orientada a agentes. O artigo centra-se na arquitetura de software e no método de desenvolvimento para o domínio de ambientes assistidos de *healthcare*.

O projeto foi realizado por meio de um consórcio entre membros da academia e da indústria e aplicou a metodologia ASEME para desenvolver um sistema multiagente para futuras aplicações reais. O trabalho de Spanoudakis e Moraitis (2015) usa uma combinação de agentes inteligentes com *Web services*, com diferentes sistemas conectados no padrão *plug and play*, por meio de uma plataforma de agentes.

As avaliações da arquitetura foram feitas na primeira fase por meio de um projeto piloto aplicado em um hospital, com o foco em duas categorias

de usuários: pacientes e serviços médicos. Foram selecionados trinta pacientes com diversos históricos médicos e dez especialistas da área de saúde. O objetivo foi avaliar o progresso dos pacientes utilizando o projeto HERA a partir de uma aplicação instalada em um *set-top Box* de TV que monitorava as interações do usuário nos quesitos, assistir vídeo, jogar e assistir TV.

A segunda avaliação foi instalar o mesmo sistema nas residências dos pacientes por quinze dias incluindo a personalização dos serviços aprendidos pelo sistema de agentes e ao final coletar dados por meio de questionário quanto ao desempenho, usabilidade, flexibilidade e segurança. A Figura 12 apresenta o gráfico de avaliação dos dois ambientes testados com os dados da fase um e da fase dois. No experimento C4 as fases um e dois foram as que ficaram mais próximas, 84,00% e 84,22% respectivamente.

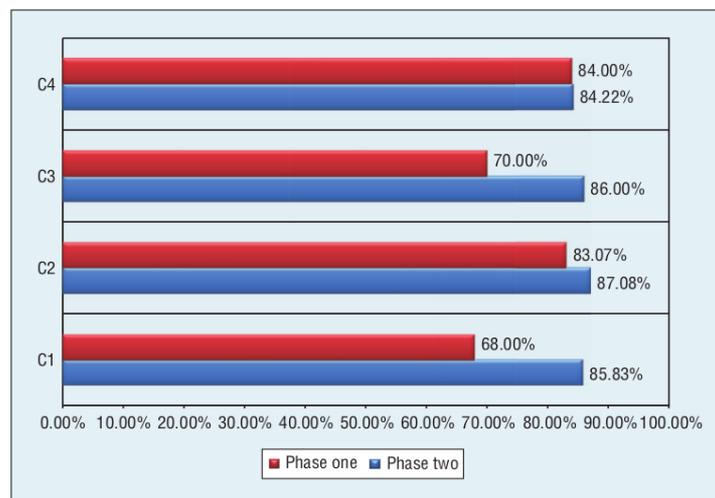


Figura 12. Gráfico com a avaliação e comparação das duas fases do experimento.  
Fonte: Spanoudakis e Moraitis, (2015).

### 3.5 Modelagem de Situações em Casas Inteligentes

Os autores Brdiczka, Crowley e Reignier (2009), desenvolveram um modelo de aprendizagem de situações em residências inteligentes. Propuseram um *framework* para aquisição de contexto, envolvendo diferentes camadas de situações e com diferentes métodos implementados

no *framework* como: detecção de papéis por entidades, extração não supervisionada, aprendizado supervisionado e evolução das situações pré-definidas no modelo de *feedback*. O modelo permite suportar diferentes métodos de extração de características permitindo que o *framework* seja declarativo e intuitivo.

O *framework* proposto usou o algoritmo *Support Vector Machines* (SVM) não supervisionado, baseado em dados extraídos por um *expert* usando histogramas. O experimento é baseado em um sistema 3D que gera e acompanha as rotas em um ambiente inteligente.

O experimento foi desenvolvido em um laboratório usando uma maquete de uma sala de visitas e os equipamentos utilizados foram: uma câmera angular, duas câmeras instaladas nos cantos da sala, uma rede de microfones instalados nas paredes para capturar o ruído e microfones *headset*.

O rastreamento com o *software tracking3-D* utilizou uma instância bayesiana de raciocínio para identificar se o usuário está de pé, sentado ou deitado e usou o algoritmo SVM para verificar a movimentação e as distâncias entre os objetos. A Figura 13 apresenta a modelagem e as interações entre as camadas de velocidade de deslocamento e a distância entre os objetos utilizados no experimento.

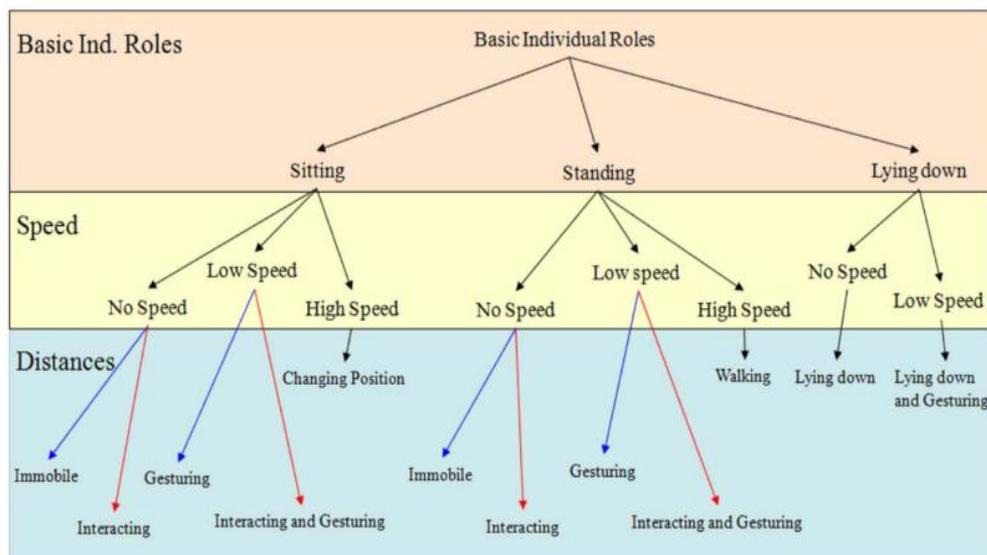


Figura 13. Combinações de atividades individuais.  
 Fonte: Brdiczka, Crowley e Reignier, (2009).

Dois conjuntos de testes foram desenvolvidos para avaliação dos resultados. Um com os dados agrupados que detectou as situações, por exemplo, pessoas jogando, pessoas se conhecendo etc., numa taxa de 96,67%, enquanto um segundo teste com os dados não agrupados obteve 93,33% de acerto das situações que ocorriam no ambiente monitorado.

### 3.6 Framework para Gerenciamento de Contexto Baseado em Web Services Heterogêneos

No trabalho de Takatsuka, Saiki, Matsumoto e Nakamura (2014) foi proposto um *framework* para gerenciamento de serviços baseados em *context-aware* chamado *Rule-based management framework for Context-Aware Services* (RuCAS). Os autores propuseram o uso de *Web services* que disponibilizam serviços de informação, sensores e aplicações em rede.

O *framework* é baseado em regras de evento, condição e ação (ECA) para descrever o contexto. Para isso, um evento é um contexto que aciona o serviço, a condição é um conjunto de contextos a ser satisfeita para a execução, e a ação é um conjunto de *Web services* a ser executado. Cada serviço *context-aware* é gerido uniformemente e depois de publicado pode ser reutilizado por outras aplicações. Como estudo de caso, RuCAS foi aplicado para criação de serviços sensíveis ao contexto em um ambiente real.

Na Figura 14 pode ser observado como um cliente faz a requisição de um serviço baseado em *context-aware* e *Web service*. O cliente registra na base de contexto o parâmetro de temperatura que ele considera quente e associa o valor limite, nesse caso a partir de 28 graus. No outro módulo o cliente associa uma regra para que receba o retorno da aplicação caso a condição seja verdadeira e quando a temperatura atingir o nível programado a aplicação é notificada.

A arquitetura completa do *framework* consiste em cinco camadas distribuídas em: *Web service*, responsável por gerenciar serviços existentes e usá-los como entrada e saída para os serviços de *context-aware*; *Adapter*, que obtêm os dados do *Web service* por meio de API para acessar e disponibilizar os valores; *Context*, para gerenciar todos os contextos

definidos por dados coletados nas camadas de *Web service* e *adapter*, rotulando-os; a camada *Action*, que gerencia todas as ações usada nas regras ECA e a camada de Rules (regras) que monitora os eventos de acordo com as condições de contexto, conforme observado na Figura 15.

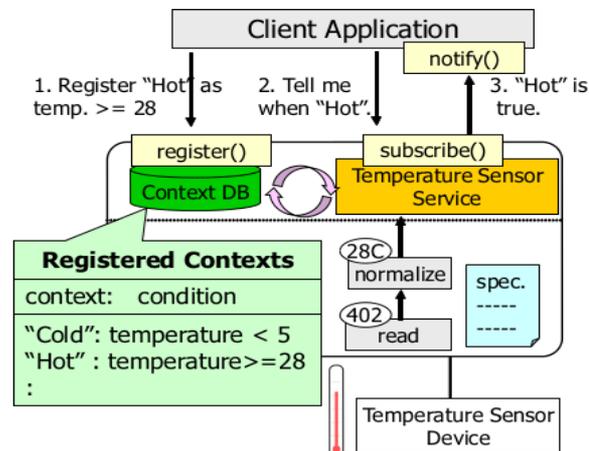


Figura 14. Exemplo de uma requisição feita com base nas informações de contexto.  
Fonte: Takatsuka, Saiki, Matsumoto e Nakamura, (2014).

Os autores testaram o *framework* construindo um serviço de ar condicionado inteligente que identificava quando uma sala estava abafada e um quarto era bem iluminado, o sistema ligava o ar-condicionado e anunciava o serviço convidando os presentes para o ambiente.

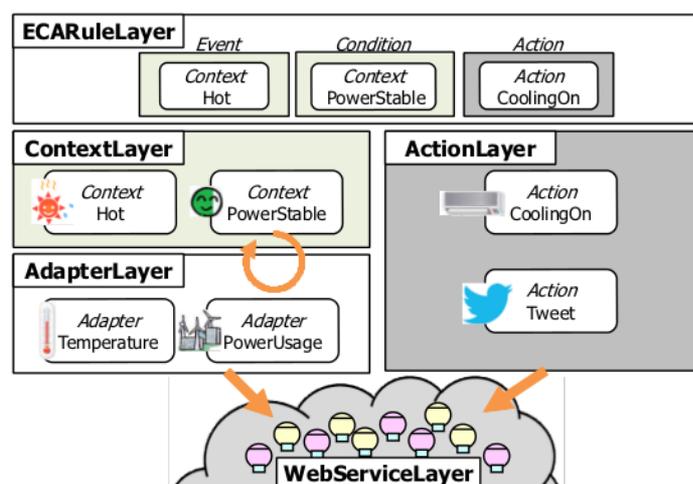


Figura 15. Arquitetura do RuCAS.  
Fonte: Takatsuka, Saiki, Matsumoto e Nakamura, (2014).

Os autores limitaram-se a testar uma arquitetura de contexto com apenas um dispositivo (Ar-condicionado) com temperaturas pré-estabelecidas, no entanto não foram testados outros equipamentos e dispositivos comuns em uma residência, como, televisores, sistemas de sonorização aberturas de portas, etc.

### 3.7 Armário de Medicamentos Inteligente para Auxiliar na Adesão

Em Gomes, Lucena, Yazdi e Göhner (2015), os autores conduziram uma cuidadosa análise dos requisitos envolvidos na tomada de medicamentos para propor uma arquitetura que integrasse um armário de medicamentos inteligente de fácil utilização. O armário foi composto por um conjunto de sensores e atuadores e usou a tecnologia RFID para coletar as informações dos usuários, medicamentos e receitas médicas por meio de cartões. Neste sistema, as *tags* passivas ISO 15693 (13,56 MHz) foram usadas para registrar as informações pessoais do paciente e os detalhes sobre as medicações que foram prescritas pelo médico, bem como a identificação individual de cada medicamento.

O armário de medicamentos possui um sintetizador de voz que informa ao usuário a receita do medicamento e os horários que o mesmo deve ser ingerido. Todos os *logs* provenientes do armário foram armazenados em um banco de dados no sistema de controle do próprio armário. Quanto à inteligência, o trabalho se limitou a processar regras pré-estabelecidas IF THEN ELSE, inseridas diretamente no código e caso as regras mudem é necessário reconstruir o código para inserir tais mudanças.

### 3.8 MediFrame: Uma Aplicação para Lembretes Planejamento e Acompanhamento de Idosos

Em Dalgaard, Gronvall, Verdezoto e Nervo (2013) foi apresentada uma descrição de um processo de design centrado no usuário para a construção de um sistema de gerenciamento pessoal de medicação e um aplicativo para

*tablet* chamado *Mediframe*. O sistema foi projetado para dar suporte a pessoas idosas em ambientes não clínicos como residências.

Os autores afirmam que o *Mediframe* pode ser usado para dar suporte à adesão à medicação em tratamentos médicos e permite o acompanhamento do dia a dia do idoso. A aplicação possibilita aos usuários planejar suas tomadas de medicamentos baseadas nas entradas de dados feitas por meio do próprio aplicativo, e receber lembretes sobre quando tomá-los.

Um ponto positivo do *Mediframe* é não ser dedicado somente a um tipo de doença e cobrir a maioria das situações de tomada de medicação, incluindo os medicamentos receitados como “de acordo com a necessidade” e medicamentos suplementares. Contudo, o *software* foi projetado para ser usado somente em *tablets* o que pode ser considerado como um fator limitador da aplicação. Outra crítica a ser feita, é quanto à entrada de dados de medicamentos feita no próprio aplicativo sem intervenção de um profissional de saúde, o que pode facilitar a automedicação por parte do usuário.

### 3.9 Sistema de Lembretes Móvel para Promover a Adesão do Paciente ao Tratamento

No trabalho de Maglogiannis et al. (2014) foi apresentado um sistema de alerta eletrônico que suporta o uso de dispositivos vestíveis e usa um *smartwatch*. O sistema proposto funciona em um dispositivo *Android* e um relógio inteligente se comunica via *bluetooth* com uma aplicação em um *smartphone* ou *tablet*.

A principal funcionalidade do sistema é a criação de lembretes para tomada de medicamentos usando um computador ou o dispositivo móvel. Esses lembretes são armazenados em uma infraestrutura de nuvem. O paciente é notificado na hora escolhida com alertas sonoros e visuais, existe também a possibilidade de outros usuários registrados usarem um aplicativo da web para criar ou atualizar os lembretes.

O sistema permite que usuários tais como, médicos, farmacêuticos e equipes de saúde acompanhem os lembretes da tomada de medicação e a adesão do paciente é medida automaticamente com o método de auto-relatos. A arquitetura do sistema proposto pode ser vista na Figura 16.

O sistema somente cria lembretes e a entrada de dados é feita manualmente por um usuário do sistema web. A adesão é medida apenas pela confiança no usuário por meio de auto-relatos que são armazenados para avaliação a posteriori.

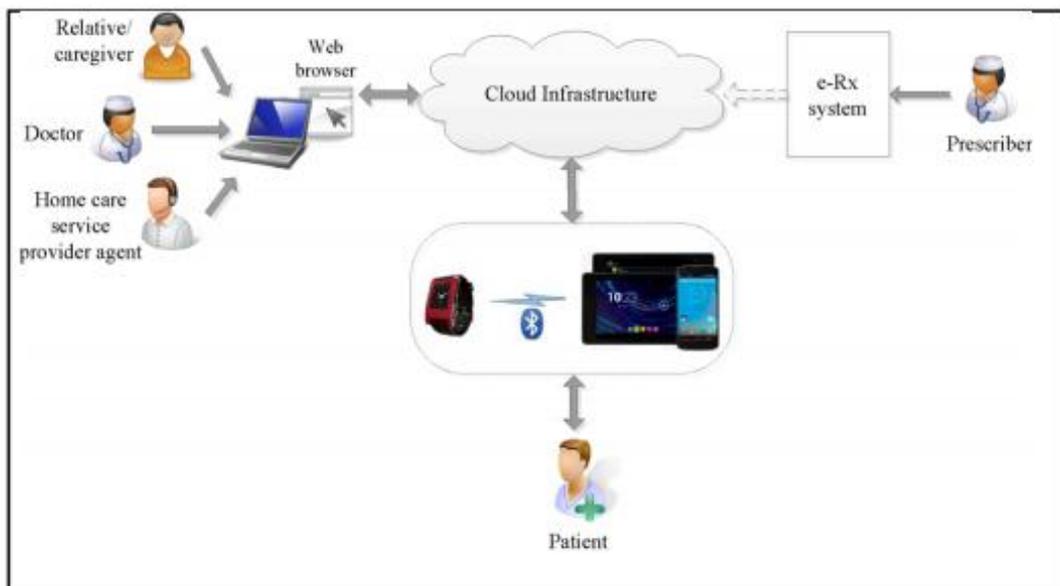


Figura 16. Arquitetura do sistema de lembretes.  
Fonte: Maglogiannis et al., (2014).

### 3.10 Uma Abordagem de AM para Monitorar a Adesão

No trabalho de Hezarjaribi, Fallahzadeh e Ghasemzadeh (2016) foi apresentado um sistema de monitoramento da adesão a medicamentos por rastreamento de atividade do usuário baseado em sensores vestíveis (pulseira eletrônica). Os autores usaram uma aplicação integrada com algoritmos de aprendizado de máquina que rastreiam os movimentos do pulso em tempo real e identificam as atividades de ingestão de medicamentos. Foi proposto um pipeline de análise de dados para detectar com segurança a aderência à medicação examinando os movimentos de um

único pulso. O sistema atinge uma precisão de 78,3% na detecção de aderência sem necessidade de caixas de remédios e com apenas um sensor usado em cada um dos pulsos.

Segundo os autores, a precisão do algoritmo é apenas 7,9% menor do que um sistema com dois sensores que rastreiam movimentos de ambos os pulsos. A técnica de monitoramento de movimento desenvolvida no trabalho baseia-se em metodologias de aprendizagem supervisionada e foram aplicados classificadores de árvore de decisão em uma base de dados de características estatísticas dos movimentos das mãos. A Figura 18 apresenta o fluxo do processo desenvolvido no trabalho.

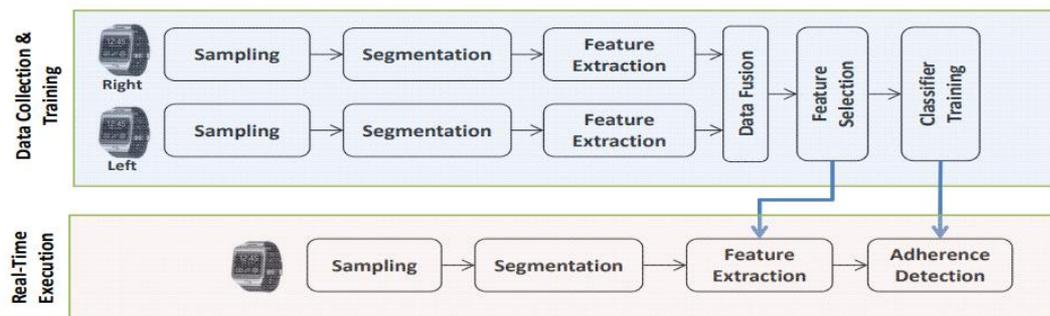


Figura 17. Fluxo do processo de coleta, treinamento e detecção da adesão  
Fonte: Hezarjaribi, Fallahzadeh e Ghasemzadeh, (2016).

### 3.11 Classificação de Uso de Medicamentos em Redes Sociais

No trabalho de Phan et al.(2017) os autores apresentaram uma técnica de monitoramento de mídias sociais para verificar, por meio de algoritmos de aprendizado de máquina, o uso abusivo de prescrições de medicamentos e de drogas ilegais.

Os autores coletaram dados da base do *twitter* que indicavam abuso de medicamentos e de drogas ilegais. O experimento comparou um conjunto de analisadores com o algoritmo de árvore de decisão J48 e SVM para determinar quais *tweets* continham sinais de abuso de drogas. Após o processamento dos dados pelos algoritmos, o algoritmo J48 classificou o uso abusivo de drogas ilegais com 74,8% de acurácia. A Figura 18 apresenta as

etapas do sistema de detecção de abuso de drogas: (1) Coleção de *tweets* através da API de streaming; (2) Gerenciamento de dados usando SGBDs; (3) *tweets* reprocessados e filtrados são alimentados na análise de dados e sistemas inteligentes artificiais para identificar *tweets* de abuso de drogas; (4) sistemas treinados usados em diferentes serviços de monitoramento de abuso de drogas.

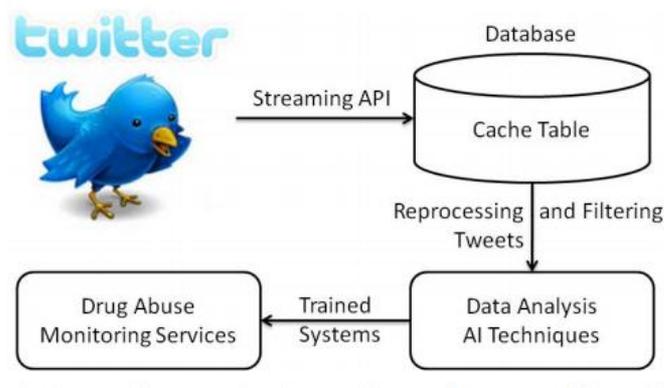


Figura 18. Etapas do Sistema de Detecção  
Fonte: Phan et al., (2017).

### 3.12 Melhoria da Acurácia da Predição em Árvore de Decisão

Um método para melhorar a precisão para mineração de árvores de decisão com pré-processamento de dados foi apresentado por Chandrasekar et al. (2017). Os autores aplicaram o filtro supervisionado para dados discretos no algoritmo J48 para construir uma árvore de decisão. Os resultados foram comparados com o J48 sem filtro de dados discretos.

O conjunto de dados de treinamento utilizado foi composto por 38 exemplos divididos em duas classes rotuladas para dois tipos de Leucemia. Os autores usaram a abordagem de validação cruzada usando o algoritmo J48, uma versão implementada em Java do C4.5.

Os resultados obtidos em experimentos mostraram que a precisão do J48 após a discretização é melhor que a J48 antes da discretização. Os autores usaram o conjunto de dados de leucemia com o método de discretização Fayyad-Irani incorporado na ferramenta weka.

As precisões obtidas pela combinação da Classificação J48 sem discretização e com discretização foram realizadas no conjunto de dados de treinamento e teste com aproximadamente 2,63% para o conjunto de dados de treinamento e 10,53% para o conjunto de dados de teste.

### 3.13 Contribuições dos Trabalhos Relacionados

Dos trabalhos relacionados foram extraídas as contribuições para o desenvolvimento desta Tese de Doutorado conforme listadas a seguir:

- Zamora-Izquierdo et al. (2010), o modelo de arquitetura centralizada e em camadas proporcionou uma visão geral para o desenvolvimento da arquitetura deste trabalho;
- Dingli, Abela e D'Ambrogio (2011), proporcionaram a ideia da construção de uma arquitetura baseada em contexto utilizada neste trabalho;
- Xiaolong Zeng et al. (2013), facilitou o entendimento do mapeamento de cenários e contribuiu para o uso de sensores na coleta de dados deste trabalho.
- Spanoudakis e Moraitis (2015), o uso de set-top Box de TV que monitorava as interações do usuário nos quesitos, assistir vídeo, jogar e assistir TV inspirou o uso de mensagens para a TVDi utilizadas neste trabalho;
- Brdiczka, Crowley e Reignier (2009), o modelo de aprendizagem de situações em residências inteligentes com dados de contexto proporcionou a inspiração para a camada de razão do nosso trabalho;
- Takatsuka, Saiki, Matsumoto e Nakamura (2014), um framework para gerenciamento de serviços baseados em context-aware, o trabalho contribuiu para o desenvolvimento da base de dados e da camada de razão do nosso trabalho.
- Gomes, Lucena, Yazdi e Göhner (2015), este trabalho de doutorado usou os dados do armário de medicamentos e integrou o sistema, com algoritmos de árvore de decisão para construção de serviços

web/mobile e reconhecimento facial que permitiram o monitoramento da adesão aos medicamentos de pacientes monitorados remotamente.

- Dalgaard, Gronvall, Verdezoto e Nervo (2013), o sistema de gerenciamento pessoal de medicação com aplicativo para tablets, inspirou o uso de avisos para tomada de medicamentos para smartphones desenvolvido neste trabalho de doutorado;
- Maglogiannis et al. (2014), o sistema de alerta eletrônico que suporta o uso de dispositivos vestíveis e usa um smartwatch contribuiu com a ideia da integração dos cenários de aplicativos conectados com consultórios médicos apresentados na presente Tese.
- Hezarjaribi, Fallahzadeh e Ghasemzadeh (2016), o sistema de monitoramento da adesão a medicamentos por rastreamento de atividade do usuário baseado em sensores vestíveis inspirou a coleta de dados do smartphone utilizado no presente trabalho para auxiliar no controle de ingestão de medicamentos.
- Phan et al.(2017), a técnica de monitoramento de mídias sociais utilizadas nesse artigo serviu para investigar a integração do nosso trabalho com as redes sociais Twitter e Telegram usando os algoritmos de árvore de decisão para as inferências sobre a adesão a medicamentos.
- Chandrasekar et al. (2017), as aplicações de filtros supervisionados para dados discretos usando o algoritmo J48 influenciou o uso da técnica no presente trabalho.

Os trabalhos relacionados apresentados na Tabela 3 diferem do presente trabalho, pois além da notificação de mensagens curtas para *smartphones*, também é utilizada as redes sociais como ferramentas de notificação, além de utilizar algoritmos de aprendizado de máquina para prever a adesão do paciente ao medicamento integrando o sistema com a residência do paciente e com o consultório médico.

Tabela 3. Comparação entre os trabalhos relacionados e a Tese.

Trabalhos	Contexto	Tomada de decisão	Ontologias	Ag. inteligentes	Abordagem	Redes sociais	Mens. Automática
Zamora Izquierdo (2010)	Não	Sim	Não	Não	Protocolo e regras próprias IF THEN ELSE.	Não	Não
Dingli (2011)	Não	Sim	Sim	Não	Uso de especialistas para definir as regras.	Não	Não
Xiao long (2013)	Sim	Sim	Não	Não	Coleta de dados com sensores conectados a um smartphone e regras IF THEN ELSE.	Não	Não
Spanoudaki (2015)	Sim	Sim	Não	Sim	Agentes inteligentes combinados com web services.	Não	Não
Brdiczka (2009)	Sim	Sim	Não	Não	Uso do algoritmo SVM em conjunto com regras extraídas com auxílio de especialista.	Não	Não
Takatsuka (2014)	Sim	Sim	Não	Não	Base de regras de contexto com eventos associados.	Não	Sim
Gomes (2015)	Não	Sim	Não	Não	Protocolo e regras próprias IF THEN ELSE com apoio de webservice.	Não	Sim
Dalgaard (2013)	Não	Sim	Não	Não	Protocolo e regras próprias IF THEN ELSE com apoio de webservice.	Não	Sim
Maglogiannis (2014)	Não	Sim	Não	Não	Geração de lembretes por meio de uma aplicação web para ser lido por um smartphone.	Não	Sim
Hezarjaribi (2016)	Sim	Sim	Não	Não	Classificador baseado em árvores de decisão para determinar a adesão pelo movimento do pulso.	Não	Sim
Phan (2017)	Sim	Sim	Não	Não	Árvore de decisão aplicado a uma base do twitter.	Sim	Sim
Chandrasekar, (2017)	Não	Sim	Não	Não	Aplica Filtro de dados para melhorar a detecção das classes com o algoritmo J48.	Não	Não
Este Trabalho	Sim	Sim	Não	Não	Aplica filtros, algoritmos baseados em árvore de decisão, votação entre classificadores e mensagens automáticas para acompanhar a adesão.	Sim	Sim

### 3.14 Considerações Finais sobre o Capítulo

Este Capítulo apresentou os trabalhos relacionados comparados com o trabalho proposto. Os trabalhos foram avaliados de acordo com as características das arquiteturas de AmI e *Context-aware*, sistemas de *healthcare* e adesão de medicamentos.

Os trabalhos foram tabulados e comparados pela abordagem utilizada que são os algoritmos para auxiliar na tomada de decisão tais como regras ontológicas, agentes inteligentes e árvore de decisão, além do modelo de comunicação entre os sistemas de mensagem. Foram extraídas as características principais da área de interesse do presente trabalho, os quais deram origem à concepção da arquitetura que será apresentada no Capítulo 4 da presente Tese.

A principal contribuição desde capítulo foi na concepção do modelo do sistema, planejamento dos módulos da arquitetura e na integração com os sistemas de mensagens em redes sociais e mensagens privadas.

## Capítulo 4 Concepção da Arquitetura

Este capítulo apresenta a concepção da arquitetura do sistema proposto para a integração de sensores com o intuito de coletar os dados para aplicação de técnicas de aprendizado de máquina e treinamento do sistema de decisão baseados em dados de contexto.

A arquitetura proposta para o desenvolvimento do trabalho é exposta na forma de diagrama de blocos e será exibida nos tópicos a seguir.

### 4.1 Visão Geral da Arquitetura

A arquitetura é dividida em quatro camadas que permitem receber dados de entrada adquiridos por sensores e dispositivos diversos, instalados em uma residência ou escritório para em seguida, fazer o pré-processamento e posteriormente definir as políticas e estratégias para a tomada de decisão. No final do processo os serviços de mensagens baseados nos dados são utilizados como resposta para os atuadores e dispositivos da residência e armazenados em uma base de serviços. A Figura 19 apresenta a arquitetura que será discutida nas subseções a seguir.

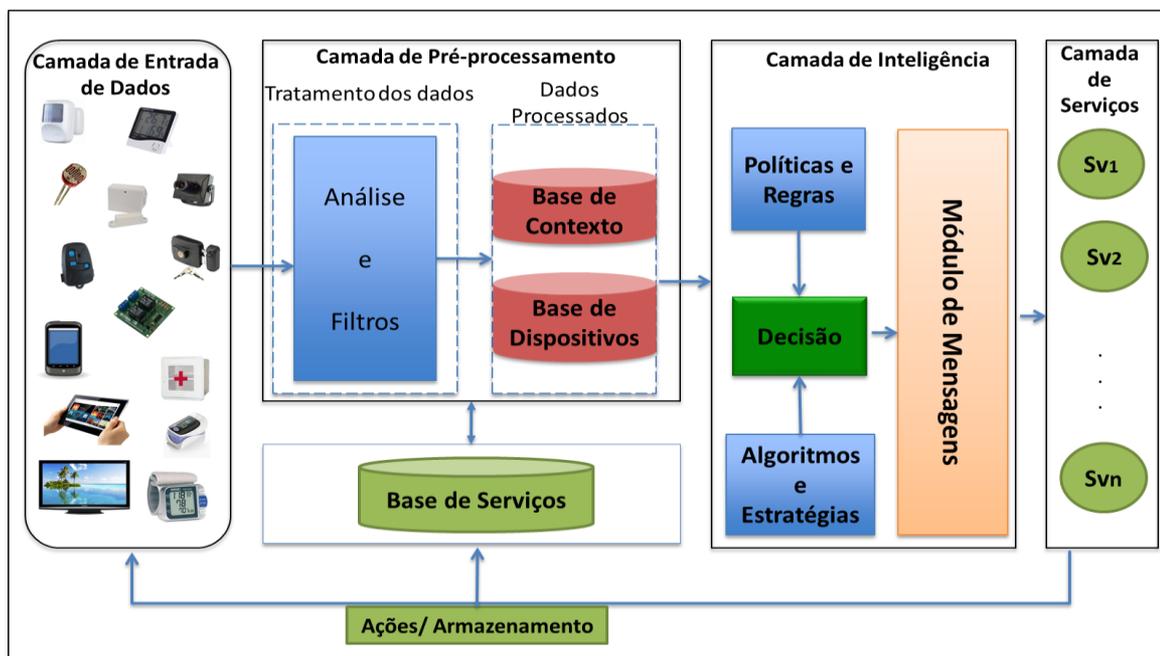


Figura 19. Visão Geral da Arquitetura.  
Fonte: Elaborado pelo autor.

## 4.2 Camada de Entrada de Dados

A camada de entrada de dados dos dispositivos considera diversos equipamentos representados por câmeras, sensores de presença, luminosidade, portas automáticas, temperatura, além de dispositivos pertencentes à residência, como computadores, *tablets*, TV, *smartphones*, *smartwatch*, armário de medicamentos, entre outros, que têm como tarefa coletar os dados do ambiente e do usuário.

O armário de medicamentos possui sensores e atuadores próprios embarcados em seu gabinete e o mesmo é tratado como um dispositivo residencial como a *smart tv* e outros eletrodomésticos. Os dados coletados são as prescrições médicas e os alarmes disponibilizados pelo armário de medicamentos e após a coleta, os mesmos são analisados e filtrados para constituir as bases de dados contextuais e de dispositivos.

As atividades de entrada, saída e permanência do paciente no ambiente são coletadas por meio de sensores de abertura e fechamento das portas, as imagens são coletadas por uma câmera *Universal Serial Bus* (USB), conectada na porta de entrada da residência e no armário de medicamento e, em seguida são armazenados em um banco de dados que serve para identificar os padrões de acesso ao armário e o uso dos remédios armazenados nele.

## 4.3 Camada de Pré-processamento

A camada de pré-processamento foi subdividida em: tratamento dos dados, que analisa e filtra os dados recebidos da camada de dispositivos; dados processados; armazenamento do resultado nas bases de contexto e de dispositivos e por uma base de serviços armazenados no final de todo o processo. Os dados para o pré-processamento consistem no mapeamento dos atributos do conjunto de dados, independentemente do tipo e da escala. O tipo de atributo pode ser qualitativo ou quantitativo, e a escala, que define as operações que podem ser realizadas com os atributos, pode ser nominal, racional ou intervalar (LORENA, 2011).

### 4.3.1 Análise e Filtros

A análise consiste em preparar os dados para descrever os objetos por meio de um vetor de características (LORENA, 2011). Os dados de localização coletados de dispositivos móveis foram usados para determinar as variáveis de contexto conforme apresentadas no trabalho de Yachir (2016). As principais variáveis são o tempo de permanência do indivíduo na residência e suas atividades durante os horários previstos para a ingestão dos medicamentos.

A filtragem na camada de pré-processamento extrai as características para identificar grupos e objetos semelhantes no conjunto de dados e regras de associação que relacionam esses grupos para encontrar dados relevantes. Os filtros utilizados foram adaptados do trabalho de Hall et al. (2000), utilizados no software weka para limpeza da base de dados e modificação dos tipos de dados do atributo quando necessário.

### 4.3.2 Conjunto de Dados

O conjunto de dados que compõe as bases de contexto e de dispositivos foi coletado dos sensores do armário de medicamentos e de outros equipamentos instalados na residência. Possuem atributos capazes de representar uma pessoa, um objeto físico, um local específico, as atividades do paciente e as prescrições médicas eletrônicas armazenadas no banco de dados do armário. A base de atividades foi construída inspirada no trabalho de Tapia (2004), os autores instalaram 77 sensores em uma residência e 84 em uma segunda residência com objetivo de coletar dados de atividades de indivíduos e classificá-las seguindo um padrão estabelecido.

Um extrato da base construída neste trabalho coletado da prescrição é apresentado na Tabela 4. Os horários da prescrição e o estado da aplicação de mensagens dos dispositivos de avisos na TV e no smartphone. Neste caso, os dados ainda não foram devidamente classificados, apenas coletados dos dispositivos instalados na residência do paciente.

**Tabela 4.** Uma amostra do conjunto de dados da prescrição eletrônica.

Identificador	Medicamento	Dose em mg	Hora prevista	Hora ingerida	Resposta das aplicações de lembrete
PA1	Clortalidona	12.5	08:00:00	08:00:00	0
PA2	Clortalidona	25	09:00:00	09:00:00	0
PA3	Hidroclorotiazida	25	08:00:00	08:00:00	0
PA4	Hidroclorotiazida	50	08:00:00	nulo	1
PA5	Idapamida	10	08:00:00	10:00:00	2

A Tabela 4 apresenta os dados de identificação do paciente (PA1, PA2, PA3, PA4 e PA5), o medicamento, a dosagem prevista em miligramas, a hora prevista para a ingestão dos medicamentos, a hora da ingestão capturada pelo aplicativo de lembrete e os estados 0, 1 e 2, que representam respectivamente se o paciente ingeriu o medicamento, não ingeriu, ou atrasou a ingestão.

Os horários para a ingestão de medicamentos iniciam pela primeira vez quando o aplicativo de avisos desenvolvido em Android informa o horário ao paciente e o retorno é fornecido pelos aplicativos da TV e smartphone. Dependendo do tipo de aviso e os dados de localização do paciente, eles são enviados para a TV, tablet, smartphone e/ou redes sociais por meio de um protocolo de comunicação baseado em JavaScript Object Notation (JSON) e eXtensible Markup Language (XML) que é lido por todos os dispositivos conectados.

A representação formal dos dados é feita por meio de uma matriz de objetos dada pela Equação (11). Onde  $X$  é a matriz composta por  $n$  que representam o número de objetos e  $d$  o número de atributos de entrada de cada objeto (LORENA 2011). O valor de  $d$  define a dimensionalidade dos objetos, espaço de entrada ou espaços de atributos. A Tabela 5 apresenta um exemplo dos dados coletados de dois sensores de abertura P1 e P2, respectivamente representando a porta de entrada da residência e do armário de medicamentos.

$X n_x d$ 

(11)

Na Tabela 5 são apresentados os dados de identificação das aberturas de portas com identificação do paciente que a abriu e a atividade que ocorreu na residência, nesse caso abertura e fechamento de portas com data e hora do acionamento. Onde E1aberta corresponde à abertura da entrada principal da residência, E2aberta, corresponde à porta do armário, EP e AR, os locais correspondentes à entrada principal da residência e o armário de medicamentos.

**Tabela 5.** Representação dos dados de acesso à residência e ao armário de medicamentos.

<b>Identificador</b>	<b>Atividade</b>	<b>Data</b>	<b>Hora</b>	<b>Local</b>
PA1	E1aberta	21/06/2013	08:00:00	EP
PA2	E1fechada	21/06/2013	09:00:00	EP
PA2	E2aberta	21/06/2013	08:00:00	AR
PA2	E2fechada	21/06/2013	08:00:00	AR
PA1	E1aberta	23/06/2013	10:00:00	EP

O conjunto de dados pode ser armazenado em um banco relacional, uma estrutura de dados de vetores e matrizes ou em documentos bem formados. Também pode ser utilizado um arquivo de texto legível por ferramentas de mineração de dados e aprendizagem de máquina tais como, a ferramenta Weka.

Observando os dados das Tabelas 4 e 5, é possível determinar qual é o atributo alvo a ser buscado. Em uma observação baseada nos horários descritos para cada usuário pode ser feita a verificação das entradas na residência e a abertura do armário de medicamentos. É possível estimar se o usuário toma seus remédios corretamente ou não, considerando os dados de contexto das ações do usuário no sistema de decisão.

## 4.4 Camada de Inteligência

A camada de inteligência representa a tomada de decisão do sistema e está dividida em quatro subsistemas que são as políticas, que contém as regras para o subsistema de decisão, as estratégias, que contém os algoritmos para as inferências e o módulo de mensagens, responsável por enviar SMS, e mensagens curtas para as redes sociais.

### 4.4.1 Regras de Decisão

As regras de decisão também chamadas de regras de classificação são compostas por: “SE <condição> ENTÃO <conclusão>”, onde a condição são os atributos e a conclusão é o resultado da classificação no conjunto de dados (WITTEN, 2016). As regras podem ser geradas a partir do conjunto de dados por meio de algoritmos de indução de regras ou ainda por meio de uma árvore de decisão.

Os experimentos com as políticas baseadas em regras de produção, apresentado no trabalho de Russell e Norvig (2016) e apresentadas na Figura 20 foram aplicados na camada de inteligência. Nesse caso foram consideradas a operação booleana “AND” e “OR” para satisfazer as condições verdadeiras e falsas conforme as entradas do problema.

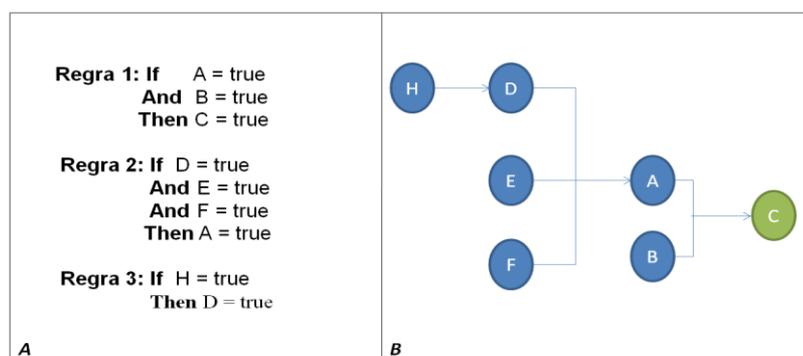


Figura 20. Exemplo de um encadeamento de regras.  
Fonte: Adaptado de Russell e Norvig, (2016).

No exemplo da Figura 20 A, o resultado do processamento da Regra 1 indica que se as condições de “A” e de “B” forem verdadeiras, então o resultado final de “C” será verdadeiro. A Regra 2 verifica se “D”, “E” e “F”

são verdadeiros neste caso “A” também é verdadeiro. A Regra 3 verifica se “H” é verdadeiro então isso implica que “D” também seja verdadeiro executando todas as regras em cadeia.

Essa técnica pode ser aplicada em um conjunto de dados para extrair certos comportamentos do usuário durante a ingestão de um medicamento, por exemplo, considerando se o paciente ingeriu, não ingeriu ou ingeriu atrasado o medicamento receitado. A Figura 20 B apresenta o gráfico gerado durante o processamento das regras em cadeia. As operações dadas nas equações (12), (13) e (14) demonstram as regras sendo executadas.

Nesse exemplo pode se observar que o resultado final “C”, será possível a partir do resultado das operações anteriores combinadas entre si e nesse caso, “C” será a resposta para as premissas das regras um, dois e três. As regras de produção em conjunto com os modelos de decisão são aplicadas no conjunto de dados por meio da codificação dos modelos que melhor classificam os dados.

$$A \wedge B \rightarrow C \quad (12)$$

$$D \wedge E \wedge F \rightarrow A \quad (13)$$

$$H \rightarrow D \quad (14)$$

#### 4.4.2 Modelos de Decisão ou Classificação

O problema de aprendizado de máquina pode ser formulado como um problema de busca num espaço de possíveis soluções (LORENA 2011). Dado um conjunto de hipóteses a busca é feita considerando a representação definida pelas generalizações de exemplos. Os modelos que podem ser utilizados para a busca são as árvores de decisão e os modelos baseados em regras.

Um modelo utilizado para auxiliar na classificação são os algoritmos de indução para árvores de decisão, demonstrado neste trabalho para identificar se o conjunto de dados gera ou não um aviso (QUINLAN, 1986). O aviso gerado é armazenado como um serviço de mensagem que pode ser enviado ao médico, equipe de saúde ou nos próprios dispositivos instalados

na residência contendo a data, hora, dosagem e o medicamento que deve ser tomado, além da situação do padrão de ingestão, ingestão atrasada e a não ingestão. O algoritmo genérico para construção de uma árvore de decisão é dado na Figura 21.

---

**Algoritmo 1.** Algoritmo para construção de uma árvore de decisão

---

**Entrada:** Um conjunto de treinamento  $D = \{(x_i, y_i), i = 1, \dots, n\}$

**Saída:** Árvore de Decisão

```

1 /*Função GeraÁrvore(D) */;
2 se critério de parada(D) = Verdadeiro então
3   Retorna: um nó folha rotulado com a constante que minimiza a função perda;
4 fim
5 Escolha o atributo que maximiza o critério de divisão em D;
6 para cada partição dos exemplos Di baseado nos valores do atributo escolhido faça
7   Induz uma sub árvore  $\hat{Árvore}_i = \text{GeraÁrvore}(D_i)$ ;
8 fim
9 Retorna: Árvore contendo um nó de decisão baseado no atributo escolhido, e descendentes  $\hat{Árvore}_i$ ;

```

---

Figura 21. Algoritmo genérico para árvore de decisão.  
Fonte: Adaptado de Lorena, (2011).

O algoritmo consiste em receber um conjunto de treinamento  $D$  na entrada por meio da função *GeraÁrvore* e retorna na saída uma árvore de decisão. O algoritmo avalia o critério de parada e se forem necessárias mais divisões do conjunto de dados, é escolhido o atributo que maximiza alguma medida de impureza, passo 5. No passo 7, a função *GeraÁrvore* é chamada recursivamente para cada partição do conjunto de dados  $D$  e por fim no passo 9, o algoritmo retorna a árvore contendo um nó de decisão baseado no atributo escolhido.

Os algoritmos testados nos experimentos usam o conceito da entropia apresentado no trabalho de Quinlan (2014), que mensura o ganho da informação e determina quais atributos possuem maior probabilidade de serem utilizados no classificador.

A representação gráfica da árvore de decisão contém um conjunto de nós e arestas, os nós se estendem na árvore até as folhas e as arestas fazem a conexão de todos os nós.

A Figura 22 apresenta uma árvore de decisão que responde se um determinado paciente continua ou não o tratamento baseado nas reações e efeitos adversos durante a ingestão do medicamento.

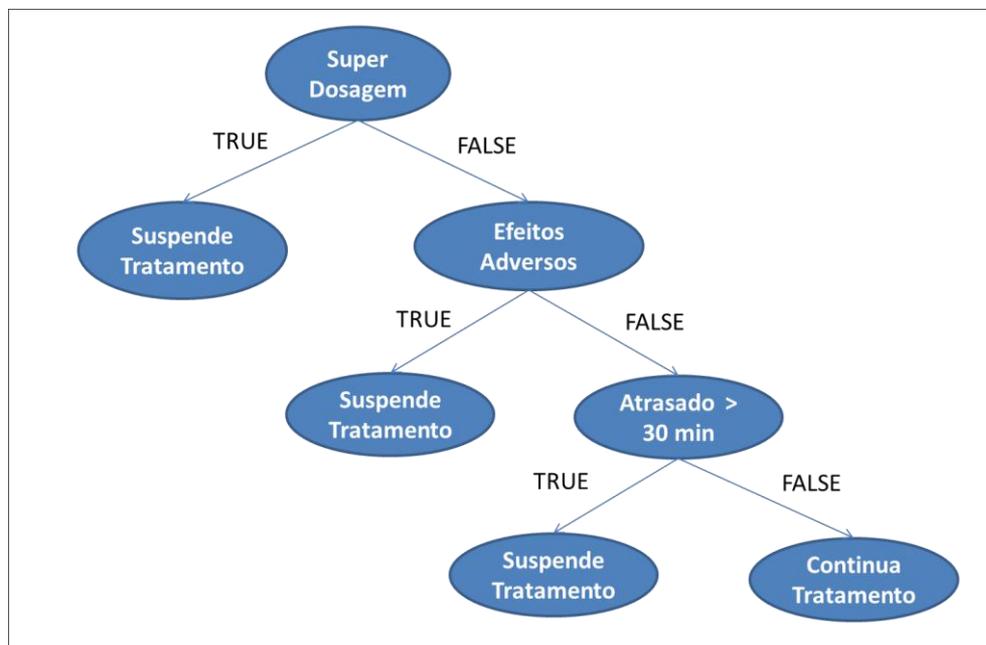


Figura 22. Árvore de decisão para o problema de tomada de medicamentos  
Fonte: Adaptado de Witten et al., (2016).

Neste caso uma instância do problema em que a “Super Dosagem” foi escolhida como o atributo que apresenta o maior ganho da informação, pode ser usada para classificar a saída como: “Suspende Tratamento” ou “Continua o Tratamento”. Assim, uma sequência observável na árvore de decisão dada na Figura 22 para suspender o tratamento é “Super Dosagem = TRUE”.

As árvores de decisão são bastante utilizadas na resolução de problemas de classificação para auxiliar na tomada de decisão em domínios científicos e principalmente em diagnósticos médicos e é especializada em problemas binários.

As estratégias para auxiliar na decisão variam desde o uso de algoritmos para agentes inteligentes baseados em utilidades Russell e Norvig (2016), a métodos probabilísticos e modelos descritivos Lorena (2011), isso depende da escolha do método a ser desenvolvido subsistema de estratégias que é parte desta arquitetura. O subsistema de decisão por meio das políticas e das estratégias estabelecidas define quais os serviços que podem ser disponibilizados para o usuário a partir da percepção atual e do histórico e gera uma lista de serviços disponíveis.

#### 4.5 Camada de Serviços

A camada de serviços gerados a partir dos dados classificados permite que o resultado da camada de inteligência seja usado para a apresentação do processamento e exiba o resultado em várias aplicações. Para experimentar o sistema de mensagem automática proposto nesta Tese foram construídos protótipos para enviar mensagens a smartphones por meio *Short Message Service*, (SMS) e das redes sociais. As redes sociais testadas foram o Twitter e o Telegram, pois, ambos permitem a escrita de postagens automáticas usando suas respectivas APIs.

Os aplicativos construídos para esse fim serão apresentados na subseção de construção de protótipos. Foram desenvolvidos protótipos para geração de lembretes para ingestão de medicamentos para *smart TV* e *smartphones*. Os serviços de mensagens criados em tempo de execução são armazenados na base de dados de serviços que serve para manter um histórico de todas as mensagens enviadas.

#### 4.6 Desenvolvimento dos Protótipos Baseados na Arquitetura

Os protótipos para coleta e extração de dados foram desenvolvidos baseados nos dois cenários apresentados no Capítulo 1 que diz respeito ao consultório no qual o médico por meio de um sistema de cadastro de receitas, prescreve os remédios para seus pacientes e os disponibiliza em um serviço web que se encarrega de carregá-las no dispositivo móvel do paciente para gerar os alarmes sobre a tomada de medicamentos.

O segundo cenário é baseado no dispositivo móvel do paciente, que pode ser um *tablet* ou um *smartphone*. Neste cenário, o *smartphone* recebe a receita e gera os alarmes de tomada do medicamento, baseado nos dados da receita e nos dados de localização do paciente. Se o paciente estiver em sua residência, o dispositivo dispara o alarme de tomada de medicamento em seu *smartphone* e em dispositivos de mídia, por exemplo, a smart TV. Se o paciente estiver fora da residência, o alarme é apresentado somente no *smartphone* do paciente. Os protótipos serão apresentados a seguir.

#### 4.6.1 Gateway Residencial

O *gateway residencial* (GR) foi desenvolvido na plataforma X86, composto por um processador Intel Atom de dois núcleos uma placa mãe AsRock modelo A945GC, equipada com *chipset* da Intel com placa de rede gigabit Ethernet, e placas de som e vídeo integrados. Possui um *gigabyte* de memória RAM e 500 *gigabytes* de disco.

O sistema operacional instalado no *gateway* foi uma distribuição Linux Debian versão 9.0 e os servidores web foram o Apache com PHP e o NodeJS. Para a programação da leitura dos dados de sensores do armário e da residência foram utilizadas as linguagens de programação LUA, NCL e Java.

Foram instaladas também as bibliotecas de comunicação que utilizam a porta serial RXTX Java e SMSLIB, ambas escritas em Java que permitem a coleta de dados de sensores e o envio de SMS.

#### 4.6.2 Protótipo para Coleta e Armazenamento de Dados

Na construção dos protótipos de software para coletar os dados, integrar com a web e com dispositivos móveis foram utilizados uma *smart TV*, um *smartphone* e o *gateway* residencial já apresentado.

A Figura 23 apresenta um exemplo do sistema de mensagens entre o protótipo desenvolvido e o armário de medicamentos. Observa-se que ao abrir a porta do armário o sistema mostra a data, hora e o local da abertura. O armário armazena os dados utilizando etiquetas e cartões RFID e interage com o usuário por meio de avisos sonoros e luminosos. Os dados são

armazenados no GR e em seguida são transformados em uma base textual para aplicar os algoritmos de identificação de padrões de tomada de medicamentos.

Os atributos coletados da base de dados são os medicamentos, dosagem, hora prevista para a ingestão, hora da ingestão e as classes como: interrompe tratamento, normalidade, automedicação, adesão e não adesão, além da resposta dos alarmes dos aplicativos da TV e do *smartphone* armazenados quando o paciente interage com o sistema.

No exemplo apresentado nas Figuras 23 A e 23 B, observa-se a captura da abertura e fechamento da porta do armário de medicamentos feita pela aplicação de monitoramento do armário e respectivamente as Figuras 23 C e 23 D, mostram os dados da interação do usuário com o armário de medicamentos, sendo armazenados em base de dados. Neste caso, um *log* do sistema é gerado informando a data e a hora da abertura bem como o local e a identificação de quem interagiu com o armário.



Figura 23. Armário de medicamentos e protótipo de coleta de dados.  
Fonte: Elaborado pelo autor.

#### 4.6.3 Protótipo Desenvolvido para a TV Digital e *Smartphone*

O protótipo para a aplicação de TV Digital Interativa (TVDi) foi construída usando as linguagens NCL e Lua usadas no Padrão Brasileiro de TV Digital. O protótipo foi usado para mapear os estados da aplicação NCL-LUA embarcada no *set top Box*, (STB). Permite que o paciente informe a tomada pressionando o botão verde do controle remoto ou pressionando o botão vermelho no caso em que o paciente por algum motivo, decida não tomar o remédio receitado.

A tela do sistema da TVDi somente destrava se o usuário apertar um dos botões (vermelho ou verde) e caso o paciente desligue a aplicação por força bruta, o sistema considera que o medicamento não foi tomado gerando um estado de erro. A Figura 24 A, apresenta o protótipo travando a tela de programação da TV com uma mensagem do tipo *pop-up* informando o nome do paciente, o horário e a dose do medicamento a ser ingerido.

A Figura 24 B mostra a aplicação móvel fazendo a notificação da ingestão de medicamentos. O exemplo da aplicação executando na TV no qual trava a tela do *smartphone* até que o usuário aperte o botão sim ou não do aplicativo é equivalente aos botões verde e vermelho da aplicação da TVDi. Os dados da tomada de medicamentos por meio dos lembretes da TVDi e do *smartphone* são coletados e direcionados para a base de dados para serem analisados.

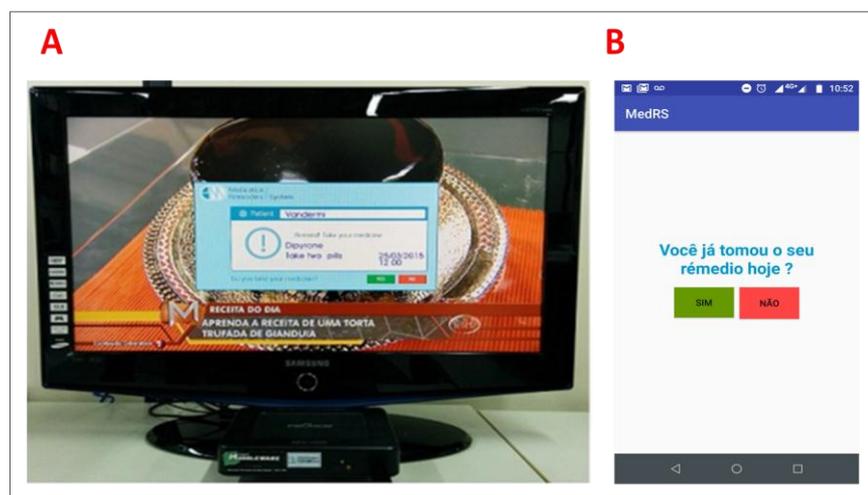


Figura 24. Protótipos desenvolvidos para coleta de dados.  
Fonte: Elaborado pelo autor.

#### 4.6.4 Modelo de Comunicação Desenvolvido para a TVDi, Web e Smartphone

O modelo foi desenvolvido por meio de uma arquitetura de comunicação para o sistema de mensagens da TVDi, *web* e *smartphone*, a partir dos dados processados e classificados, a aplicação web constrói as mensagens e devolve o retorno para a equipe de saúde. A Figura 25 mostra um exemplo da aplicação em ação. O aplicativo *web/mobile* foi integrado ao *twitter* e ao *telegram*. Assim, as mensagens são enviadas automaticamente e publicados nos relatórios do sistema na web. Foram usados *emoticons* para transmitir a mensagem visual ao médico nas colunas *local* e *status*.

Nesse caso o *emoticon* laranja informa visualmente que o medicamento foi ingerido com atraso, o verde indica que o medicamento foi ingerido normalmente e o vermelho indica que não foi ingerido. Os ícones de mapa, casa e trabalho indicam os locais que o usuário se encontra, o que permite que a aplicação de lembrete envie a mensagem para o dispositivo móvel do usuário caso ele não esteja em casa.

Além da representação visual no aplicativo *web/mobile* da Figura 25, observa-se também a notificação da aplicação via Twitter, informando as anormalidades ocorridas durante o acompanhamento do usuário.

Name	Medicine	Dosage	Taked Date	Taked Time	Local Taked	Medicines Status
Suellen Silva	Dipirona	01 pill	03/05/2016	21:30	👤	😟
Lisa Clark	Ferrous Sulphate	01 dose	15/02/2016	14:00	🏠	😊
Hugo Taylor	Antihypertensives	01 pill	14/02/2016	08:00	👤	😊
William Thomas	Domperidone	01 pill	14/02/2016	08:00	👤	😞

Patient William Thomas patient  
 medication not taken! Last time taken was not found!

Patient Suellen Silva patient  
 medication late! Last Date taken 05.03.2016 21:30

Figura 25. Informação do padrão de ingestão do medicamento acessado via web.  
 Fonte: Elaborado pelo autor.

A Figura 26 mostra um exemplo de mensagem de alerta enviada por SMS. O documento XML é usado para padronizar a comunicação entre as aplicações e contém os dados do paciente e dos medicamentos além do número do celular do médico. Após compor a mensagem, o sistema a envia para o *smartphone* registrado.

```
<?xml version="1.0" encoding="UTF-8"?>
  <prescription_message>
    <message_data>
      <patient>Suellem</patient>
      <doctor_phone>+5592992547005</doctor_phone>
      <medicine>Dipirona</medicine>
      <dosage>01 comprimido</dosage>
      <taken_data>03/05/2016</taken_data>
      <taken_time>20:45</taken_time>
      <local>home</local>
      <status>OK</status>
    </message_data>
  </prescription_message>
```

Figura 26. Conteúdo da mensagem SMS em XML  
Fonte: Elaborado pelo autor.

A Figura 27 mostra um exemplo da mensagem recebida no *Telegram* assim que o paciente ingere o medicamento. O *Telegram* permite que seja criado um *bot* (serviço automatizado) que pode ser configurado para enviar mensagens de forma automática, então a leitura de um arquivo XML é transformada em uma mensagem que é enviada automaticamente para o usuário cadastrado e autorizado por meio de chave de segurança no aplicativo de mensagem.



Figura 27. Mensagem enviada pelo aplicativo Telegram  
Fonte: Elaborado pelo autor.

No exemplo apresentado na Figura 27, se vê uma mensagem informando a data e a hora em que um paciente ingeriu o medicamento.

A API da SMSLib possui métodos para envio e recebimento de mensagens de texto, habilitando a conexão de um dispositivo móvel a um computador convencional por meio da porta *Universal Serial Bus* (USB). O módulo executa sobre a camada da *Java Virtual Machine* (JVM) instalada no *Gateway* Residencial. Dessa forma, uma mensagem de texto pode ser disparada para dispositivos cadastrados no GR, usando a infraestrutura da rede *Global System for Mobile Communications* (GSM) e seus protocolos de comunicação.

O modelo definido para envio de mensagens SMS é apresentado na Figura 28. Nesse modelo dois dispositivos móveis fazem parte da comunicação: um celular associado ao GR e um celular de destino, cujo número é armazenado na base de dados. Caso haja alguma alteração no padrão de ingestão do medicamento o GR utilizará o celular conectado para o envio de mensagem de alerta para o dispositivo cadastrado na base de dados, que pode ser o celular do médico ou de um responsável pelo paciente monitorado. A comunicação se dá por meio do módulo EnviaSMS.

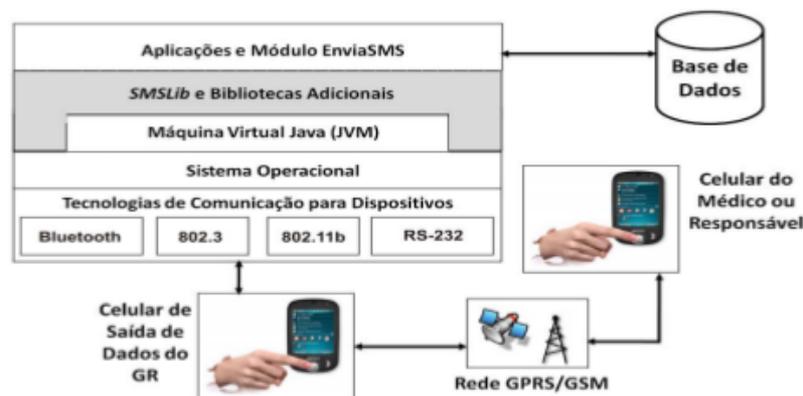


Figura 28. Modelo para envio de Mensagens SMS.  
Fonte: Elaborado pelo autor.

O modelo da Figura 29 apresenta uma interface para a aplicação de TVDi, foi elaborada uma interface de visualização de dados em NCL-LUA. Os dados são acessados por meio de uma rede de comunicação TCP-IP que se conecta com o GR. O módulo de alerta recebe os dados via rede por

intermédio da leitura dos resultados armazenados na base de serviços dados do GR e na operação de envio de alertas, o GR primeiramente consulta a base de dados para verificar se existem novos alertas, enviando-os em seguida ao módulo de TVDi que os apresenta na tela.



Figura 29. Modelo de envio de mensagens para a TVDi.  
Fonte: Elaborado pelo autor.

O usuário, por meio do controle remoto pode acessar as informações do alarme selecionando os botões vermelho ou verde. Como decisão de projeto, verificou-se que um *gateway* residencial baseado na arquitetura x86 deveria ser usado para integrar os dispositivos com a TVDi, visto que o *Set-top box* (STB) não possuíam poder de processamento necessário para ser usado como unidade central de processamento. Além disso, a aplicação de TVDi não deve exigir que o STB esteja conectado a uma rede banda larga.

Todas as mensagens são construídas de acordo com o módulo de decisão sem a intervenção do usuário. Uma vez que o processo é iniciado, o sistema coleta os dados, filtra, armazena, executa os algoritmos, as regras, e finalmente fornece a mensagem.

#### 4.6.5 Integração dos Protótipos do Sistema

Todos os protótipos desenvolvidos foram integrados baseados na arquitetura construída neste trabalho. O fluxo do sistema inicia com a camada de dispositivos que contém entre outros eletrônicos, o armário de medicamentos, a TV e o *smartphone* usados durante os experimentos. A

Figura 30 apresenta como foram integrados os módulos do sistema para execução dos experimentos gerando os serviços de mensagens, proposto neste trabalho.

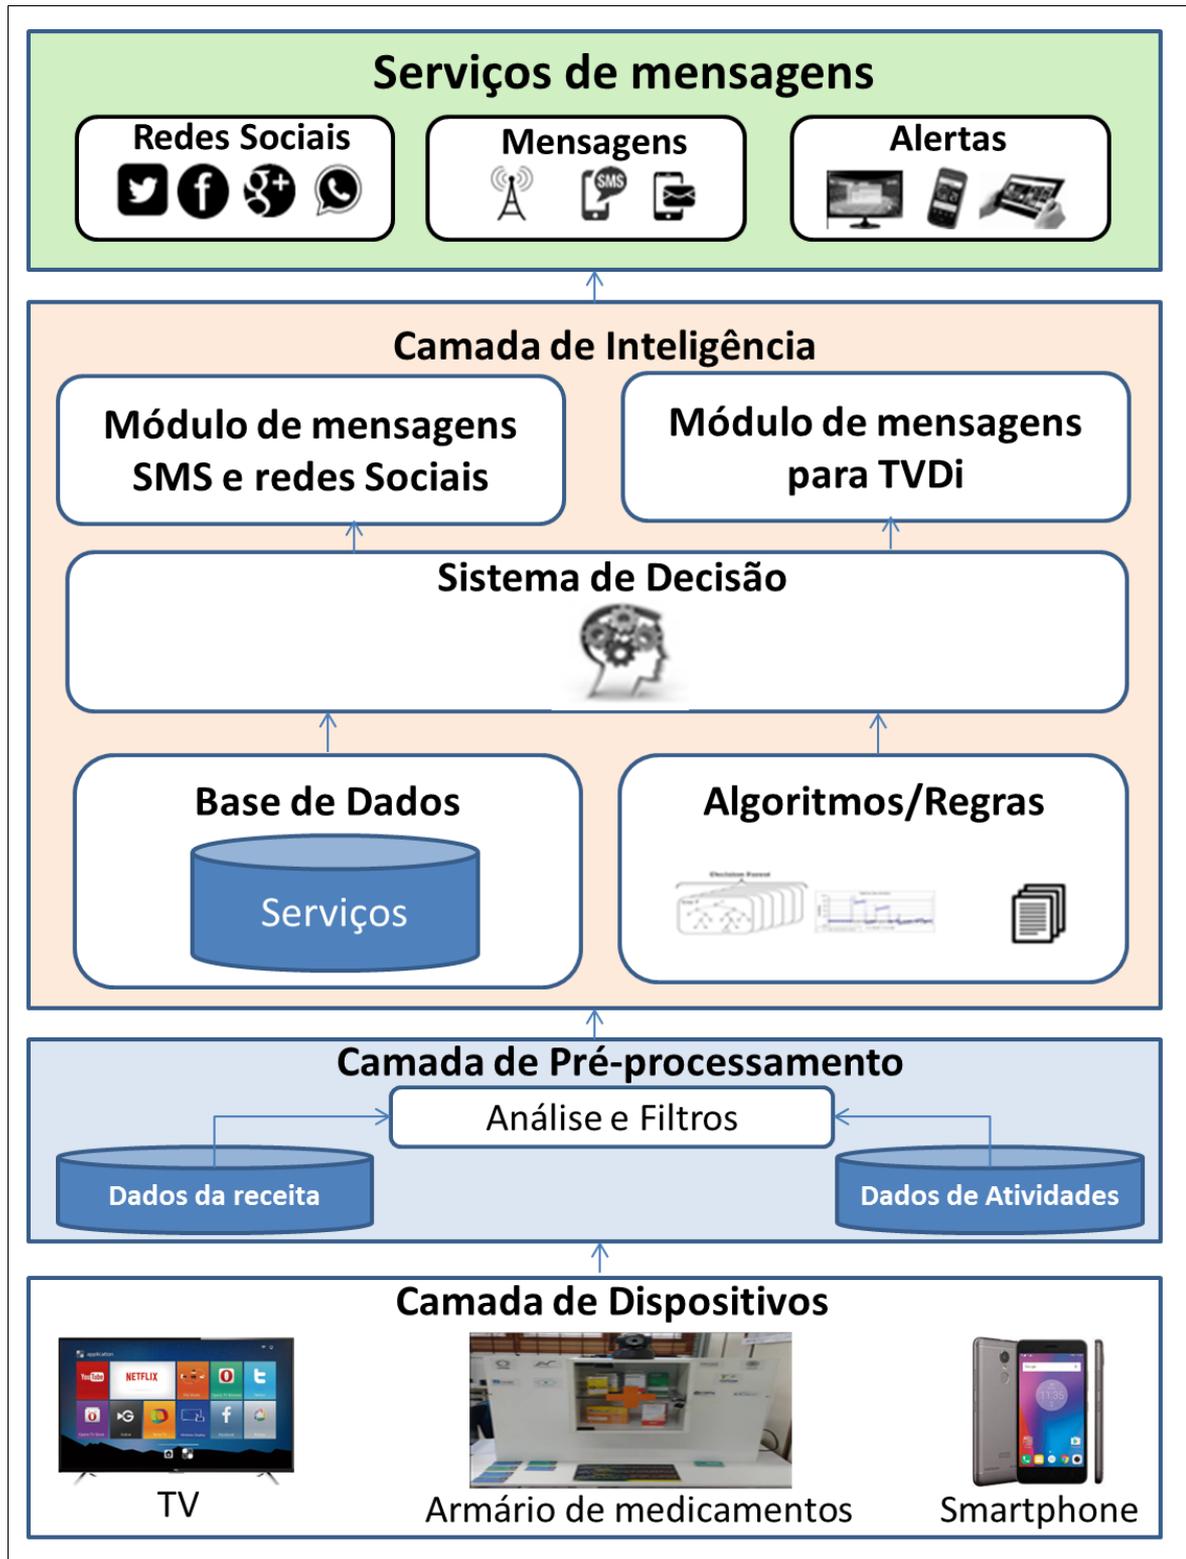


Figura 30. Integração dos subsistemas com a Arquitetura  
Fonte: Elaborado pelo autor.

Na camada de dispositivos os dados brutos são coletados e enviados para o pré-processamento e separados em dados da receita e de atividades. Na camada de inteligência os algoritmos *J48*, *RepTree* e *RandomTree* classificam a adesão em percentuais de “adere” ou “não adere” ao medicamento e repassam o resultado para os subsistemas de envio de mensagens SMS, redes sociais e alertas.

Os alertas são de dois tipos: lembretes para a tomada de medicamentos diretamente no *smartphone* ou na TV e mensagens SMS, *Twitter* e *Telegram* informando ao médico se o paciente esta realmente ingerindo a medicação e qual o seu percentual de adesão.

O envio de mensagens pelo aplicativo *Telegram* foi possível porque ele possui a *Application Programming Interface* (API) permitindo que qualquer aplicação desenvolvida possa usar toda a infraestrutura de mensagens do aplicativo por meio de robôs (*telegram-bot*). A integração com as linguagens de *scripts*, tais como o *NodeJs* permite que as mensagens sejam automatizadas.

Os alertas para ingestão da medicação foram codificados em linguagem de programação Java para o *gateway* residencial, armário de medicamentos e *smartphone*, e NCL-LUA para o *Set top Box* de TV Digital. As mensagens enviadas são armazenadas na base de serviços para posterior verificação.

## 4.6 Considerações Finais sobre o Capítulo

Neste Capítulo foram apresentados os componentes da arquitetura do sistema dividido em camadas, cada camada foi explicada com detalhes e apresentada como as mesmas foram conectadas. Os filtros foram aplicados nas bases de dados para excluir inconsistências e redundâncias. Foram separados os dados de aplicativos e de contexto para em seguida serem processados pela camada de inteligência. A camada de inteligência foi composta por algoritmos baseados em árvore de decisão capazes de inferir a classificação da adesão a medicamentos para em seguida serem avaliados no Capítulo 5.

A camada de serviços apresentou possibilidades para construção de sistemas de mensagens automáticas para redes sociais, SMS e mensagens de texto curtas para serem publicadas no *Twitter* e no *Telegram*. As contribuições deste capítulo para a tese é exatamente o modelo de desenvolvimento da arquitetura do sistema com acesso aos dados do armário de medicamentos, o pré-processamento, a verificação da adesão por meio dos algoritmos de decisão e a geração dos serviços de mensagens de maneira automatizada.

# Capítulo 5 Experimentos Realizados

Neste Capítulo são apresentados o protocolo experimental e os experimentos realizados baseados em árvore de decisão. O objetivo foi analisar o contexto com o intuito de gerar serviços permitindo que equipes médicas acompanhem a prescrição e as tomadas de medicamentos por pacientes, usando um sistema de alertas móvel e um armário de medicamento na residência do usuário. Nesta seção foram testados algoritmos baseados em árvore de decisão e de estimativas de probabilidade para validar a camada de inteligência do sistema.

## 5.1 Protocolo Experimental

Os experimentos foram configurados de duas formas, primeiro usando a abordagem de divisão da base de dados em dados de treinamento e dados de testes, (*percentage Split*), considerando 70% para treinamento e 30% para os testes conforme Hall et al. (2009) depois foram feitos os mesmos experimentos usando a abordagem de validação cruzada (HALL et al., 2009).

A *Percentage Splits* consiste em separar a base de dados em subconjuntos de treinamento com o percentual da base definida durante a fase de pré-processamento a fim de treinar o reconhecimento do padrão em busca da melhoria dos resultados estatísticos (HALL et al., 2009).

A *Cross-Validation* consiste em executar  $n$  repetições de  $i$  iterações de subconjuntos da base de dados fornecidos na entrada chamados *folds*, onde o número de pares do conjunto de treinamento e testes são os *folds*. O número de *folds* influencia no resultado dos testes e devem ser alternados para maior ou menor em busca do melhor resultado (HALL et al., 2009).

### 5.1.1 Ambiente de Experimentação e Tecnologias Utilizadas

As tecnologias de *hardware* utilizadas na configuração e execução dos experimentos são apresentadas na Tabela 6. Todo o *hardware* utilizado está disponível no laboratório de TV Digital do CETELI-UFAM.

**Tabela 6. Tecnologias de Hardware utilizadas nos Experimentos**

Hardware		
Quantidade	Equipamentos	Uso
1	Computador Desktop 500 Gb HD e 4 GB de memória RAM.	Armazenamento de dados coletados de sensores e dispositivos.
1	Computador Servidor com 32 Gb de RAM e 1 Tb de HD.	Utilizado no laboratório para experimentos com grande massa de dados.
4	Placa de controle de acesso com comunicação sem fio.	Utilizada para coletar os dados de entrada e saída do laboratório, da porta do armário de medicamentos e das estações de trabalho.
1	Computador configurado como Armário de medicamentos inteligente.	Utilizado para controlar a tomada de medicamentos e informar avisos sonoros para o paciente.
1	Antena RFID com leitor de proximidade.	Utilizada para coletar os dados e interagir com o armário de medicamentos.
1	<i>Smartphone</i> com Android.	Utilizado para embarcar o protótipo do sistema de avisos e alarmes.
1	Computador Atom Intel duo core com 500 GB e 1 GB de memória RAM	Configurado como <i>gateway</i> residencial com conexão a Internet.

O sistema de coleta de dados foi desenvolvido usando o paradigma de orientação a objetos com banco de dados relacional. Os algoritmos baseados em árvore de decisão foram avaliados usando a ferramenta weka, por permitir livre acesso ao código fonte dos algoritmos desenvolvidos e por ser de fácil integração com sistemas codificado em linguagem de programação Java. A ferramenta possui uma coleção de algoritmos de aprendizado de máquina que podem ser aplicados diretamente em base de dados além de algoritmos para pré-processamento, classificadores, algoritmos de regressão, clusterização, associação, regras e visualização.

Parte do sistema de coleta de dados foi desenvolvida em linguagem de programação Java e parte em linguagem C e os protótipos para apresentação de dados na TVDi e no *smartphone*, foram respectivamente desenvolvidos em linguagem NCL, LUA e *Android*.

### 5.1.2 Base de Dados e Ferramenta de Mineração

A base de dados possui 8.000 registros gerados a partir dos dados coletados das ações de tomadas de remédios executadas nos aplicativos do armário de medicamentos, TVDi e *smartphone* desenvolvidos para o experimento. A ferramenta de mineração de dados weka foi utilizada nessa fase para auxiliar na geração do modelo de árvore de decisão a ser aplicada na camada de decisão da arquitetura. A Figura 31 mostra a estrutura de

dados em arquivo texto com extensão “.arff”, utilizado pela ferramenta de mineração para extração das características.

```

1 % Data set to reminder medication
2 % Weka file to training the machine. The aim is identify the intake medicine
3 % and recommend to users, and doctor about the medicines adherence.
4
5 @relation medicineIntake_2017-30_days
6
7 @attribute age {'elderly','adult','kid'}
8 @attribute medicine {'Hidroclorotiazida','Clortalidona','Indapamida'}
9 @attribute dose numeric
10 @attribute ingested {TRUE,FALSE}
11 @attribute delayed {TRUE,FALSE}
12 @attribute adverse_effects {TRUE,FALSE}
13 @attribute super_dosage {TRUE,FALSE}
14 @attribute situation{'suspend_treatment','continue_treatment','delayed'}
15 @attribute adherence{1,0}
16
17 @data
18 'elderly','Clortalidona',12.5,TRUE,FALSE,FALSE,FALSE,'continue_treatment',1
19 'elderly','Clortalidona',12.5,TRUE,TRUE,FALSE,FALSE,'continue_treatment',1
20 'elderly','Clortalidona',12.5,TRUE,TRUE,TRUE,TRUE,'suspend_treatment',0
21 'elderly','Clortalidona',12.5,TRUE,TRUE,FALSE,TRUE,'suspend_treatment',0
22 'elderly','Clortalidona',12.5,TRUE,TRUE,FALSE,TRUE,'suspend_treatment',1
23 'elderly','Clortalidona',12.5,TRUE,FALSE,TRUE,TRUE,'suspend_treatment',0
24 'elderly','Clortalidona',12.5,TRUE,FALSE,FALSE,TRUE,'suspend_treatment',0
25 'elderly','Clortalidona',12.5,TRUE,FALSE,TRUE,FALSE,'suspend_treatment',0
26 'elderly','Clortalidona',12.5,TRUE,TRUE,TRUE,FALSE,'suspend_treatment',0
27 'elderly','Clortalidona',12.5,TRUE,FALSE,TRUE,FALSE,'suspend_treatment',1
28 'elderly','Clortalidona',12.5,TRUE,TRUE,TRUE,FALSE,'suspend_treatment',1
29
--

```

Figura 31. Parte da base de dados preparada para os experimentos.  
Fonte: Elaborado pelo autor.

O arquivo utilizado pela ferramenta de mineração possui uma estrutura com anotações. O caractere “@” indica o início da declaração dos atributos. Na linha 7 o atributo *age* (idade) determina, por exemplo, os dados pré-classificados de *elderly*, *adult* e *kid* (idoso, adulto e criança). Na linha 8 o atributo *medicine* (medicamentos), define quais os medicamentos estão sendo tomados, neste caso específico do experimento são medicamentos para controle de hipertensão. Na linha 15 está o atributo alvo, classe que se deseja inferir, nesse caso a adesão ao medicamento com “1” para adesão e “0” para não adesão.

Cada linha marcada a partir da anotação @data, linha 17, corresponde a uma instância passada para o classificador treinar e gerar os modelos de árvore de decisão e regras. O exemplo da linha 18 treina o algoritmo para identificar a adesão baseada nos dados dos outros atributos, resultado “1” no final da linha.

A ferramenta de mineração de dados permite que sejam aplicados filtros para melhorar o poder do classificador e durante os experimentos eles foram aplicados para omitir dados da base que não possuem ganho de informação considerável. A aplicação desses filtros permite melhorar a classificação do atributo alvo. A Figura 32 apresenta a interface da ferramenta weka configurada para executar o algoritmo J48.

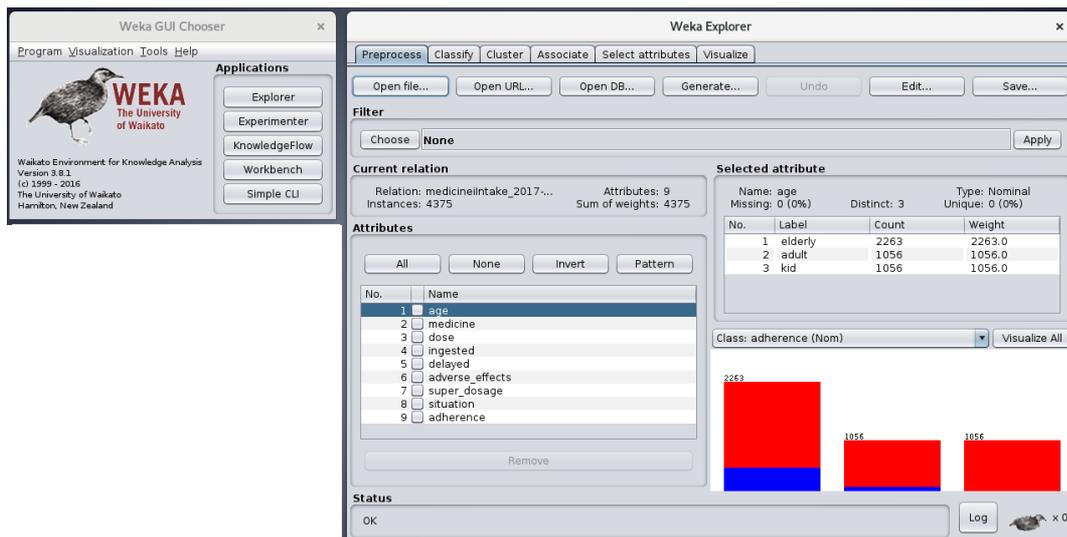


Figura 32. Interface Gráfica da ferramenta de mineração de dados.

Fonte: Elaborado pelo autor.

É possível observar que a ferramenta faz a leitura do *dataset* e em seguida faz o carregamento com algumas estatísticas predefinidas tais como, a distribuição do conjunto de dados, contagem e peso dos atributos.

## 5.2 Execução dos Experimentos e Análise dos Resultados

Nos primeiros experimentos foram realizados testes iniciais com cinco classificadores usando a mesma base de dados com 8.000 registros sem filtros e sem ajustes, aplicando os algoritmos de fragmentação *Percentage Splits* com 50%, 70% e 80% para treinamento e com a abordagem *Cross-Validation* usando 10 *folds*. O melhor resultado encontrado com essa

abordagem foi usando 70% dos dados para treinamento e 30% para testes. As avaliações completas desse experimento são apresentadas nas subseções a seguir.

### 5.2.1 Experimento Inicial para a Escolha dos algoritmos da Camada de Inteligência

Os algoritmos utilizados foram o *J48*, *Reptree*, *DecisionTable*, *RandomTree* e *NaiveBayes*, todos implementados na ferramenta de mineração de dados. O objetivo era escolher o algoritmo que mais se adaptava para a resolução do problema ou um conjunto deles, nas questões da acurácia, tempo de execução e custo computacional.

A Tabela 7 apresenta os dados e as características avaliadas nos cinco algoritmos utilizando o método da *Cross-Validation* e as Tabelas 7, 8, e 9, apresentam os resultados usando os percentuais da base de dados com *Percentage Splits* respectivamente 50%, 70% e 80%.

Observando a Tabela 7 pode se vê que usando a mesma base de dados com o particionamento *Cross-Validation*, os algoritmos *Naivebayes* e *Reptree*, obtiveram o melhor desempenho na classificação dos serviços em detrimento dos algoritmos *Randomtree*, *J48* e *DecisionTable* apesar da métrica do erro quadrático do algoritmo *Naivebayes* apresentar um valor mais alto que dos demais algoritmos.

**Tabela 7. Resultado dos testes com Cross-Validation**

Algoritmo	Tempo em ms	Acurácia com Cross-Validation			
		% Corretas	% Incorretas	Erro Quadrático	Erro Absoluto
Naive Bayes	0,02	87,50	12,50	0,2123	0,0753
RepTree	0,02	87,50	12,50	0,2042	0,0834
Random Tree	0,02	86,64	13,35	0,1769	0,0626
J48	0,05	86,64	13,35	0,188	0,0701
Decision Table	0,24	86,64	13,35	0,177	0,0646

O algoritmo *DecisionTable*, teve o tempo de processamento maior que os demais, porém obteve os mesmos índices de classificação do *RandomTree* e

J48. A Figura 33 apresenta o gráfico resultante dos dados coletados e avaliados pelo método *Cross-Validation*. Observa-se no gráfico da Figura 33 que os algoritmos *Naive Bayes* e *RepTree* ficaram empatados em primeiro lugar e os algoritmos *RandomTree*, *J48* e *DecisionTable*, também permaneceram empatados no segundo lugar com pequenas diferenças no tempo de execução.

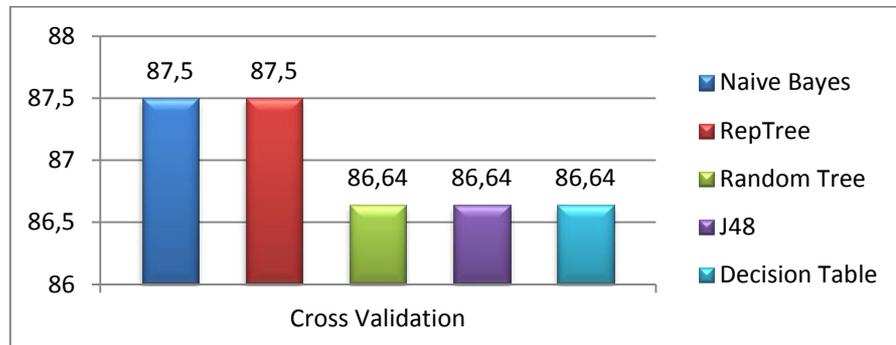


Figura 33. Gráfico de barras que apresentam o desempenho dos algoritmos  
Fonte: Elaborado pelo autor.

Observando a Tabela 8 nota-se que usando o percentual de 50% para treino e 50% para testes, o algoritmo *Naive Bayes* permanece a frente dos demais com uma diferença de 0,62% do algoritmo *RepTree* e 0,89% dos demais algoritmos. No entanto, o erro quadrático do algoritmo *Naive Bayes* é maior que dos demais em aproximadamente 0,02 pontos, o que para essa quantidade de dados não faz muita diferença.

Tabela 8. Resultado dos testes usando 50% da base de dados para treinamento

Algoritmo	Tempo em ms	Acurácia com 50% da base para treino			
		% Corretas	% Incorretas	Erro Quad	Erro Abs
Naive Bayes	0,01	87,92	12,07	0,2058	0,0739
RepTree	0,01	87,03	12,96	0,1773	0,0627
Random Tree	0,01	87,03	12,96	0,1773	0,0627
J48	0,01	87,03	12,96	0,1773	0,0627
Decision Table	0,01	87,03	12,96	0,1773	0,0664

O gráfico da Figura 34 apresenta a diferença no acerto das classificações corretas com o *split* de 50%. O eixo horizontal representa os

*splits* da base de dados e o eixo vertical representa o percentual de acerto das classificações.

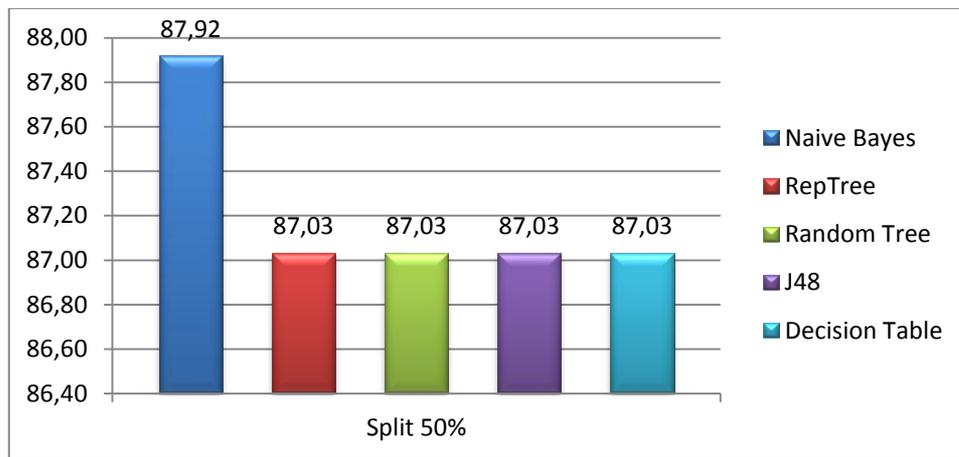


Figura 34. Gráfico Split 50% da base de dados para treinamento.  
Fonte: Elaborado pelo autor.

Observando a Tabela 9 com o percentual de 70% para treino e 30% para testes indicados pela literatura, os resultados têm uma mudança significativa. Os algoritmos *NaiveBayes* e *RepTree* têm o mesmo número de acertos, 88,21%, com uma diferença de 0,91% em relação aos demais algoritmos testados. Novamente o erro quadrático do *Naive Bayes* é maior que do *RepTree* em 0,058 pontos.

**Tabela 9. Resultado dos testes com 70% da base de dados**

Algoritmo	Tempo em ms	Acurácia com 70% da base para treino			
		% Corretas	% Incorretas	Erro Quad	Erro Abs
Naive Bayes	0,01	88,21	11,7839	0,2058	0,0724
<i>RepTree</i>	0,01	88,21	11,7839	0,2000	0,0809
Random Tree	0,01	87,30	12,6953	0,1750	0,0612
J48	0,01	87,30	12,6953	0,1750	0,0612
Decision Table	0,07	87,30	12,6953	0,1751	0,0639

O gráfico da Figura 35 mostra as diferenças entre os algoritmos usando a base com *split* de 70% para treino e 30% para testes. Os algoritmos *RandomTree*, *J48* e *DecisionTable*, permaneceram empatados com 87,30% cada um. O tempo de execução do algoritmo *DecisionTable* foi maior que dos demais.

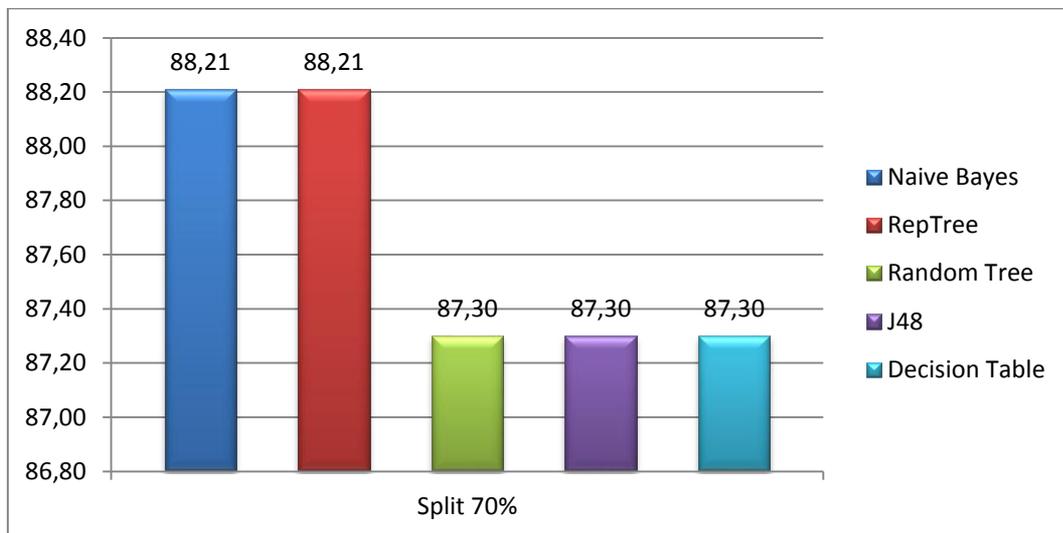


Figura 35. Gráfico contendo os resultados do Split com 70% da base de dados  
Fonte: Elaborado pelo autor.

Na Tabela 10 são mostrados os dados dos testes com 80% da base de dados para treinamento e 20% para testes. Nesse caso o algoritmo *NaiveBayes* e *RepTree* novamente empataram com 87,59% com a diferença entre os dois apenas no erro quadrático que no *NaiveBayes* ainda é o maior que todos os algoritmos verificados.

**Tabela 10. Resultados dos testes com 80% da base de dados**

Algoritmo	Tempo em ms	Acurácia com 80% da base para treino			
		% Corretas	%Incorretas	Erro Quad	Erro Abs
Naive Bayes	0,01	87,59	12,40	0,2111	0,0736
<i>RepTree</i>	0,01	87,59	12,40	0,2021	0,0811
Random Tree	0,01	87,10	12,89	0,1778	0,0632
J48	0,01	87,10	12,89	0,1778	0,0632
<i>Decision Table</i>	0,07	87,10	12,89	0,1779	0,0655

O gráfico da Figura 36 mostra como se comportaram os algoritmos com 80% da base de dados. O eixo vertical exibe os dados em forma de barras para facilitar a observação do comportamento dos algoritmos.

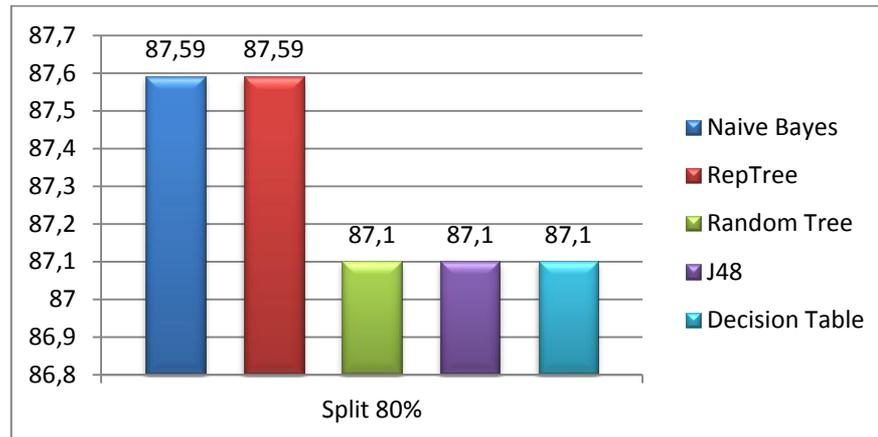


Figura 36. Gráfico contendo os resultados do Split com 80% da base de dados  
Fonte: Elaborado pelo autor.

Além de avaliar a quantidade de acertos dos classificadores e o tempo de execução, foi avaliada também a média dos erros quadráticos como uma primeira métrica para uma possível escolha do algoritmo que mais se adéqua ao problema de decisão tratado nos experimentos.

A Figura 37 apresenta o resultado da média do erro quadrático tabulado dos *Splits* e da *Cross-Validation*, resultando em um erro muito próximo nos dois algoritmos com maior percentual de acertos.

Um dado interessante é a média de erro dos algoritmos *RandomTree*, *J48* e *DecisionTable*, ambos obtiveram uma média de erro quadrático iguais e relativamente mais baixo que os algoritmos *Naive Bayes* e *RepTree*, apesar dos três algoritmos terem um percentual de acerto menor que os dois primeiros.

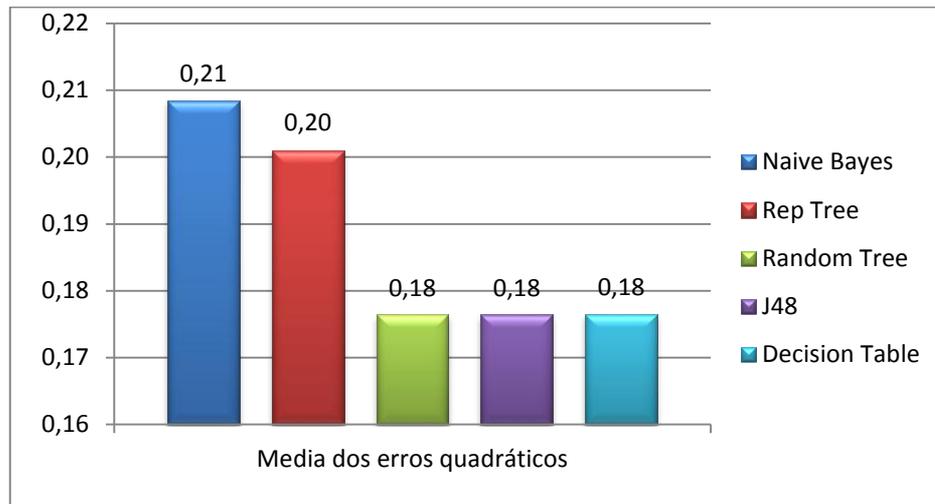


Figura 37. Gráfico contendo a média dos erros quadráticos dos algoritmos avaliados.

Fonte: Elaborado pelo autor.

Observando as tabelas e gráficos apresentados nesta seção, verifica-se que o melhor resultado da acurácia dos algoritmos se deu usando 70% da base para treinamento e 30% para os testes. Neste caso os algoritmos que melhor classificaram a adesão foram o *Naivebayes* e o *Reptree*, ambos empatados, porém, com uma pequena vantagem levando em consideração o erro quadrático conforme observado no gráfico da Figura 23, o algoritmo *Reptree*, obteve o melhor resultado para o conjunto de dados testado neste experimento, conforme a avaliação feita considerando a média do erro quadrático como métrica de avaliação inicial. Assim para os próximos experimentos decidiu-se por excluir o *Naivebayes*.

Os algoritmos *RandomTree*, *J48* e *DecisionTable*, possuem o mesmo erro quadrático em todos os *splits*, portanto a média calculada foi igual para os três, no entanto, o algoritmo *DecisionTable* se mostrou lento em relação aos demais e foi descartado para os próximos experimentos.

### 5.2.2 Experimento com Envio de Mensagens

Para esse experimento foram excluídos os algoritmos *DecisionTable* e *Naivebayes* pelo critério do maior erro quadrático e velocidade de processamento. Assim, foram mantidos os algoritmos *J48*, *RandomTree* e *RepTree*. Foram acrescentados na base de dados de testes os dados de

localização do paciente para inferir o local das ingestões dos medicamentos, dando origem a uma aplicação web que mostra se usuário ingeriu o medicamento e se foi em sua residência, em ambiente externo ou em seu local de trabalho.

A Tabela 11 apresenta um extrato da base de dados passivo de classificação contendo os medicamentos, dose ingerida, data e hora da ingestão, latitude e longitude e a coleta de dados do retorno da aplicação como um dos indicadores da ingestão. As datas estão em formato *timestamp*.

**Tabela 11. Extrato da base de dados com os dados brutos e não classificados.**

Pac.	Medicamento	Dose	DataPrev.	DataTom.	Lat.	Long.	Dis.
001	Medicamento1	1p	1462311020	1462311020	-3.088165	-59.963258	1
002	Medicamento2	1p	1455544801	1462311020	48.786817	9.194187	2
003	Medicamento3	1p	1455436820	1455436820	-3.098754	-59.994431	3
004	Medicamento4	1p	1452589220	nulo	nulo	nulo	nulo

A Tabela 12 mostra um extrato do *status* do resultado da classificação do medicamento ingerido, atrasado (A), pontual (P) e não ingerido (N), e a escolha de enviar ou não mensagens (S) ou (N). Nessa regra o sistema só envia a mensagem se houver alguma alteração na ingestão.

**Tabela 12. Extrato da base de dados já classificada**

Pac.	Medicamento	Dose	DataTom.	HoraTom.	Local	Status	Mens.
001	Medicamento1	1p	03/05/2016	21:30	externo	A	S
002	Medicamento2	1p	15/02/2016	14:00	casa	P	N
003	Medicamento3	1p	14/02/2016	08:00	escritório	P	N
004	Medicamento4	1p	-	-	-	N	S

Observando os dados da Tabela 12 nota-se que existem células não preenchidas, por exemplo, a data de tomada do medicamento, a hora e o local. Nesse caso o sistema considera que o paciente não tomou o medicamento e gera a mensagem para o médico.

### *Avaliação dos Resultados dos Algoritmos*

Foram usadas duas técnicas para avaliação do conjunto de dados, percentagem *split* e validação cruzada, ambas já apresentadas neste

Capitulo. A Tabela 13 mostra o resultado com a técnica de Validação Cruzada e a Tabela 14 mostra os resultados com a percentagem *Split* com 70% para treinamento e 30% para testes.

A precisão foi observada pela porcentagem correta % C e incorreto,% I, erro quadrático, E2 e erro absoluto, ABS, de cada algoritmo usado no experimento.

**Tabela 13: Resultado dos testes com validação cruzada**

Algoritmos	Acurácia			
	%C	%I	E2	ABS
RepTree	96.6	3.36	0.2123	0.0753
RandomTree	96.6	3.36	0.1769	0.0626
J48	97.5	2.50	0.188	0.0701

Observando a Tabela 13 se vê que o algoritmo J48 obteve o melhor desempenho na classificação dos medicamentos tomados comparado ao algoritmo *RepTree* e *RandomTree*. O J48 também possui o menor erro quadrático dentre os algoritmos avaliados no experimento.

**Tabela 14: Resultado dos testes com 70% da base para treinamento**

Algoritmos	Acurácia			
	%C	%I	E2	ABS
RepTree	98.2	1.79	0.2000	0.809
RandomTree	97.3	1.79	0.1750	0.809
J48	98.2	2.7	0.1750	0.612

Na Tabela 14 são mostrados os resultados usando a técnica de porcentagem *split*. Os resultados têm uma mudança significativa, o algoritmos J48 e RepTree têm o mesmo número de respostas corretas 98,2% com uma diferença de 0,9% para o *RandomTree* no entanto, o *RepTree* possui o maior erro quadrático que os outros algoritmos.

### *Considerações sobre o Experimento*

Os algoritmos que melhor classificaram os dados foram o *RepTree* e o J48 usando uma base de dados de 70% para treinamento. Ambos os algoritmos ficaram empatados, mas o algoritmo J48 obteve uma pequena

vantagem levando em consideração o erro quadrático para o conjunto de dados testado neste estudo.

### 5.2.3 Experimento Usando a Abordagem de Votação entre os Algoritmos.

Nesse experimento foram usados os algoritmos J48, *RandomTree* e *RepTree* foram aplicados dois filtros um para discretização dos dados e transformação de atributos nominais para numéricos segundo Breheny (1984), a fim de melhorar a classificação da adesão, limpeza dos dados para excluir alguns atributos não necessários como, identificação do paciente, dentre outros.

Os resultados obtidos durante os experimentos estão descritos nas subseções abaixo e foram divididos para melhor observar o comportamento dos algoritmos utilizados. Os três algoritmos foram testados com e sem filtros de atributos e os resultados foram diferentes em todos eles.

A avaliação dos resultados foi feita por meio das métricas de acurácia, precisão e *recall*, além do coeficiente de correlação de *phi* apresentado em Chedzoy (2014), conforme Equação (15). O coeficiente é uma medida de qualidade de duas classificações binárias que podem ser usadas mesmo se as classes tiverem tamanhos diferentes, como é o caso do conjunto de dados apresentado neste trabalho. A acurácia, *recall* e precisão são as medidas baseadas nos valores da matriz de confusão apresentadas no Capítulo 2. O coeficiente de correlação de *phi* é dado na equação (15).

$$phi = \frac{(tp \times tn - fp \times fn)}{\sqrt{(tp + fp) \times (tp + fn) \times (tn + fp) \times (tn + fn)}} \quad (15)$$

De acordo com Chedzoy (2014), o coeficiente de correlação de *phi* é uma medida de qualidade de duas classificações binárias que podem ser usadas mesmo se as classes tiverem tamanhos bastante diferentes. O índice retorna um valor entre (-1) e (+1), onde um coeficiente de (+1) representa uma previsão perfeita, (0) representa uma previsão aleatória média e (-1) uma previsão inversa.

Na etapa final dos testes foram executados de acordo com abordagem de votação, conforme Kuncheva (2004) e Kittler (1998) que consiste em selecionar um conjunto de algoritmos para resolver um dado problema e verificar a porcentagem de erros de cada um e em seguida escolher o que estatisticamente melhor classifica um conjunto de dados.

### *Resultados com o Algoritmo J48*

O algoritmo J48 com nove atributos executando a configuração com validação cruzada e dez *folds* resultaram em um modelo de três níveis em uma árvore de decisão. Esta árvore classificou os dados com precisão de 99%, no entanto, foi detectado superespecialização (*overfitting*) no modelo e então foi necessário aplicar o filtro de atributos, excluindo os atributos “idade” e “situação”, que durante os testes induzia o algoritmo ao erro.

Após uma nova análise dos resultados com os dados filtrados e com as mesmas configurações o algoritmo J48 apresentou um modelo de árvore de decisão com seis níveis, classificando as instâncias em 95,1% de acurácia diminuindo o *overfitting* do modelo. A precisão do algoritmo foi de 92,7%, o recall foi de 97,4% e o índice de *phi* ficou em 0,90.

### *Resultados com o Algoritmo RandomTree*

As configurações com os mesmos parâmetros utilizados para o algoritmo J48 foram aplicados ao RandomTree. Observou-se que o algoritmo apresentou 91,50% de acurácia, 87,8% de precisão, 94,7% de recall e 0,83 para o índice *phi*.

### *Resultados com o Algoritmo RepTree*

As configurações com os mesmos parâmetros utilizados para os algoritmos RandomTree e J48 foram aplicados ao RepTree. Observou-se que o algoritmo apresentou 90.2 % da acurácia, 87,8% da precisão, 92,3% de recall e 0,81 do índice *phi*.

## Avaliação do Experimento

Os algoritmos testados para classificar a adesão à medicação obtiveram um bom desempenho quando se avalia a precisão, acurácia, recall e o índice de *phi*. A métrica de precisão apresentada em Kuncheva (2004) e Kittler (1998) visa identificar quantas amostras foram classificadas positivamente. Em outras palavras, é uma medida de quão precisa é a classificação para amostras positivas, exatamente a questão que se deseja responder. A métrica também é conhecida como valor de predição positiva.

A Tabela 15 mostra os resultados das avaliações dos três algoritmos escolhidos para a construção da camada de razão da arquitetura proposta no Capítulo 4, utilizados na camada de inteligência do sistema.

**Tabela 15. Resultado dos algoritmos escolhidos para a camada de decisão.**

Algoritmo	Acurácia	Precisão	Recall	PHI
J48	95,10	92,07	97,40	0.90
RandomTree	91,50	87,80	94,70	0.83
RepTree	90,20	87,80	92,30	0.81

Observando a Tabela 15 é possível inferir que o algoritmo que melhor se adequa à construção do classificador para o conjunto de dados utilizado neste trabalho é o J48, pois possui o melhor índice de acurácia e possui o índice de *phi* mais próximo de 1, em relação aos demais algoritmos testados. Assim, em um sistema de votação em que os algoritmos são classificados pelo maior índice de recall e precisão de *phi*, conforme determinado nas métricas, fica claro que o algoritmo J48 se destaca, gerando o melhor modelo a ser construído na camada de decisão da aplicação não fazendo mais sentido utilizar o esforço de votação entre os algoritmos, já que o algoritmo J48 vence em todos os experimentos devido a especialização do algoritmo para problemas com duas classes e também pelo critério de custo computacional.

O gráfico da Figura 38 mostra os resultados da tabela para melhor visualização dos índices. O algoritmo J48 para o conjunto de dados da pesquisa vence em acurácia, precisão e recall.

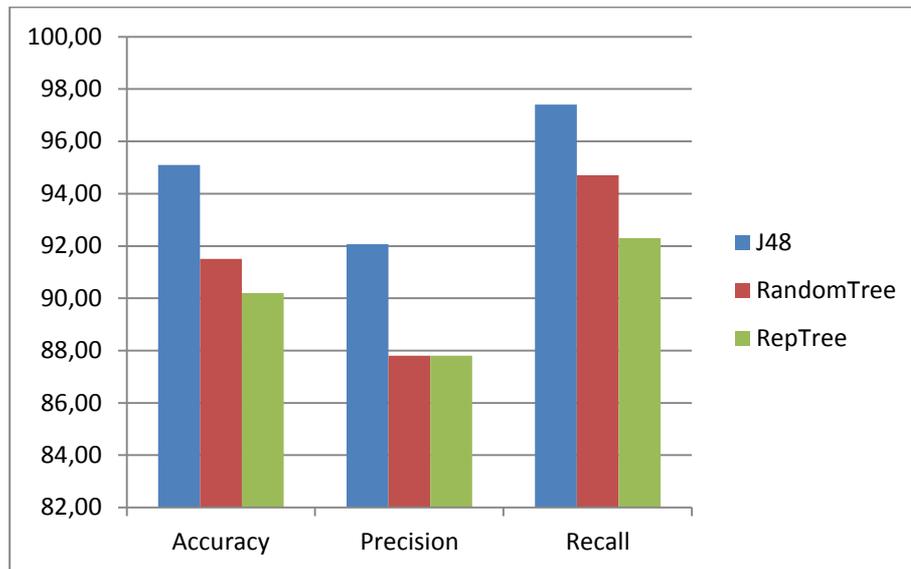


Figura 38. Gráfico demonstrando os algoritmos testados.  
Fonte: Elaborado pelo autor.

O gráfico da Figura 39 apresenta o resultado da tabulação apenas dos índices de PHI da Tabela 15. Novamente, observa-se que o algoritmo J48 vence os demais algoritmos no índice de *phi*, onde quanto mais próximo de 1 (um), melhor o índice de classificação correta do algoritmo. Nesse caso, o algoritmo J48 obteve um índice de 0,90.

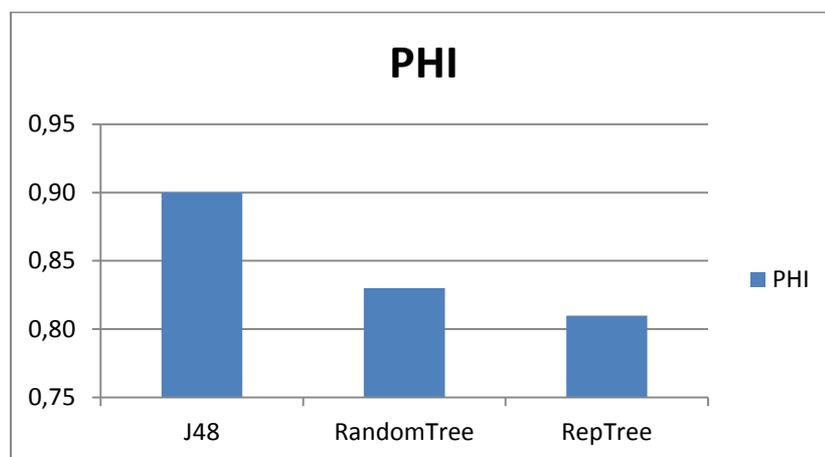


Figura 39. Gráfico que demonstra os valores do índice phi para cada algoritmo testado.  
Fonte: Elaborado pelo autor.

### 5.3 Considerações Finais sobre o Capítulo

Os resultados alcançados apresentados neste capítulo são a criação de modelos para envio de mensagens customizadas de acordo com o tipo de equipamento da residência, a integração com as mídias sociais *Twitter* e *Telegram*, a análise dos algoritmos baseados em árvore de decisão para compor a camada de razão da arquitetura que melhor classificam a adesão de medicamentos e a criação e integração de um sistema de comunicação que possibilita a ligação do consultório do médico com a residência do paciente.

Os primeiros experimentos desenvolvidos com os algoritmos, *RandomTree*, *J48*, *RepTree*, *DecisionTable* e *NayveBayes* possibilitaram a escolha dos algoritmos mais indicados para a classificação dos dados com duas classes e nesse caso optou-se pelos algoritmos baseados em árvore de decisão *RandomTree*, *RepTree* e *J48*. No segundo experimento os algoritmos escolhidos foram avaliados na camada de razão para em seguida serem codificados no sistema.

Os protótipos para coleta de dados, envio de mensagens e alertas para ingestão da medicação foram codificados e instalados na TVDi e *smartphone* e foram integrados com a camada de decisão do sistema para coletar dados, processar e enviar as mensagens automaticamente.

## Capítulo 6 Conclusão

O presente trabalho apresentou um sistema integrado de mensagens para auxiliar na adesão à medicação. O trabalho foi desenvolvido seguindo o processo de revisão sistemática para identificar os conceitos e trabalhos relacionados com o tema, apresentou uma arquitetura própria para integrar dispositivos de uma residência com um consultório médico a fim de monitorar a ingestão de medicamentos receitados e construiu e avaliou a camada de decisão proposta na arquitetura.

O Capítulo 1 apresentou os conceitos de Aml, *context-aware* e *healthcare* com ênfase em adesão à medicação. Foram desenvolvidos dois cenários para demonstrar o entendimento do problema e das questões de pesquisa, a justificativa, os objetivos e a metodologia de trabalho.

O Capítulo 2 os conceitos inerentes a ambientes inteligentes e as definições, características principais, áreas de aplicação dos temas *healthcare*, *contexto-aware*, *adesão* a medicamentos e aprendizado de máquina, conceitos presentes na questão de pesquisa da Tese.

No Capítulo 3 foram apresentados e discutidos os trabalhos relacionados com a presente Tese, foi feito um mapeamento de cada contribuição dos trabalhos relacionados foi feita a tabulação e comparação de acordo com as abordagens utilizadas nos trabalhos.

Os algoritmos para auxiliar na tomada de decisão tais como regras ontológicas, agentes inteligentes e árvore de decisão, além do modelo de comunicação entre os sistemas de mensagem foram apresentados no decorrer do Capítulo e foram extraídas as características principais da área de interesse do presente trabalho, os quais deram origem à concepção da arquitetura do Capítulo 4.

No Capítulo 4 foi apresentado o sistema integrado com sensores para a coleta de dados do armário de medicamentos, processamento e envio de mensagens por meio de uma camada de inteligência treinada com algoritmos baseados em árvore de decisão codificada no *gateway* residencial.

A arquitetura foi projetada e exposta na forma de diagrama de blocos e foi dividida em quatro camadas que permitiram receber dados de entrada adquiridos por sensores e dispositivos diversos, instalados em uma residência ou escritório para em seguida, fazer o pré-processamento e posteriormente definir as políticas e estratégias para a tomada de decisão usando técnicas de aprendizado de máquina.

No Capítulo 5 os experimentos foram executados e avaliados, foram construídos protótipos para gerar serviços de mensagens automatizados e modelos para desenvolvimento dos serviços de mensagens. Os protótipos para a TVDi e *smartphone* foram construídos, nos quais foram testados algoritmos baseados em árvore de decisão e de estimativas de probabilidade.

A integração dos sistemas foi feita baseado na arquitetura definida no Capítulo 4 por meio do desenvolvimento de aplicações para testes com redes sociais e sistemas de mensagens.

Dentre os dispositivos utilizados em dois cenários diferentes estavam um armário de medicamentos inteligente, uma TV digital interativa, *smartphones* e *tablets* e um computador de mesa como *gateway* residencial para processamento dos dados dentre outros dispositivos.

Foi construída uma base a partir dos dados da receita médica e dos dispositivos móveis de posse do paciente, permitindo que fossem geradas regras de decisão a partir do tratamento, filtragem e aplicação de algoritmos no conjunto de dados.

Durante os experimentos, os algoritmos J48, RepTree e RandomTree, após exaustivos testes, foram escolhidos para a camada de decisão da arquitetura e o sistema de mensagens foi construído para enviar mensagens automáticas para o *Twitter*, *Telegram* e também via SMS.

O sistema proposto neste trabalho testou a hipótese H1 apresentada no Capítulo 1, “é possível que um ambiente residencial provido de uma infraestrutura de redes interconectadas, auxilie na aplicação de serviços de mensagens eletrônicas para acompanhar a adesão a medicamentos de

pacientes em tratamento na residência”, foi testada e avaliada no decorrer do trabalho.

Durante a construção da arquitetura do sistema e dos protótipos, foi possível responder parte do problema de pesquisa que tratava da infraestrutura necessária para o desenvolvimento de um ambiente residencial conectado.

Nos experimentos com os algoritmos baseados em árvore de decisão ficou clara a escolha dos algoritmos C.4.5 (J48), *RepTree* e *RandomTree*, codificados em Java nos pacotes da ferramenta weka e embarcados no *gateway* residencial.

A taxa de acurácia para identificar a adesão a medicamentos do melhor algoritmo utilizado na camada de inteligência foi de 95,10%, considerando os dados coletados do armário de medicamentos e dos demais dispositivos presentes na residência monitorada, o que responde a segunda parte da hipótese H1 apresentada.

## 6.1 Contribuições deste Trabalho

Como contribuições deste trabalho citam-se: A construção de uma base de dados a partir da coleta de dados de prescrições e de dispositivos móveis, tais como horários de tomada de medicamentos e localização;

- A arquitetura construída para modelar um sistema inteligente com coleta de dados de sensores de uma residência, apresentada no Capítulo 4;
- A avaliação dos algoritmos de tomada de decisão específicos para problemas binários, *J48*, *RepTree* e *RandomTree* juntamente com a aplicação dos algoritmos em um sistema real, com recomendação sobre a adesão do paciente aos medicamentos prescritos apresentados no Capítulo 5;
- A construção de protótipos integrados com a TVDi, *smartphone*, web e redes sociais;

- A integração dos sistemas por meio de módulos do envio de mensagens com arquiteturas diferentes.
- A escrita e publicação de artigos científicos qualificados e na área de interesse da Tese, listados nos Apêndices.

## 6.2 Limitações e Trabalhos Futuros

A principal limitação deste trabalho foi na construção de um sistema para auxiliar na adesão de medicamentos aplicando os algoritmos *RepTree*, *J48* e *RandomTree* em uma base de medicamentos para hipertensão em pacientes idosos.

Os algoritmos testados foram os baseados em árvore de decisão e não foram testadas outras abordagens como clusterização, por exemplo. No entanto, isso se deu pelo domínio do problema, problema de apenas duas classes e também pelo custo computacional de outros algoritmos. Em outros domínios com mais de duas classes o sistema deve ser reformulado para problemas de mais de duas classes, pois para esses tipos de problemas este trabalho não se aplica.

Outra limitação é quanto ao uso de dispositivos eletrônicos tais como *smartphones* e *tablets* que podem constituir uma barreira para a população idosa durante o acompanhamento para a tomada de medicamentos visto que a maioria dessa população não se sente confortável com o uso de tecnologias. O ideal é que o sistema seja utilizado pelo cuidador.

Apesar do crescimento do acesso a internet em áreas urbanas a infraestrutura computacional não está totalmente presente em todos os lares, o que também pode ser considerado um fator limitante para a aplicação deste trabalho. Considerou-se uma residência totalmente conectada para a realização deste trabalho.

Como trabalhos futuros, pretende-se estender a abordagem para integrar outros dispositivos, embarcar o dispositivo *gateway* em um *hardware* mais barato e mesclar o classificador com os modelos de aprendizagem por reforço e por fim, melhorar a acurácia dos algoritmos estudados.

# Referências

- ABOWD, G. D., ATKESON, C. G., HONG, J., LONG, S., KOOPER, R., & Pinkerton, M. Cyberguide: A mobile context-aware tour guide. **Wireless networks**, v. 3, n. 5, p. 421-433, 1997.
- ADOMAVICIUS, Gediminas; TUZHILIN, Alexander. Context-aware recommender systems. In: **Recommender systems handbook**. Springer, Boston, MA, p. 217-253, 2011.
- ALI-LOYTTY, S., PERALA, T., HONKAVIRTA, V., & PICHE, R. Fingerprint kalman filter in indoor positioning applications. In: **Control Applications,(CCA) & Intelligent Control,(ISIC), 2009 IEEE**. IEEE, 2009. p. 1678-1683.
- BALDAUF, Matthias; DUSTDAR, Schahram; ROSENBERG, Florian. A survey on context-aware systems. **International Journal of Ad Hoc and Ubiquitous Computing**, v. 2, n. 4, p. 263-277, 2007.
- BHARGAVA, N., SHARMA, G., BHARGAVA, R., & MATHURIA, M. Decision tree analysis on j48 algorithm for data mining. **Proceedings of International Journal of Advanced Research in Computer Science and Software Engineering**, v. 3, n. 6, 2013.
- BIOLCHINI, J., MIAN, P. G., NATALI, A. C. C., & TRAVASSOS, G. H.. Systematic review in software engineering. **System Engineering and Computer Science Department COPPE/UFRJ, Technical Report ES**, v. 679, n. 05, p. 45, 2005.
- BRDICZKA, Oliver; CROWLEY, James L.; REIGNIER, Patrick. Learning situation models in a smart home. **IEEE Transactions on Systems, Man, and Cybernetics, Part B (Cybernetics)**, v. 39, n. 1, p. 56-63, 2009.
- BREHENY, Patrick. **Classification and regression trees**. 1984.
- BREIMAN, L., FRIEDMAN, J. H., OLSHEN, R. A., & STONE, C. J. Wadsworth international group. **Classification and Regression Trees**, 1984.
- BRINK, Henrik; RICHARDS, Joseph W.; FETHEROLF, Mark. **Real-world machine learning**. Manning, 2017.
- BROCK, David L. The electronic product code (epc). **Auto-ID Center White Paper MIT-AUTOID-WH-002**, 2001.
- CALDIERA, Victor R. Basili-Gianluigi; ROMBACH, H. Dieter. Goal question metric paradigm. **Encyclopedia of software engineering**, v. 1, p. 528-532, 1994.
- CARTER, Sarah; TAYLOR, D. G.; LEVENSON, Ros. **A question of choice: Compliance in medicine taking**. The Medicines Partnership, 2003.
- CHAI, Xiaoyong; YANG, Qiang. Reducing the calibration effort for probabilistic indoor location estimation. **IEEE Transactions on Mobile Computing**, n. 6, p. 649-662, 2007.
- CHANDRASEKAR, P., QIAN, K., SHAHRIAR, H., & BHATTACHARYA, P. Improving the prediction accuracy of decision tree mining with data preprocessing. In: **Computer Software and Applications Conference (COMPSAC), 2017 IEEE 41st Annual**. IEEE, p. 481-484, 2017.
- CHAUHAN, H., KUMAR, V., PUNDIR, S., & PILLI, E. S. A comparative study of classification techniques for intrusion detection. In: **Computational and Business Intelligence (ISCBI), 2013 International Symposium on**. IEEE, 2013. p. 40-43.

CHEDZOY, O. B. Phi-Coefficient. **Wiley StatsRef: Statistics Reference Online**, 2014.

CHEN, G., & KOTZ, D. **A survey of context-aware mobile computing research**. Technical Report TR2000-381, Dept. of Computer Science, Dartmouth College, 2000.

COOK, Diane J.; AUGUSTO, Juan C.; JAKKULA, Vikramaditya R. Ambient intelligence: Technologies, applications, and opportunities. **Pervasive and Mobile Computing**, v. 5, n. 4, p. 277-298, 2009.

DALGAARD, Lea Gulstav; GRONVALL, Erik; VERDEZOTO, Nervo. MediFrame: a tablet application to plan, inform, remind and sustain older adults' medication intake. In: **Healthcare Informatics (ICHI), 2013 IEEE international conference on**. IEEE, p. 36-45, 2013.

Departamento de Atenção Básica à Saúde - **DAB** portal da saúde: e-sus AB atenção básica. Disponível em: <<http://dab.saude.gov.br/portaldab/esus.php>>. Acessado em: 10/03/2018.

DEY, Anind K. Understanding and using context. **Personal and ubiquitous computing**, v. 5, n. 1, p. 4-7, 2001.

DIETTERICH, Thomas G. Approximate statistical tests for comparing supervised classification learning algorithms. **Neural computation**, v. 10, n. 7, p. 1895-1923, 1998.

DING, Shifei; ZHU, Zhibin; ZHANG, Xiekai. An overview on semi-supervised support vector machine. **Neural Computing and Applications**, v. 28, n. 5, p. 969-978, 2017.

DINGLI, Alexiei; ABELA, Charlie; D'AMBROGIO, Ilenia. Pervasive nursing and doctoral assistant-PINATA. In: **PervasiveHealth**. p. 123-130, 2011.

FAWCETT, Tom. An introduction to ROC analysis. **Pattern recognition letters**, v. 27, n. 8, p. 861-874, 2006.

FRIEDMAN, Jerome H. Greedy function approximation: a gradient boosting machine. **Annals of statistics**, p. 1189-1232, 2001.

GAMA, J., CARVALHO, A. C. P. D. L., FACELI, K., LORENA, A. C., & OLIVEIRA, M. **Extração de conhecimento de dados: data mining**. 2015.

GLUHAK, A., KRCO, S., NATI, M., PFISTERER, D., MITTON, N., & RAZAFINDRALAMBO, T. A survey on facilities for experimental internet of things research. **IEEE Communications Magazine**, v. 49, n. 11, p. 58-67, 2011.

GOMES, C. E., LUCENA, V. F., YAZDI, F., & GÖHNER, P. Extending an intelligent medicine cabinet through the use of consumer electronic devices in order to increase the medication adherence. In: **Consumer Electronics-Berlin (ICCE-Berlin), 2015 IEEE 5th International Conference on**. IEEE, p. 98-102, 2015.

GUBBI, J., BUYYA, R., MARUSIC, S., & PALANISWAMI, M. Internet of Things (IoT): A vision, architectural elements, and future directions. **Future generation computer systems**, v. 29, n. 7, p. 1645-1660, 2013.

HAGRAS, H., CALLAGHAN, V., COLLEY, M., CLARKE, G., POUNDS-CORNISH, A., & DUMAN, H. Creating an ambient-intelligence environment using embedded agents. **IEEE Intelligent Systems**, v. 19, n. 6, p. 12-20, 2004.

HALL, M., FRANK, E., HOLMES, G., PFAHRINGER, B., REUTEMANN, P., & WITTEN, I. H. The WEKA data mining software: an update. **ACM SIGKDD explorations newsletter**, v. 11, n. 1, p. 10-18, 2009.

HAYNES, R. Brian; MCDONALD, Heather P.; GARG, Amit X. Helping patients follow prescribed treatment: clinical applications. **Jama**, v. 288, n. 22, p. 2880-2883, 2002.

HEZARJARIBI, Niloofar; FALLAHZADEH, Ramin; GHASEMZADEH, Hassan. A machine learning approach for medication adherence monitoring using body-worn sensors. In: **Proceedings of the 2016 Conference on Design, Automation & Test in Europe**. EDA Consortium, p. 842-845, 2016.

HONKAVIRTA, V., PERALA, T., ALI-LOYTTY, S., & PICHÉ, R. A comparative survey of WLAN location fingerprinting methods. In: **Positioning, Navigation and Communication, 2009. WPNC 2009. 6th Workshop on**. IEEE, p. 243-251, 2009.

IBGE- Instituto Brasileiro de Geografia e Estatística. “Pesquisa Nacional por Amostragem de Domicílios”. **IBGE**, 2017.

JACKEVICIUS, Cynthia A.; MAMDANI, Muhammad; TU, Jack V. Adherence with statin therapy in elderly patients with and without acute coronary syndromes. **Jama**, v. 288, n. 4, p. 462-467, 2002.

JIMMY, Beena; JOSE, Jimmy. Patient medication adherence: measures in daily practice. **Oman medical journal**, v. 26, n. 3, p. 155, 2011.

KITCHENHAM, B., BUDGEN, D., BRERETON, P., TURNER, M., CHARTERS, S., & LINKMAN, S. Large-scale software engineering questions—expert opinion or empirical evidence?. **IET software**, v. 1, n. 5, p. 161-171, 2007.

KITTLER, J., HATEF, M., DUIN, R. P., & MATAS, J..On combining classifiers. **IEEE transactions on pattern analysis and machine intelligence**, v. 20, n. 3, p. 226-239, 1998.

KOMNINOS, Nicos; TSARCHOPOULOS, Panagiotis; KAKDERI, Christina. New services design for smart cities: A planning roadmap for user-driven innovation. In: **Proceedings of the 2014 ACM international workshop on Wireless and mobile technologies for smart cities**. ACM, p. 29-38, 2014.

KOTSIANTIS, Sotiris B.; ZAHARAKIS, I.; PINTELAS, P. Supervised machine learning: A review of classification techniques. **Emerging artificial intelligence applications in computer engineering**, v. 160, p. 3-24, 2007.

KUHN, Max; JOHNSON, Kjell. **Applied predictive modeling**. New York: Springer, 2013.

KUNCHEVA, Ludmila I. **Combining pattern classifiers: methods and algorithms**. John Wiley & Sons, 2004.

LAM, Wai Yin; FRESCO, Paula. Medication adherence measures: an overview. **BioMed research international**, 2015.

LORENA, Ana Carolina; GAMA, João; FACELI, Katti. **Inteligência Artificial: Uma abordagem de aprendizado de máquina**. Grupo Gen-LTC, 2011.

MAFRA, Sômulo Nogueira; TRAVASSOS, Guilherme Horta. Estudos Primários e Secundários apoiando a busca por Evidência em Engenharia de Software. **Relatório Técnico**, RT-ES, v. 687, n. 06, 2006.

MAGLOGIANNIS, I., SPYROGLOU, G., PANAGOPOULOS, C., MAZONAKI, M., & TSANAKAS, P.. Mobile reminder system for furthering patient adherence utilizing commodity smartwatch and Android devices. In: **Wireless Mobile Communication and Healthcare (Mobihealth), 2014 EAI 4th International Conference on**. IEEE, p. 124-127, 2014.

MEERAGANDHI, G. Machine learning approach for attack prediction and classification using supervised learning algorithms. **Int. J. Comput. Sci. Commun**, v. 1, n. 2, 2010.

MIAO, F., CHENG, Y., HE, Y., HE, Q., & LI, Y. A wearable context-aware ECG monitoring system integrated with built-in kinematic sensors of the smartphone. **Sensors**, v. 15, n. 5, p. 11465-11484, 2015.

MIRANDA, Gabriella Morais Duarte; MENDES, Antonio da Cruz Gouveia; DA SILVA, Ana Lucia Andrade. O envelhecimento populacional brasileiro: desafios e consequências sociais atuais e futuras. **Revista Brasileira de Geriatria e Gerontologia**, v. 19, n. 3, p. 507-519, 2016.

MISRA, G., KUMAR, V., AGARWAL, A., & AGARWAL, K.. Internet of things (iot)—a technological analysis and survey on vision, concepts, challenges, innovation directions, technologies, and applications (an upcoming or future generation computer communication system technology). **American Journal of Electrical and Electronic Engineering**, v. 4, n. 1, p. 23-32, 2016.

O'GRADY, Michael; O'HARE, Gregory. How smart is your city?. **Science**, v. 335, n. 6076, p. 1581-1582, 2012.

OTEBOLAKU, Abayomi Moradeyo; ANDRADE, Maria Teresa. Supporting context-aware cloud-based media recommendations for smartphones. In: **Mobile Cloud Computing, Services, and Engineering (MobileCloud), 2014 2nd IEEE International Conference on**. IEEE, p. 109-116, 2014.

PANDYA, Rutvija; PANDYA, Jayati. C5. 0 algorithm to improved decision tree with feature selection and reduced error pruning. **International Journal of Computer Applications**, v. 117, n. 16, p. 18-21, 2015.

PHAN, N., CHUN, S. A., BHOLE, M., & GELLER, J. Enabling real-time drug abuse detection in tweets. In: **2017 IEEE 33rd International Conference on Data Engineering (ICDE)**. IEEE, p. 1510-1514, 2017.

POWERS, David Martin. Evaluation: from precision, recall and F-measure to ROC, informedness, markedness and correlation. 2011.

Previdência. Aposentadoria: Tábua de mortalidade do IBGE muda fator previdenciário. Disponível em: <<http://www.previdencia.gov.br/noticias/aposentadoria-tabua-de-mortalidade-do-ibge-muda-fator-previdenciario/>>. Acessado em: 10/05/2018.

QUINLAN, J. Ross. **C4. 5: programs for machine learning**. Elsevier, 2014.

QUINLAN, J.. Ross . Induction of decision trees. **Machine learning**, v. 1, n. 1, p. 81-106, 1986.

QUINLAN, R. C. 4.5: Programs for machine learning morgan kaufmann publishers inc. **San Francisco, USA**, 1993.

RAMOS, Carlos; AUGUSTO, Juan Carlos; SHAPIRO, Daniel. Ambient intelligence—the next step for artificial intelligence. **IEEE Intelligent Systems**, v. 23, n. 2, p. 15-18, 2008.

RANGANATHAN, Anand; CAMPBELL, Roy H. A middleware for context-aware agents in ubiquitous computing environments. In: **ACM/IFIP/USENIX International Conference on Distributed Systems Platforms and Open Distributed Processing**. Springer, Berlin, Heidelberg, p. 143-161, 2003.

RUSSELL, Stuart J.; NORVIG, Peter. **Artificial intelligence: a modern approach**. Malaysia; Pearson Education Limited, 2016.

SABATÉ, Eduardo. **Adherence to long-term therapies: evidence for action**. World Health Organization, 2003.

SCHILIT, Bill; ADAMS, Norman; WANT, Roy. Context-aware computing applications. In: **Mobile Computing Systems and Applications, 1994. Proceedings., Workshop on**. IEEE, p. 85-90, 1994.

SMITH, D. Readings in Artificial Intelligence and Software Engineering. **chapter Top-down Synthesis of Divideand-Conquer Algorithms**. 1986.

SOLANAS, A., PATSAKIS, C., CONTI, M., VLACHOS, I. S., RAMOS, V., FALCONE, F., & MARTINEZ-BALLESTE, A. Smart health: a context-aware health paradigm within smart cities. **IEEE Communications Magazine**, v. 52, n. 8, p. 74-81, 2014.

SPANOUDAKIS, Nikolaos; MORAITIS, Pavlos. Engineering ambient intelligence systems using agent technology. **IEEE Intelligent Systems**, v. 30, n. 3, p. 60-67, 2015.

STRONG, Diane M.; LEE, Yang W.; WANG, Richard Y. Data quality in context. **Communications of the ACM**, v. 40, n. 5, p. 103-110, 1997.

SUTTON, R. S., & BARTO, A. G. **Reinforcement learning: An introduction**. MIT press, 1998.

SZEPESVARI, Csaba. Algorithms for Reinforcement Learning (Synthesis Lectures on Artificial Intelligence and Machine Learning). **Morgan and Claypool**, 2010.

TAKATSUKA, H., SAIKI, S., MATSUMOTO, S., & NAKAMURA, M. A rule-based framework for managing context-aware services based on heterogeneous and distributed Web services. In: **Software Engineering, Artificial Intelligence, Networking and Parallel/Distributed Computing (SNPD), 2014 15th IEEE/ACIS International Conference on**. IEEE, p. 1-6, 2014.

TAPIA, E. M., MARMASSE, N., INTILLE, S. S., & LARSON, K. MITes: Wireless portable sensors for studying behavior. In: **Proceedings of Extended Abstracts Ubicomp 2004: Ubiquitous Computing**. 2004.

UN- População idosa mais do que dobrará até 2050; especialista da ONU pede foco em direitos. Disponível em: <<https://nacoesunidas.org/populacao-idosa-mais-do-que-dobrara-ate-2050-especialista-da-onu-pede-foco-em-direitos/>>. Acessado em: 08/04/2018.

WEBER, Rolf H.; WEBER, Romana. **Internet of things**. Heidelberg: Springer, 2010.

WEISER, Mark. The computer for the 21st century: specialized elements of hardware and software, connected by wires, radio waves and infrared, will be so ubiquitous that no one will notice their presence. In: **Readings in Human-Computer Interaction**. p. 933-940, 1995.

WITTEN, I. H., FRANK, E., HALL, M. A., & PAL, C. J. **Data Mining: Practical machine learning tools and techniques**. Morgan Kaufmann, 2016.

WORLD HEALTH ORGANIZATION. **World report on ageing and health**. World Health Organization, 2015.

WU, X., KUMAR, V., QUINLAN, J. R., GHOSH, J., YANG, Q., MOTODA, H., & ZHOU, Z. H.. Top 10 algorithms in data mining. **Knowledge and information systems**, v. 14, n. 1, p. 1-37, 2008.

YACHIR, A., AMIRAT, Y., CHIBANI, A., & BADACHE, N. Event-aware framework for dynamic services discovery and selection in the context of ambient intelligence and Internet of Things. **IEEE Transactions on Automation Science and Engineering**, v. 13, n. 1, p. 85-102, 2016.

YAQOUB, I., AHMED, E., HASHEM, I. A. T., AHMED, A. I. A., GANI, A., IMRAN, M., & GUIZANI, M. Internet of things architecture: Recent advances, taxonomy, requirements, and open challenges. **IEEE wireless communications**, v. 24, n. 3, p. 10-16, 2017.

ZAMORA-IZQUIERDO, Miguel A.; SANTA, José; GÓMEZ-SKARMETA, Antonio F. An integral and networked home automation solution for indoor ambient intelligence. **IEEE Pervasive Computing**, v. 9, n. 4, p. 66-77, 2010.

ZENG, Xiaolong et al. Behavioral analysis and modeling of sensor network system in ambient intelligence environment. In: **Intelligent Control and Information Processing (ICICIP), 2013 Fourth International Conference on**. IEEE, p. 283-288, 2013.

ZHANG, C. G., XIA, S. X., CAI, S. Y., & WAN, L. Semi-supervised Gaussian process classification algorithm addressing the class imbalance. **Journal of China Institute of Communications**, v. 34, n. 5, p. 42-51, 2013.

ZHANG, Guoqiang Peter. Neural networks for classification: a survey. **IEEE Transactions on Systems, Man, and Cybernetics, Part C (Applications and Reviews)**, v. 30, n. 4, p. 451-462, 2000.

ZIMMER, Tobias. Towards a better understanding of context attributes. In: **Pervasive Computing and Communications Workshops, 2004. Proceedings of the Second IEEE Annual Conference on**. IEEE, p. 23-27, 2004.

# Apêndice

## Principais publicações

SILVA, V. J. ; Vinicius S. Souza; Robson G.; Nasser Jazdi; Vicente F. de Lucena. MobiHealth: a System to Improve Medication Adherence in Hypertensive Patients. The 8th International Conference on Current and Future Trends of Information and Communication Technologies in Healthcare (ICTH 2018).

SILVA, VANDERMI J. ; GOMES, CLÁUDIO. E.M. ; SANTANA, SUELLEN. S. ; DE LUCENA, VICENTE F. . Intelligent System for Medication Management in Residential Environments. IFAC-PapersOnLine , v. 49, p. 171-174, 2016.

DA SILVA, V. J. ; MAIA, O. B. ; RODRIGUES, M. ; DE LUCENA, V. F. . Universal system for integrating commercial medical devices with standardized digital TV system. In: 2016 IEEE International Conference on Consumer Electronics (ICCE), 2016, Las Vegas.

SILVA, VANDERMI J. ; RODRIGUES, MARLOS A. S. ; BARRETO, RAIMUNDO ; FERREIRA DE LUCENA, VICENTE . UbMed: A ubiquitous system for monitoring medication adherence. In: 2016 IEEE 18th International Conference on eHealth Networking, Applications and Services (Healthcom), 2016, Munich. 2016 IEEE 18th International Conference on e-Health Networking, Applications and Services (Healthcom), 2016. p. 1.

SILVA, VANDERMI ; FERREIRA JR, VICENTE ; S. VIANA, NAIRON . Architecture for Integrating Healthcare Services to the Brazilian Digital TV System. Revista IEEE América Latina , v. 13, p. 241-249, 2015.

SILVA, G. L. P. ; CRUZ, L. F. ; OLIVEIRA, J. A. ; SILVA, V. J. . DomeSis: Sistema para integração de dispositivos móveis com sensores e atuadores em ambientes automatizados. In: 33 Simpósio Brasileiro de Redes de Computadores e Sistemas Distribuídos- SBRC, 2015, Vitória-ES. ANAIS DO WoCCES 2015 - SBRC 2015, 2015. v. 1. p. 41-50.

RODRIGUES, MARIOS A. S. ; SILVA, VANDERMI J. ; DE LUCENA, VICENTE F. . An intelligent medication system designed to improve the medication adherence. In: 2015 IEEE 5th International Conference on Consumer Electronics Berlin (ICCEBerlin), 2015, Berlin. 2015 IEEE 5th International Conference on Consumer Electronics - Berlin (ICCE-Berlin), 2015. p. 46.

SILVA, V. J. ; SILVA, G. L. P. ; Vicente Lucena Jr. . Arquitetura experimental para automação e integração de ambientes inteligentes com dispositivos móveis. In: XXXII Simpósio Brasileiro de Redes de Computadores e Sistemas Distribuídos, 2014, Florianópolis. Anais XXXII Simpósio Brasileiro de Redes de Computadores e Sistemas Distribuídos. Porto Alegre: Sociedade Brasileira de Computação (SBC), 2014. v. 1. p. 24-37.