



SENAI CIMATEC

**PROGRAMA DE PÓS-GRADUAÇÃO EM MODELAGEM
COMPUTACIONAL E TECNOLOGIA INDUSTRIAL
Doutorado em Modelagem Computacional e Tecnologia Industrial**

Documento de Tese de Doutorado

**Modelagem de Padrões Comportamentais de Pessoas
em Domicílios Unipessoais**

Apresentada por: Márcio Renê Brandão Sousa

Orientador: Valter de Senna

Co-orientador: Valéria Loureiro da Silva

15 de Maio de 2015

Márcio Renê Brandão Sousa

Modelagem de Padrões Comportamentais de Pessoas em Domicílios Unipessoais

Documento de Tese de Doutorado apresentada ao Programa de Pós-graduação em Modelagem Computacional e Tecnologia Industrial, Curso de Doutorado em Modelagem Computacional e Tecnologia Industrial do SENAI CIMATEC, como requisito parcial para a obtenção do título de **Doutor em Modelagem Computacional e Tecnologia Industrial**.

Área de conhecimento: Interdisciplinar

Orientador: Valter de Senna

SENAI CIMATEC

Coorientadora: Valéria Loureiro da Silva

SENAI CIMATEC

Salvador
SENAI CIMATEC
2015

Este documento de tese de doutorado foi elaborada considerando as normas de estilo (i.e. estéticas e estruturais) propostas aprovadas pelo colegiado do Programa de Pós-graduação em Modelagem Computacional e Tecnologia Industrial e estão disponíveis em formato eletrônico (*download* na Página Web http://ead.fieb.org.br/portal_faculdades/dissertacoes-e-teses-mcti.html ou solicitação via e-mail à secretaria do programa) e em formato impresso somente para consulta.

Ressalta-se que o formato proposto considera diversos itens das normas da Associação Brasileira de Normas Técnicas (ABNT), entretanto opta-se, em alguns aspectos, seguir um estilo próprio elaborado e amadurecido pelos professores do programa de pós-graduação supracitado.

SENAI CIMATEC

Programa de Pós-graduação em Modelagem Computacional e Tecnologia Industrial

Doutorado em Modelagem Computacional e Tecnologia Industrial

A Banca Examinadora, constituída pelos professores abaixo listados, leram e recomendam a aprovação da Tese, intitulada “Modelagem de Padrões Comportamentais de Pessoas em Domicílios Unipessoais”, apresentada no dia (15) de (Maio) de (2015), como requisito parcial para a obtenção do título de **Doutor em Modelagem Computacional e Tecnologia Industrial**.

Orientador:

Prof. Dr. Valter de Senna

SENAI CIMATEC

Coorientadora:

Profa. Dra. Valéria Loureiro da Silva

SENAI CIMATEC

Membro interno da Banca:

Prof. Dr. Hernane Borges de Barros Pereira

SENAI CIMATEC

Membro interno da Banca:

Prof. Dr. Roberto Luiz Souza Monteiro

SENAI CIMATEC

Membro externo da Banca:

Prof. Dr. José Garcia Vivas

UFBA - Universidade Federal da Bahia

Membro externo da Banca:

Prof. Dr. Sebastião Antônio Loureiro de Souza e Silva

UFBA - Universidade Federal da Bahia

Dedico este trabalho a ...

Agradecimentos

Após alguns anos de muito esforço, é hora a agradecer à aqueles que estiveram juntos comigo nessa jornada.

Primeiro gostaria de agradecer ao meu pai, pelo exemplo de força e trabalho e a minha querida minha mãe, pelo exemplo de humildade e sabedoria, e onde quer que ela esteja, sei que estará celebrando essa conquista.

Gostaria de agradecer a minha amada esposa Paula e os meus maravilhosos filhos, Júlia e Mateus, pela paciência devido as privações de tempo que tivemos durante todo esse tempo. Gostaria de agradecer também a minha irmã pelo eterno incentivo.

Agradeço também ao meu orientador, o Professor Valter Senna, pela parceria que construímos desde os tempos do mestrado e a minha coorientadora, a Professora Valéria Silva, pelas importantes contribuições e grande generosidade. Aproveito para agradecer a disponibilidade e as contribuições dos Professores Hernane Pereira e Roberto Monteiro.

Por fim, não poderia esquecer de agradecer a todos os colegas que estiveram me incentivando e ajudando nessa empreitada, especialmente, Charles Soares, Patrícia Braga, Fábio Brito e Eron Brunelli.

Salvador, Brasil
15 de Maio de 2015

Márcio Renê Brandão Soussa

RESUMO

O aumento da expectativa de vida, ligado a fatores como o desenvolvimento econômico e o avanço tecnológico contribuíram de forma significativa para uma tendência atual que é a busca pela moradia unipessoal. Estima-se que em 2011, 15% dos domicílios em todo o mundo tinham apenas um morador e um aspecto importante desse cenário, é que essa tendência vem sendo observada também entre os idosos. De acordo com o IBGE, em 2011, 14,4% dos idosos no Brasil moravam sozinhos. Contudo, o processo natural de envelhecimento traz graduais perdas físicas, mentais, cognitivas e sociais, o que se traduz em uma maior vulnerabilidade para o idoso. Diante do cenário exposto, este projeto tem como objetivo a criação de um modelo computacional capaz de aprender alguns comportamentos rotineiros de uma pessoa que mora em um domicílio unipessoal e também identificar situações consideradas de risco para a sua saúde, através de dados coletados exclusivamente por sensores de movimentação e temperatura. O modelo proposto foi testado inicialmente com dados extraídos de um programa de simulação baseada em agentes e posteriormente, com dados coletados da casa de dois idosos. Como resultado, o modelo apresentou evidências da sua capacidade em aprender alguns comportamentos considerados importantes para uma pessoa que vive sozinha, como também, em identificar algumas situações críticas, como falhas técnicas nos sensores e, principalmente, situações consideradas de risco para a sua saúde da pessoa.

Palavras-chave: Reconhecimento de Padrões, Mineração de Dados, Domicílio Unipessoal

ABSTRACT

The increase in life expectancy linked to other important factors, such as economic development and technological advancements have contributed significantly to a current trend for single-person households. It is estimated that in 2011, almost 15% of households worldwide had only one resident and an important aspect is that this trend has also been observed among the elderly. According to IBGE, in 2011, 14.4% of the elderly in Brazil lived alone. Moreover, the natural aging process brings gradual physical, mental, cognitive and social losses, resulting in a greater vulnerability for them. So, this project aims at creating a computational model capable of learning some routine behaviors of a person who lives alone and also identifying activities considered abnormal and suggestive of health risks, based on data extracted exclusively from motion and temperature sensors. The proposed model was tested initially over data collected from a agent based simulation program and later, over data collected from the house of two elderly that live alone. As a result, the model presented some evidence of its ability to learn some person's behavior considered important, as well as some situations considered critical, like sensor problems and also situations considered suggestive of health risks.

Keywords: Pattern Recognition, Data Mining, Single-Person Households

Sumário

1	Introdução	1
1.1	Definição do problema	2
1.2	Objetivo	3
1.3	Importância da pesquisa	3
1.4	Motivação	4
1.5	Limites e limitações	4
1.6	Questões e hipóteses	5
1.7	Aspectos metodológicos	6
1.8	Organização da Documento de Tese de Doutorado	6
2	Transformações Sociais	8
2.1	Introdução	8
2.2	Uma breve visão histórica da vida em família	8
2.3	Transformações Sociais ocorridas a partir do século XIX	9
2.3.1	Transição Demográfica	10
2.3.2	Crescimento no número de pessoas morando sozinhas	11
2.4	Síntese	13
3	Tecnologias de suporte a qualidade de vida	15
3.1	Introdução	15
3.2	Conceitos	15
3.3	Cenário Atual das Tecnologias de Assistência Domiciliar	17
3.4	Pesquisas e Produtos de monitoramento domiciliar	18
3.5	Síntese	20
4	Fundamentação Teórica	24
4.1	Introdução	24
4.2	Reconhecimento de Padrões	24
4.2.1	Estimador de Função Densidade	27
4.2.1.1	Estimador Kernel	27
4.2.2	Mineração de Padrões Sequenciais	32
4.2.2.1	Introdução	32
4.2.2.2	Definição Formal do Problema	32
4.2.2.3	Algoritmo SPADE	33
4.2.3	Detecção de Outliers	38
4.2.3.1	Introdução	38
4.2.3.2	Abordagens	39
4.2.3.3	Algoritmo LOF (Local Outlier Factor)	40
4.3	Sensores	43
4.3.1	Introdução	43
4.3.2	Sensor de Movimentação	44
4.3.3	Sensor de temperatura	45
4.3.4	Conclusão	45

5	Modelo Proposto	46
5.1	Introdução	46
5.2	Visão Geral	46
5.2.1	Propósito	46
5.2.2	Variáveis de Estado e Escalas	48
5.2.3	Visão de Processo e Escalonamento	50
5.3	Conceitos de Projeto	51
5.3.1	Conceitos de Projeto	51
5.4	Detalhes	51
5.4.1	Inicialização	51
5.4.1.1	Posicionamento dos Sensores na Residência	52
5.4.1.2	Configuração dos Possíveis Caminhos entre os Cômodos da Residência	53
5.4.1.3	Inicialização de Parâmetros e Variáveis do Modelo	54
5.4.2	Entrada	54
5.4.3	Submodelos	55
5.4.3.1	Processo 1: Pré-Processamento de Dados	55
5.4.3.2	Processo 2: Reconhecimento de Padrões	71
5.4.3.3	Processo 3: Identificação de Situações Anormais	74
5.5	Conclusão	83
6	Experimentos com o modelo	84
6.1	Introdução	84
6.2	Experimentos com dados extraídos de uma simulação computacional baseada em agentes	84
6.2.1	Breve descrição do programa de simulação baseada em agentes	84
6.2.2	Análise acerca dos testes realizados com o uso do programa de simulação	86
6.3	Experimentos com dados extraídos de ambientes reais	87
6.3.1	Características dos Idosos Monitorados	87
6.3.2	Inicialização do Modelo	88
6.3.2.1	Especificação e Configuração dos Ambientes	88
6.3.2.2	Configuração do grafo de sensores	89
6.3.2.3	Inicialização de parâmetros do modelo	90
6.3.3	Padrões de Comportamento Encontrados	91
6.3.3.1	Padrões de Presença nos Cômodos e Móveis da Residência	91
6.3.3.2	Padrões da Atividade de Dormir	95
6.3.3.3	Padrões de movimentação entre cômodos da residência, em alguns intervalos de hora	97
6.3.3.4	Padrões de entrada e saída da residência	98
6.3.4	Situações Anormais Encontradas	100
6.3.4.1	Situações de Risco Iminente	100
6.3.4.2	Identificação de Situações de Risco Não Iminente	101
6.3.5	Inconsistência na ativação dos sensores de movimentação	105
6.4	Conclusão	105
7	Considerações finais	106
7.1	Conclusões	106
7.2	Contribuições	108
7.3	Atividades Futuras de Pesquisa	109

Referências	110
A Comitê de Ética	116

Lista de Tabelas

2.1	Expectativa Média de Vida e Número de Idosos no Brasil e no Mundo . . .	10
2.2	Proporção de domicílios unipessoais em alguns países, em 2011	11
3.1	Resumo de Projetos de Tecnologia de Suporte a Qualidade de vida	22
4.1	Funções Kernel mais conhecidas	28
4.2	Base de Dados de Transação	33
5.1	Variáveis de Estado do Modelo	49
5.2	Parâmetros do Modelo	50
5.3	Dados sobre atividades com baixa emissão de sinais	68
5.4	Quantidade de acionamento dos sensores, por intervalo de hora	69
5.5	Período de presença da pessoa nos cômodos, por intervalo de hora	71
5.6	Exemplo de dados pré-configurados para a execução do algoritmo SPADE. Intervalo das 06:00 às 07:00	73
5.7	Frequência na realização das principais refeições em casa	74
5.8	Aspectos da atividade de dormir identificados pelo modelo	80
5.9	Mapeamento entre as Questões/Hipóteses do projeto e os métodos/técnicas utilizados para solucioná-las	83
6.1	Resumo do questionário aplicado às pessoas monitoradas	88
6.2	Relação dos sensores presentes no grafo de sensores da casa dos dois idosos	90
6.3	Inicialização dos parâmetros utilizados no modelo	91
6.4	Padrões de Movimentação entre os cômodos e móveis da residência	97
6.5	Dados pré-processados da atividade de dormir do idoso 1	102
6.6	Dados pré-processados da atividade de dormir do idoso 2	103

Lista de Figuras

1.1	Inter-relação entre os projetos de mestrado e este projeto de doutorado. . .	2
4.1	Etapas do Processo de Reconhecimento de Padrões.	25
4.2	Influência de cada observação na construção de Função Densidade.	28
4.3	Formato das Funções Kernel mais conhecidas. Da esquerda para a direita e de cima para baixo: uniforme, triangular, exponencial (ou gaussiana), epanechnikov, quartic (ou biweight) e triweight.	29
4.4	Exemplo ilustrativo de uma Função Densidade.	30
4.5	Exemplos de duas funções densidade para um mesmo conjunto de dados, alterando apenas a largura de banda. A primeira possui $h = 0,2$ e a segunda, $h = 4$	31
4.6	Listas contendo os registros de cada item.	34
4.7	Listas contendo as sequências frequentes de 1 item.	35
4.8	Lista contendo os pares (Item, EID) para cada SID.	35
4.9	Listas contendo as sequências frequentes com 2 itens.	36
4.10	Equivalência entre Sequências com tamanho 2.	37
4.11	Lista contendo algumas sequências de tamanho 3.	37
4.12	Exemplo ilustrativo de <i>outliers</i>	39
4.13	Pontos em áreas com densidades bem distintas.	41
4.14	Distância entre um ponto o e seus k vizinhos.	42
4.15	Resultado da aplicação do algoritmo LOF com k vizinhos.	43
4.16	Ilustração do Funcionamento de um Sensor PIR.	44
5.1	Protocolo ODD.	46
5.2	Visão geral do funcionamento do sistema de monitoramento.	47
5.3	Visão geral do modelo proposto.	48
5.4	Relação entre as entidades do modelo.	48
5.5	Atividades que compõem a etapa de inicialização do modelo.	52
5.6	Critérios para instalação dos sensores em uma residência.	53
5.7	Exemplo de um grafo de sensores de movimentação.	54
5.8	Submodelos que compõem o processo Pré-Processamento de Dados.	55
5.9	Alg01 - Identificação de entrada na residência quando ela estiver vazia. . .	57
5.10	Alg02 - Identificação de entrada e saída da residência quando há apenas uma pessoa.	59
5.11	Alg03 - Identificação de entrada e saída da residência quando há mais de uma pessoa.	61
5.12	Alg04 - Confirmação ou correção no número de pessoas na residência. . . .	63
5.13	Alg05 - Determinação dos intervalos ininterruptos de uso de móveis relacionados com atividades de baixa emissão de sinais.	65
5.14	Alg06 - Verificação de prolongamento do uso de móveis relacionados com atividades de baixa emissão de sinais.	67
5.15	Alg07 - Contabilização do número de acionamento dos sensores, por intervalo de hora.	69
5.16	Alg08 - Contabilização do tempo presente nos cômodos, por intervalo de hora.	70

5.17	Submodelos que compõem o processo de reconhecimento de padrões.	71
5.18	Situações de risco iminente à saúde da pessoa.	75
5.19	Alg09 - Verificação de valores críticos de temperatura.	76
5.20	Alg10 - Não recepção de sinais de movimentação por um período maior do que o esperado.	77
5.21	Alg11 - Verificação do tempo fora de casa.	79
5.22	Alg12 - Verificação de inconsistência na sequência de ativação dos sensores de movimentação.	82
6.1	Exemplo de uma planta baixa de uma casa e os sensores nela posicionados.	85
6.2	Área de alcance de um sensor de movimentação no ambiente virtual.	85
6.3	Residências monitoradas: (a) - Idoso 1 e (b) - Idoso 2.	89
6.4	Densidade de ativações dos sensores instalados na sala, cozinha e banheiro.	92
6.5	Densidade de ativações dos sensores da mesa e do sofá.	94
6.6	Funções Densidade dos horários habituais de “dormir” e “acordar” dos idosos.	96
6.7	Horários habituais de saída da casa. Idoso 1 à esquerda e o idoso 2 à direita.	99
6.8	Quantidade de ativações simultâneas para cada hora, durante todos dias monitorados.	100
6.9	Resultado da aplicação do algoritmo LoF sobre dados da atividade de dormir do idoso 1 (acima) e idoso 2 (abaixo).	104
A.1	Termo de Consentimento Livre e Esclarecido.	116
A.2	Documento de Aprovação do Projeto pelo Comitê de Ética (Página 01/05).	117
A.3	Documento de Aprovação do Projeto pelo Comitê de Ética (Página 02/05).	118
A.4	Documento de Aprovação do Projeto pelo Comitê de Ética (Página 03/05).	119
A.5	Documento de Aprovação do Projeto pelo Comitê de Ética (Página 04/05).	120
A.6	Documento de Aprovação do Projeto pelo Comitê de Ética (Página 05/05).	121

Introdução

Ao longo da história da humanidade, mudanças graduais foram transformando de forma significativa a vida em sociedade, mas foi a partir do século XIX, que essas transformações começaram a ocorrer de forma mais rápida e que cujos reflexos afetaram todos os aspectos da vida em sociedade, e em especial o ambiente familiar.

Uma transformação muito importante foi a transição demográfica, ocorrida a partir da revolução industrial e que pode ser caracterizada essencialmente pela redução significativa das taxas de natalidade e mortalidade das populações.

Como consequência direta dessa mudança demográfica, as populações estão envelhecendo de uma forma nunca antes observada. De acordo com [IBGE \(2013\)](#) e [Health \(2013\)](#), a expectativa média de vida no Brasil e no mundo em 2012 chegou a 74,6 e 73 anos, respectivamente, e em alguns países, atualmente ela já passa dos 82 anos, como é o caso do Japão, Singapura, Suíça, Austrália, dentre outros. De acordo com [UNFPA \(2012\)](#), em 2011, os idosos já correspondiam a 11,5% da população mundial e 12,1% da população brasileira.

Aliados a esse aumento da expectativa de vida, outros fatores importantes que ocorreram nos últimos séculos, como o desenvolvimento econômico, os aprimoramentos das leis de seguridade social, o processo de urbanização e especialmente, o desenvolvimento tecnológico contribuíram para uma tendência de comportamento que já é observada há algumas décadas em alguns países desenvolvidos, e que vem sendo percebida mais recentemente no Brasil, que é a busca pela moradia unipessoal.

[Euromonitor \(2012\)](#) estimou que no ano de 2011, aproximadamente 15% de todos os domicílios no mundo tinham apenas um morador. E essa tendência em morar sozinho, também vem sendo observada entre os idosos. [Nations \(2005\)](#) estimou que em 2005, 14% dos idosos no mundo moravam sozinhos e no Brasil, [IBGE \(2012\)](#) contabilizou em 2011, 14,4% dos idosos morando sozinhos.

Contudo, o processo natural de envelhecimento traz graduais perdas físicas, mentais, cognitivas e sociais, o que se traduz em uma maior vulnerabilidade para o idoso, principalmente para aqueles que moram sozinhos. Por essa razão, esse cenário tem despertado bastante interesse de diversos segmentos da sociedade, o que tem levado às indústrias a investirem na criação de produtos e serviços tecnológicos para o segmento de assistência domiciliar à saúde.

1.1 Definição do problema

O cenário exposto anteriormente faz suscitar uma questão muito comum no cotidiano atual de pessoas que moram sozinhas, principalmente dos idosos, seus familiares e amigos, e especialmente nos grandes centros urbanos, que é: como monitorar remotamente, de forma não intrusiva e com baixo custo uma pessoa que mora em um domicílio unipessoal, aprender alguns dos seus comportamentos rotineiros e também identificar algumas situações consideradas de risco para a sua saúde?

O problema de pesquisa supracitado foi segmentado e distribuído entre este projeto de doutorado e dois projetos de mestrado, desenvolvidos no mesmo programa de pós-graduação, e a relação entre eles pode ser vista na Figura 1.1.

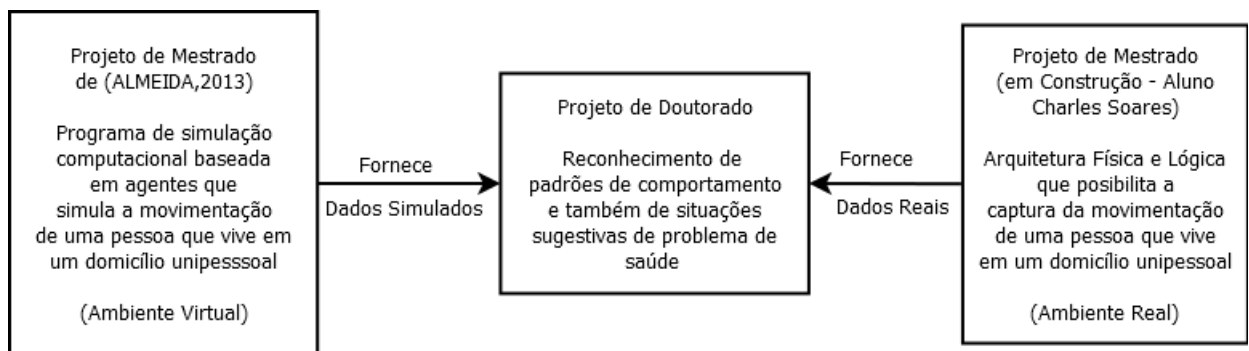


Figura 1.1: Inter-relação entre os projetos de mestrado e este projeto de doutorado. Fonte: Autor

Os dois trabalhos de mestrado apresentados na Figura 1.1 têm como propósito capturar a movimentação de uma pessoa em um domicílio unipessoal, fornecendo dados para que este trabalho de doutorado possa aprender alguns padrões de comportamento da pessoa monitorada.

Vale salientar, contudo, que a principal diferença entre os dois trabalhos de mestrado é que o trabalho de Almeida (2013) fornece dados a partir de uma simulação computacional baseada em agentes, e o outro trabalho, ainda em construção, fornece dados da movimentação de um idoso em um domicílio real, por meio de um conjunto de equipamentos eletrônicos instalados na sua residência.

1.2 *Objetivo*

Esse trabalho de doutorado tem como objetivo principal propor um modelo computacional capaz de aprender alguns comportamentos habituais de uma pessoa que mora sozinha e também identificar situações consideradas de risco para a sua saúde, com base em dados coletados exclusivamente por sensores de ambiente não intrusivos.

Espera-se que o modelo consiga identificar com uma maior brevidade situações de risco para saúde da pessoa, contribuindo assim para um atendimento de socorro mais rápido, minimizando um possível agravamento do seu estado de saúde.

De forma subjacente, objetiva-se também:

- Definir os tipos de sensores mais adequados para serem utilizados na fase de sensoriamento do modelo;
- Implementar e testar algoritmos de tratamento e agrupamento de dados;
- Selecionar e testar os algoritmos de reconhecimento de padrões e mineração de dados mais adequados para o aprendizado do comportamento da pessoa monitorada.

1.3 *Importância da pesquisa*

A contribuição científica mais relevante desse trabalho está relacionada com a criação de algoritmos que tenham a capacidade de identificar padrões de comportamento de pessoas que moram sozinhas, tendo como base, tão somente dados capturados por sensores de ambiente não intrusivos, distribuídos ao longo da residência da pessoa monitorada.

O impacto tecnológico se apresenta na medida em que o modelo subsidia a criação de produtos de assistência domiciliar capazes de aprender o comportamento de uma pessoa que moram sozinha, utilizando um conjunto de sensores de ambiente, de pequeno porte, fácil instalação e baixo custo.

Sob a perspectiva social, espera-se contribuir para que pessoas que moram sozinhas, principalmente pessoas idosas ou com problemas crônicos de saúde, possam ter uma vida mais independente e segura.

1.4 Motivação

Esse trabalho justifica-se na medida em que o modelo computacional proposto fornece subsídios para a criação de produtos e serviços tecnológicos de suporte a qualidade de vida, através do monitoramento e aprendizado do comportamento de pessoas que vivem sozinhas.

Como consequência direta, espera-se que o modelo contribua para uma identificação antecipada de possíveis problemas de saúde de pessoas que moram sozinhas, reduzindo o tempo de chegada de atendimento de socorro, o período de internamento em unidades de saúde e conseqüentemente, os gastos nas unidades de atendimento à saúde.

Almeja-se por fim, contribuir para a melhoria da qualidade de vida das pessoas que moram sozinhas, principalmente dos idosos e pessoas com problemas crônicos de saúde, seus familiares e amigos, auxiliando-os na busca por uma vida mais independente e segura.

1.5 Limites e limitações

O modelo proposto nesse trabalho apresenta alguns limites importantes de serem apresentados.

Ambiente Monitorado

O modelo foi concebido para aprender o comportamento de pessoas que vivem em domicílios unipessoais, excluindo-se então, domicílios onde vive mais de uma pessoa e também ambientes de assistência à saúde, como casas de repouso, hospitais e clínicas.

Sensores

Por conta da característica não-intrusiva do projeto, está excluída a análise de dados coletados por: a) equipamentos que capturem a imagem da pessoa, como câmeras de vídeo e máquinas fotográficas; b) equipamentos que coletem dados fisiológicos da pessoa; c) sensores acoplados ao corpo da pessoa, como braceletes e relógios.

Portanto, o modelo analisa dados coletados exclusivamente por dois tipos de sensores: sensor de movimentação e sensor de temperatura ambiente.

1.6 Questões e hipóteses

Segue abaixo uma lista com questões importantes a serem respondidas pelo modelo.

Questão 1: Como aprender alguns padrões de comportamento considerados importantes para uma pessoa dentro do seu domicílio?

Hipótese 1.1: Para identificar os locais mais frequentados pela pessoa ao longo do dia e também as movimentações mais frequentes por entre os cômodos da casa, o modelo se baseia nos horários de acionamento dos sensores de presença instalados em cada cômodo e móvel da casa.

Hipótese 1.2: Os padrões habituais de dormir e de se alimentar da pessoa são aprendidos através do acionamento dos sensores instalados sobre a cama/sofá e a mesa, respectivamente.

Hipótese 1.3: Os hábitos de sair e retornar para a casa, como também o tempo que costuma ficar fora de casa, são aprendidos através do acionamento dos sensores instalados na porta de entrada da casa.

Questão 2: Como identificar situações de risco para a saúde da pessoa?

Hipótese 2.1: Os riscos iminentes são identificados quando: a) a pessoa estiver realizando atividades que apresentem baixa emissão de sinais, como dormir, cochilar, etc e não forem identificados sinais de movimentação durante um período maior que o habitual; b) a pessoa estiver realizando outras atividades e não houver o acionamento de sinais de movimentação em um intervalo maior do que um limite configurável.

Hipótese 2.2: O modelo identifica comportamentos que podem vir a comprometer a sua saúde através da detecção de mudanças significativas em alguns aspectos relacionados com as atividade de dormir e de se alimentar.

Questão 3: Como identificar falhas no acionamento dos sensores?

Hipótese 3: No caso dos sensores de movimentação, uma falha é detectada quando o sequenciamento das ativações for diferente do esperado pelo modelo e para o sensor de temperatura, quando não for identificada ativação durante um tempo maior do que o configurado no modelo.

1.7 Aspectos metodológicos

A abordagem metodológica utilizada nesse trabalho foi constituída pelas seguintes etapas:

Inicialmente foram realizadas pesquisas bibliográficas atualizadas sobre envelhecimento populacional, arranjos familiares, sensores, tecnologias de suporte a qualidade de vida e algoritmos de reconhecimento de padrões e mineração de dados.

Posteriormente, foi elaborado um desenho esquemático com os elementos que compunham o modelo e seu funcionamento. Nesta etapa foram definidos também os tipos de sensores que poderiam ser utilizados na fase captação dos sinais.

Pela ausência de dados reais que subsidiassem a etapa de construção dos algoritmos, foi implementada uma simulação computacional baseada em agentes, com o objetivo de fornecer dados para a fase de implementação e testes dos algoritmos. Vale ressaltar que em um momento posterior, essa tarefa se tornou o objetivo principal do trabalho de mestrado de (ALMEIDA, 2013).

Posteriormente, iniciou-se a etapa de codificação dos algoritmos, como também da construção de uma base de dados. Foi realizado o primeiro teste com o modelo, utilizando dados gerados por um programa de simulação baseada em agentes, proposto por (ALMEIDA, 2013) e os resultados encontrados demandaram uma calibração dos algoritmos.

A etapa posterior consistiu na instalação de um conjunto de sensores e equipamentos eletrônicos na casa de dois idosos que moram sozinhos, com o objetivo de coletar dados das suas movimentações. Contudo, antes foi necessário a submissão e aprovação do projeto (sob CAAE: 35247214.5.0000.5544.) pelo comitê de ética. No Apêndice A, são encontrados os documentos: Termo de Consentimento Livre e Esclarecido e o parecer com a aprovação pelo Conselho de Ética.

Por fim, o modelo foi testado com os dados extraídos da casa de dois idosos e os resultados foram apresentados e analisados.

1.8 Organização da Documento de Tese de Doutorado

- **Capítulo 1 - Introdução:** Contextualiza o âmbito no qual a pesquisa proposta está inserida. Apresenta, portanto, a definição do problema, objetivos e justificativas da pesquisa e como esta documento de tese de doutorado está estruturada;
- **Capítulo 2 - Transformações Sociais:** Discorre de uma forma breve sobre al-

gumas das principais mudanças ocorridas ao longo do tempo e que impactam esse trabalho;

- **Capítulo 3 - Tecnologias de suporte a qualidade de vida:** Apresenta os principais conceitos relacionados com o tema e um panorama com algumas das tecnologias mais recentes de suporte a qualidade de vida;
- **Capítulo 4 - Fundamentação Teórica:** Detalha os fundamentos teóricos que subsidiam esse trabalho: reconhecimento de padrões e sensores;
- **Capítulo 5 - Modelo Proposto:** Apresenta o modelo proposto, detalhando os seus elementos e funcionamento;
- **Capítulo 6 - Experimentos com o Modelo:** Descreve os experimentos realizados com o modelo, tanto em ambiente virtual, como em ambiente real;
- **Capítulo 7 - Considerações Finais:** Apresenta as conclusões, contribuições e algumas sugestões de atividades de pesquisa a serem desenvolvidas no futuro.

Transformações Sociais

2.1 Introdução

Este capítulo apresenta algumas das principais mudanças ocorridas na história da humanidade e cujos reflexos impactam esse trabalho. Espera-se que os fatos e abordagens apresentadas nesse capítulo permitam uma compreensão do processo de transformações ocorridas ao longo da história e que culminaram no momento em que vivemos atualmente, principalmente no que tange aspectos do ambiente domiciliar.

2.2 Uma breve visão histórica da vida em família

Ao longo da história, a humanidade tem testemunhado mudanças graduais e significativas no comportamento das pessoas e que transformaram definitivamente a vida em sociedade, principalmente no âmbito familiar.

Na época do nômades, grupos de até vinte pessoas costumavam viver juntas em cavernas, caçando e pescando, lutando pela sobrevivência. Os grupos não podiam ser muito pequenos, pois precisavam lutar contra animais selvagens e nem muito grandes, pois não tinham habitação fixa, nem plantavam e nem criavam animais. Conseqüentemente, tinham dificuldade em alimentar grandes quantidades de pessoas e também não tinham como cuidar adequadamente dos idosos e tampouco dos doentes, principalmente daqueles com dificuldade de locomoção (BLAINEY, 2011) e (GUISEPI, 2014).

A partir de 8.000 A.C., quando os primeiros povos adquiriram a habilidade de domesticar animais e posteriormente cultivar alimentos, uma revolução começou a acontecer, e a partir de então, os povos puderam se estabelecer em um lugar fixo, vivendo de suas plantações e da criação de animais. Como o suprimento de comida deixou de ser um problema crônico, tornou-se possível alimentar mais pessoas e de forma mais consistente, trazendo como consequência, um aumento nas taxas de natalidade, e por conseguinte, um aumento dessas populações. (GUISEPI, 2014)

De acordo com Goucher, Guin e Walton (1998) e Brewer e Teeter (2001), tanto os povos do Antigo Egito e da Antiga China costumavam viver em famílias numerosas, não sendo incomum a coabitação de duas ou três gerações de pessoas de uma mesma família. Goucher, Guin e Walton (1998) afirmam ainda que em grande parte da vida reprodutiva, as

mulheres egípcias estavam grávidas e que muitas delas chegavam a ter 20 ou mais filhos, sendo que poucos sobreviviam até a vida adulta. O respeito para com os mais velhos tornava um dever para o filho ou a filha mais velha, cuidar dos pais até a morte.

Em um passado mais recente, e mais especificamente, na Europa medieval do século XV, mais de 90% da população ainda vivia em zonas rurais, sobrevivendo da agricultura de subsistência, afirma [California \(2014\)](#). Devido as péssimas condições nutricionais e sanitárias das populações, estima-se que mais de um terço das crianças morriam antes dos 5 anos de idade e com isso, a expectativa de vida média não alcançava os 30 anos.

Alguns estudos sobre a história do Brasil descrevem o estilo de vida e a família no período do Brasil Colônia. [Brito \(2004\)](#) apud [Machado \(2006\)](#) afirmam que a família era a verdadeira unidade social e que um indivíduo sozinho não tinha valor para a sociedade. Eles ainda afirmam que era o sentimento de proteção que fazia um indivíduo buscar um amparo na família. Nessa época, principalmente no nordeste, um arranjo familiar muito comum era a família patriarcal extensa, que costumava viver em grandes fazendas e era formada pelo dono da casa, esposa, filhos legítimos, e também irmãos, tios, primos, além de filhos ilegítimos e escravos.

Em resumo, [Cowan \(1976\)](#) afirma que antes da revolução industrial, de uma maneira geral, a família era para muitas sociedades, a unidade social mais básica e fundamental e a maior parte delas vivia em pequenos vilarejos ou fazendas, era numerosa e alto sustentável, produzindo o que consumia e vendendo o excedente para mercados locais.

Foi uma época caracterizada por uma baixa taxa de crescimento populacional, isto porque tanto as taxas de mortalidade, quanto as de natalidade eram muito altas, o que levava a um equilíbrio do crescimento populacional.

Nessa época, as tecnologias, de uma maneira geral, ainda eram muito rudimentares, se comparadas com as atuais. No campo das comunicações, por exemplo, uma mensagem podia levar semanas ou até meses para chegar ao destinatário. As limitações nos meios de transporte não permitiam que grande parte das populações pudesse viajar para lugares muito distantes dos seus vilarejos e cidades, contribuindo para que as pessoas vivessem mais próximas dos seus familiares.

2.3 Transformações Sociais ocorridas a partir do século XIX

A partir do século XIX, a humanidade começou a testemunhar transformações mais rápidas e que afetaram quase todos os aspectos da vida em sociedade. No âmbito familiar, [Cowan \(1976\)](#) chega a afirmar que a família começou a perder sua importância,

deixando de ser o foco da produção econômica.

2.3.1 *Transição Demográfica*

De acordo com [Michigan \(2000\)](#), o termo transição demográfica refere-se a uma importante mudança ocorrida nos padrões de crescimento populacional, durante os séculos XIX e XX. Essa transição caracterizou-se essencialmente por uma redução significativa nas taxas de natalidade e mortalidade das populações.

Com a revolução industrial, houve uma melhora significativa na produção, transporte e distribuição de alimentos, como também um aprimoramento dos serviços sanitários, principalmente de água e esgoto, o que levou inicialmente a Inglaterra e posteriormente outros países, a um processo crescente de redução da mortalidade, principalmente entre as crianças, tendo como consequência, um aumento significativo de suas populações.

Posteriormente, no final do século XIX, começou-se a observar também uma tendência de redução nas taxas de natalidade nos países industrializados e [Michigan \(2000\)](#) costuma creditar esse fato a mudanças no comportamento das sociedades, como por exemplo, o processo de urbanização, onde as famílias numerosas deixaram de ser desejadas, já que as residências se tornaram menores e não precisavam de tantas pessoas para a realização dos trabalhos, como outrora nas famílias agrárias. Um outro fator também importante foi a busca por qualidade de vida, incluindo uma melhoria na educação das mulheres e a retirada das crianças como força de trabalho.

Como consequência dessa mudança demográfica, as populações no mundo inteiro estão envelhecendo de uma forma nunca vista na história de humanidade. Na Tabela 2.1 é possível visualizar a expectativa média de vida no Brasil e no mundo em 2012, como também a quantidade de idosos no Brasil e no mundo, em 2011. Entende-se por idoso, uma pessoa com 60 anos ou mais.

Tabela 2.1: Expectativa Média de Vida e Número de Idosos no Brasil e no Mundo

	Expectativa Média de Vida (anos)	Quantidade de Idosos (milhões)	(%) de Idosos
Brasil	74,6 ¹	23,5 ³	12,1 ³
Mundo	73 ²	810 ³	11,5 ³

Fontes: ¹:[IBGE \(2013\)](#), ²:[Health \(2013\)](#), ³:[UNFPA \(2012\)](#), ⁴:[IBGE \(2012\)](#),
⁵:[Euromonitor \(2012\)](#)

2.3.2 Crescimento no número de pessoas morando sozinhas

[Klinenberg \(2012\)](#) informa que até a primeira metade do século XX, as pessoas sempre buscaram viver com outras pessoas e nunca sozinhas. Porém, a partir da segunda metade do século, começou um processo gradual de mudança de comportamento, onde foi possível perceber um número crescente de pessoas, de idades e em locais diferentes, buscando morar sozinhas.

O autor chega a descrever o comportamento que era considerado padrão, onde as pessoas costumavam se casar mais cedo e conviver com o(a) parceiro(a) até a morte, e quando a viuvez acontecia de forma prematura, era comum se buscar um novo casamento. Quando a viuvez chegava em uma idade mais avançada, a pessoa ia morar na casa de algum parente ou este vinha morar na casa dela.

[Klinenberg \(2012\)](#) descreve também um comportamento que tem se tornado comum nos dias atuais, onde os jovens se casam mais tarde, mas ao invés de morarem com os pais até o casamento, como outrora, preferem morar sozinhos. Em caso de divórcio, moram mais tempo sozinhos até se engajarem em um novo arranjo familiar e no caso dos idosos, quando se tornam viúvos, preferem morar sozinhos, de forma independente, sem a companhia de filhos e netos.

[Euromonitor \(2012\)](#) estimou que de 2001 à 2011, houve um crescimento de 30,1% no número de domicílios unipessoais no mundo, representando 14,9% do total de domicílios no ano de 2011. Na Tabela 2.2 é possível visualizar o percentual de domicílios unipessoais em alguns países, inclusive o Brasil. Entende-se por domicílio unipessoal, o domicílio onde mora apenas uma pessoa.

Tabela 2.2: Proporção de domicílios unipessoais em alguns países, em 2011

País	Domicílios Unipessoais (%)
Suécia	47
Dinamarca	40
Noruega	40
Reino Unido	34
Japão	31
Itália	29
Estados Unidos	27
Canadá	27
Rússia	25
África do Sul	24
Brasil	10
Índia	3

Fonte: [Euromonitor \(2012\)](#)

Na Tabela 2.2 é possível perceber que as maiores taxas encontram-se em países desenvolvidos, principalmente do norte da Europa, mas [Klinenberg \(2012\)](#) afirma que o número de domicílios unipessoais está crescendo de uma forma significativa na China, no Brasil e na Índia.

Já [IBGE \(2012\)](#) apresenta resultados ligeiramente diferentes em relação ao Brasil. De acordo com a referida fonte, de 2001 à 2011, houve um crescimento de 35,6% no número de domicílios unipessoais, representando em 2011, 12,4% do total de domicílios e ela afirma ainda que desse universo de domicílios unipessoais, 42,3% era formado por um idoso.

De acordo com [Jaffe \(2013\)](#) e [Klinenberg \(2012\)](#), essa realidade se tornou possível por conta de um conjunto de fatores, como o aumento da expectativa de vida, o crescimento econômico, o aprimoramento dos sistemas de seguridade social, o processo crescente de urbanização das cidades e o desenvolvimento tecnológico.

O aumento da expectativa de vida, aliado ao desenvolvimento econômico dos últimos séculos e ao aprimoramento das leis de seguridade social tem contribuído de forma substancial para esse estilo de vida, pois as pessoas estão conseguindo viver por mais tempo, com uma situação financeira e social que as permitem se manterem sozinhas com mais qualidade de vida.

O crescente processo de urbanização das cidades tem sido também um componente importante nesse contexto, pois traz como consequência um maior distanciamento entre a moradia das pessoas, seus amigos e familiares.

E por fim, o desenvolvimento tecnológico que vem acontecendo nas últimas décadas, principalmente os avanços nos meios de transporte e nas comunicações, tem contribuído de forma significativa para esse cenário. No que diz respeito aos avanços tecnológicos, o advento da internet e dos dispositivos móveis tem desempenhado um papel fundamental, permitindo que as pessoas se comuniquem de uma forma nunca antes possível na história da humanidade, sendo possível por exemplo, que familiares que moram distantes, se comuniquem através de imagem e voz a qualquer momento e de forma instantânea.

De acordo com alguns autores da área, as razões que levam as pessoas a morarem sozinhas variam de acordo com a faixa etária. No caso dos mais jovens, eles buscam um novo estilo de vida e oportunidades de crescimento pessoal e profissional. No caso dos idosos, após criarem seus filhos e posteriormente se divorciarem ou se tornarem viúvos, decidem por morar sozinhos, de forma independente, sem a companhia de familiares.

[Nations \(2005\)](#) estimou que em 2005, 90 milhões de idosos moravam sozinhos no mundo. No Brasil, [IBGE \(2012\)](#) contabilizou em 2011, aproximadamente 3,4 milhões de idosos

morando sozinhos.

Essa tendência dos idosos em morarem sozinhos tem despertado bastante preocupação e interesse dos estudiosos da área, pois o processo natural de envelhecimento traz graduais perdas físicas, mentais, cognitivas e sociais, o que se traduz em uma maior vulnerabilidade para o idoso ([NATIONS, 2010](#)). Alguns estudos informam que os idosos que moram sozinhos estão mais propensos a solidão, depressão, além da falta de assistência em caso de desmaios, quedas ou problemas de saúde, comparados com os aqueles que moram com seus familiares.

Alguns dados ajudam a ter uma dimensão da situação. O Ministério da Saúde estima que mais de 30% dos idosos caem um vez por ano e que entre os idosos com 85 anos ou mais, mais de 50% caem a cada ano. As quedas são a 6^o causa de morte entre os idosos no Brasil.

Uma consequência ainda mais grave e que já começa a aparecer nas estatísticas, é o aumento no número de pessoas que morrem sozinhas em seus domicílios. [Guardian \(2005\)](#) afirma que em 2005, na Inglaterra, em torno de 60 pessoas morreram sozinhas em suas casas, semanalmente. [Japan \(2011\)](#) informou que em Tokyo, capital do Japão, estima-se que 10 pessoas morrem sozinhas em casa por dia e, somente no ano de 2008, morreram 2.211 idosos com 65 anos ou mais em casa sozinhos.

2.4 Síntese

Com base nas informações apresentadas nesse capítulo, é possível fazer uma breve interpretação das principais transformações ocorridas nas sociedades, e cujas implicações são relevantes para contextualizar esse trabalho.

As antigas sociedades agrárias, que viviam em fazendas e vilarejos deram lugar a sociedades contemporâneas e urbanas. A grande parte da população mundial vive hoje nos centros urbanos e em moradias cada vez menores. A família outrora numerosa, hoje costuma ser pequena. Por conta dos avanços ocorridos nos sistemas sanitários e de saúde, a expectativa média de vida quase dobrou em muitos países nos últimos séculos, e hoje, ela corresponde à aproximadamente 73 anos.

Os avanços na economia e nos sistemas de seguridade social, juntamente com o desenvolvimento tecnológico das últimas décadas tem fomentado uma tendência, inicialmente observada na segunda metade do século XX e que já representa uma característica das sociedades atuais, que é da moradia unipessoal.

Dentre os diversos impactos causados pelo aumento no número de pessoas morando sozinhas, um deles diz respeito a questão de saúde e bem-estar dessas pessoas, principalmente de pessoas idosas e que tem uma relação direta com esse trabalho. Trata-se do aumento no número de acidentes e problemas ocorridos com a pessoa sozinha, dentro do seu ambiente domiciliar.

Como conclusão, é possível perceber um cenário apropriado para o uso de novas tecnologias de suporte a qualidade de vida, que permitam monitorar e acompanhar remotamente pessoas que moram sozinhas, dentro dos seus ambientes domiciliares. Essas tecnologias almejam contribuir para o bem-estar e a segurança dessas pessoas, de forma a perceber com maior brevidade, possíveis problemas. O próximo capítulo tem as tecnologias de suporte a qualidade de vida como seu tema principal.

Tecnologias de suporte a qualidade de vida

3.1 Introdução

Uma característica marcante das sociedades contemporâneas é a incessante busca pela melhoria da qualidade de vida e as tecnologias tem desempenhado um papel fundamental nesse contexto. Portanto, este capítulo apresenta alguns dos principais conceitos relacionados com o tema e um panorama com algumas das tecnologias mais recentes de suporte a qualidade de vida. Espera-se com isso, contribuir para a percepção da importância do tema na atualidade, da diversidade de projetos e produtos existentes e também de como esse trabalho de doutorado está inserido neste cenário.

3.2 Conceitos

De acordo com [Costanza et al. \(2007\)](#), qualidade de vida é um termo genérico utilizado nas mais diversas áreas do conhecimento, como na psicologia, medicina, economia e sociologia, e que de uma forma geral, representa a percepção de satisfação ou insatisfação que indivíduos ou grupos de indivíduos tem em relação a vários aspectos da vida.

Qualidade de Vida (QV) é também uma área de estudo que objetiva compreender os fatores que influenciam a sensação de felicidade e bem-estar das pessoas, contribuindo para uma vida mais prazerosa e significativa ([TORONTO, 2014](#)).

[Atkinson e Castro \(2014\)](#) afirmam que desde o final do século XX, as tecnologias da informação têm sido o elemento mais importante no crescente processo de melhoria da qualidade de vida das pessoas e das sociedades, estando presente nas áreas de saúde, educação, segurança e meio ambiente.

Na atualidade, é encontrada na literatura uma grande variedade de termos relacionados com as tecnologias de suporte a qualidade de vida e se faz necessário conceituá-los, visando um melhor entendimento do tema em questão. Portanto, a seguir são apresentados alguns dos conceitos mais relevantes.

Tecnologia Assistiva (*Assistive Technology*) foi um termo definido pelo governo americano em 1998 e modificado em 2004 e refere-se “a qualquer item, peça de equipamento, ou produto, que pode ser adquirido comercialmente, modificado ou customizado,

e que é usado para aumentar, manter ou melhorar as capacidades funcionais de indivíduos com deficiências”. (GPAT, 2014)

Nas últimas décadas, os termos Telemedicina (*Telemedicine*) e Telessaúde (*Telehealth*) ganharam muito destaque e são muitas vezes utilizados como sinônimos, mas Darkins e Cary (2000) afirmam que a Organização Mundial da Saúde faz uma distinção entre eles.

Telessaúde é entendida como uma integração de sistemas de telecomunicação que visa promover a saúde e abrange atividades de educação para a saúde, desenvolvimento de sistemas de saúde pública, comunitária e epidemiológica, enquanto o termo **telemedicina** incorpora apenas a medicina curativa e é voltada para aspectos clínicos.

Nikus et al. (2011) corroboram com a definição de telemedicina, descrevendo como o provimento de serviços de assistência médica através do uso de tecnologias de informação e comunicação, onde há a transmissão de dados do estado de saúde do paciente com o objetivo de prevenção, diagnóstico, tratamento e acompanhamento.

O **e-Saúde** (*e-Health*) é um termo que vem sendo utilizado mais recentemente e, de acordo com McLendon (2000), refere-se a todas as formas eletrônicas de assistência a saúde que fazem uso da internet, abrangendo aspectos educacionais, comerciais e informativos, oferecidos por profissionais, não-profissionais, empresas ou os próprios pacientes. O **m-Saúde** (*m-health*) representa um sub-conjunto do e-Saúde e caracteriza-se pelo amplo uso de dispositivos móveis.

Um outro termo muito comumente encontrado na literatura é ***Independent living technologies*** ou tecnologias para vida independente e representa principalmente ao conjunto de tecnologias projetadas para permitir que pessoas com limitações e principalmente idosos, possam ter mais autonomia e independência na realização das tarefas do seu dia-a-dia.

Elderly Care Technologies representam tecnologias específicas para assistência ao idoso e de acordo com BBC (2013), podem ser divididas em dois grupos: assistência a saúde domiciliar e monitoramento de segurança domiciliar. O primeiro grupo caracteriza-se pelo uso de tecnologias que levam cuidados médicos até o domicílio do paciente, monitorando por exemplo sintomas e parâmetros fisiológicos. Já o segundo grupo engloba os dispositivos de chamada de emergência, sistemas de gerenciamento de quedas e sistemas de casa inteligente.

Em resumo, esses termos não são excludentes entre si quanto à sua abrangência, visto que há claramente uma sobreposição de atuação entre eles. No que diz respeito a esse trabalho de doutorado, como ele se propõe a monitorar e aprender o comportamento de pessoas, e principalmente idosos que moram em ambientes unipessoais, ele pode ser melhor

enquadrado na categoria das tecnologias para vida independente, e principalmente, nas tecnologias de monitoramento de segurança domiciliar para assistência a idosos.

3.3 Cenário Atual das Tecnologias de Assistência Domiciliar

O segmento de assistência à saúde domiciliar tem crescido de forma substancial nos últimos anos, caracterizando uma mudança nos padrões tradicionais de assistência à saúde, saindo dos ambientes hospitalares e migrando para os lares das pessoas. (INMEDICA, 2011)

BBC (2013) informa que o mercado global de tecnologias de assistência ao idoso movimentou em 2012 algo em torno de 2,7 bilhões de dólares e estima que alcance aproximadamente 7,2 bilhões, em 2018.

BBC (2013) e InMedica (2011) afirmam que essas tecnologias prometem reduzir drasticamente os custos com a assistência à saúde, através da percepção e do atendimento antecipados de possíveis problemas, evitando o agravamento do estado de saúde da pessoa e conseqüentemente, minimizando os altos custos de internamento.

Alguns estudos já demonstram uma relação entre o monitoramento de pacientes dentro de seu ambiente domiciliar e o número de visitas hospitalares, como em (PARE; JAANA; SICOTTE, 2007). Eles informam que em um estudo realizado com pacientes com problemas pulmonares e cardíacos, monitorados dentro de seus ambientes domiciliares, houve uma melhora consistente nos seus resultados clínicos, através de uma redução no número de visitas emergenciais, admissões hospitalares e o tempo médio de permanência nesses equipamentos.

Diversos autores afirmam que o que tem favorecido esse cenário é a convergência de interesse de grandes e diferentes indústrias, como as empresas de telessaúde, os fabricantes de dispositivos eletrônicos, as empresas de assistência médica, as companhias de telecomunicação, provedores de internet, dentre outras.

InMedica (2011) ainda afirma que esse cenário só é possível por conta do avanço tecnológico dos últimos tempos, que tem permitido uma crescente oferta de novos produtos e serviços de suporte a qualidade de vida.

3.4 Pesquisas e Produtos de monitoramento domiciliar

Uma grande variedade de projetos e produtos tem sido desenvolvida nessa área, variando desde botões de acionamento em caso de quedas, passando por sistemas de monitoramento de parâmetros fisiológicos do paciente, até sofisticados sistemas de aprendizado de comportamento, utilizando robôs. A seguir são apresentados alguns exemplos de pesquisas, patentes e produtos relacionados com o tema.

O estado atual da técnica contempla algumas patentes relacionadas com o tema, como por exemplo, a Patente de número de inscrição PI 9403843-0, intitulada “*Sistema de Monitoração Remota de Recém Nascidos, Crianças, Idosos e Convalescentes de qualquer idade e aparelhos componentes do mesmo*” e a Patente de número de publicação CN 102737474 A, intitulada “*Monitoring and alarming for abnormal behavior of indoor personnel based on intelligent video*”.

A primeira foi depositada no Brasil e consiste em um sistema composto por cinco sensores que monitoram condições fisiológicas de uma pessoa: temperatura corporal, atividade motora, choro, enurese e atividade cardíaca. Cada sensor possui um micro transmissor alimentado por uma micro-bateria que permite o envio de sinais de rádio frequência para um rádio receptor, que analisa as transmissões recebidas pelos sensores e dentro de parâmetros pré-estabelecidos pelo usuário, retransmite para um “bip”, que é usado pelo usuário.

A segunda foi depositada na China e refere-se a um sistema de monitoramento de pessoas para ambientes internos, baseado em vídeo. Seu funcionamento se dá da seguinte maneira: as áreas do ambiente são monitoradas através de câmeras de vídeo que analisam imagens corporais das pessoas e identificam posturas do tipo: “em pé”, “sentado”, “caído”, dentre outros. Caso o resultado da análise informe que a pessoa está caída, então uma mensagem de alerta é enviada para dispositivos eletrônicos de membros da família.

Na atualidade, também são encontrados alguns projetos de monitoramento de idosos em ambientes domiciliares, que fazem uso de robôs e/ou câmeras de vídeo para realizar o acompanhamento das atividades, como é o caso dos projetos apresentados por [Cesta et al. \(2011\)](#) e [Seki e Susumu \(2010\)](#)

O trabalho apresentado por [Cesta et al. \(2011\)](#) foi desenvolvido na Itália e tem com objetivo fornecer uma ferramenta de inteligência artificial capaz de assistir pessoas idosas em suas casas através da utilização de câmeras, robôs e sensores integrados. Com base em um agendamento de atividades pré-estabelecidas pelos cuidadores e/ou familiares dos idosos, como por exemplo, almoçar das 12:00 às 13:00 horas ou tomar determinados remédios após o café da manhã, o sistema interage com o idoso e envia mensagens de

alerta quando algum evento não esperado ocorre.

Já o trabalho apresentado por [Seki e Susumu \(2010\)](#) foi desenvolvido no Japão e fornece uma solução de reconhecimento de padrões de comportamento que utiliza um sensor de visão onidirecional, colocado no centro de um ambiente, como um quarto, uma sala e que capta imagens da pessoa monitorada. As imagens capturadas por esse aparelho são armazenadas e algumas das suas características são posteriormente utilizadas por um algoritmo de rede bayesiana, que tem como objetivo identificar comportamentos diferentes dos usuais, como por exemplo, a captura de uma sequência de imagens que não faz parte dos registros de padrões, ou uma sequência de imagens que consta nos registros, mas seu tempo ou horário de duração são diferentes do rotineiro.

Outros projetos utilizam biosensores ou sensores acoplados ao corpo da pessoa monitorada, com o propósito de avaliar as condições de saúde, como é o caso dos projetos apresentados por [Carvalho, Copetti e Filho \(2012\)](#) e [Bottrel \(2011\)](#).

O primeiro foi desenvolvido por pesquisadores da Universidade Federal Fluminense e tem como objetivo criar uma solução de monitoramento de idosos, utilizando sensores que captam dados fisiológicos e das atividades praticadas pelo idoso. O projeto utiliza um aparelho ajustado ao pulso do paciente para obter dados da pressão arterial e frequência cardíaca e utiliza também um acelerômetro para identificar atividades praticadas pelo idoso (em repouso, caminhando, dormindo, etc). Esses dados são enviados remotamente para um software que utiliza algoritmos de lógica *fuzzy* para determinar a situação de saúde do paciente, como: normal, alerta ou emergência.

O segundo foi desenvolvido por pesquisadores da Universidade Federal de Minas Gerais e objetiva a criação de um chip sensor, que pode ser conectado a diversos dispositivos que medem a temperatura, batimento cardíaco e nível de oxigenação do sangue. Após coletados esses dados, o chip os envia para uma base central e posteriormente para a internet. De acordo com os pesquisadores, se o chip estiver junto ao corpo do idoso e ele sofrer uma queda, o chip pode detectar a queda e transmitir para a base.

Além dos trabalhos acima citados, [Missouri \(2012\)](#) ainda informa sobre duas pesquisas de doutorado que vêm sendo desenvolvidas na Universidade de Missouri, nos Estados Unidos, uma utilizando dispositivos de jogos e outra, radar com doppler, com o propósito de reconhecer mudanças nos movimentos de idosos, com riscos de queda.

Ainda no processo de pesquisa de anterioridade, foi encontrado um sistema que busca aprender o comportamento de uma pessoa em um ambiente domiciliar, utilizando a mineração de dados, mas tendo como objetivo, tão somente a identificação de sequências frequentes de atividades realizadas pela pessoa. Intitulado de *Learning Models of Humam*

Behaviour with Sequential Patterns, ele foi desenvolvido por *Automated Reasoning Group* e apresentado por [Guralnik e Haigh \(2002\)](#).

No trabalho supracitado foi utilizado um conjunto de sensores de ambiente, como sensores de abertura e fechamento de portas, de movimentação, de acionamento de equipamentos, dentre outros, instalados em um ambiente domiciliar, com o propósito de capturar seqüências de atividades diárias realizadas pelo seu morador.

Os dados capturados pelos sensores são armazenados em ordem cronológica e posteriormente são avaliados por um algoritmo de Padrões Sequenciais, com o objetivo de identificar seqüências de eventos que ocorrem com maior frequência em determinados períodos do dia, como por exemplo, uma seqüência, que informa que o sensor do banheiro é acionado em 75% da vezes que o sensor do quarto é acionado, entre 07:00 e 08:00 horas da manhã.

3.5 Síntese

O capítulo em questão apresentou a importância das tecnologias de suporte à qualidade de vida na atualidade, apresentando alguns projetos que estão sumarizados na Tabela 3.1.

É possível categorizar os projetos supracitados em dois tipos: o primeiro, abrange o conjunto de soluções que tem como objetivo monitorar uma pessoa, sem necessariamente aprender o seu comportamento rotineiro, como é o caso dos botões de emergência, botões de pânico e alguns sistemas que utilizam câmeras de vídeo, biosensores e sensores acoplados ao corpo.

A outra categoria compreende soluções que monitoram o dia-a-dia de uma pessoa dentro da sua residência, extraindo informações que são interpretadas por sistemas de reconhecimento de padrões, possibilitando o aprendizado rotineiro da pessoa. Muitas dessas soluções utilizam de alguma forma, uma combinação de sensores de ambiente, câmeras de vídeo e até mesmo robôs, para capturar as informações.

Três aspectos relevantes, porém, devem ser ressaltados no que tange a implementação de sistemas dessa natureza: a privacidade e o conforto da pessoa monitorada e o custo do produto.

Com o surgimento da Telessaúde, a questão da privacidade do paciente monitorado tem sido abordada em diversas pesquisas. [Cavoukian et al. \(2010\)](#), por exemplo, questionam a segurança no envio de informações da saúde do paciente, como glicemia, pressão, temperatura corporal e outros, de forma remota. Uma outra dimensão envolvendo a questão da privacidade, diz respeito ao uso de soluções que utilizam câmeras de vídeo ou similares,

pois elas capturam imagens da pessoa na sua intimidade, podendo gerar um incômodo para a pessoa monitorada.

A questão do conforto diz respeito ao uso de sensores acoplados ao corpo da pessoa monitorada, como botões de emergência, braceletes e chips acoplados à roupa. A eficácia desses produtos exige que eles estejam o maior tempo possível acoplado ao corpo da pessoa monitorada e muitas delas se sentem incomodadas e até mesmo estressadas em usá-los.

O último aspecto está relacionado com custo das soluções, pois quanto mais complexa a tecnologia, maior tende a ser o custo do projeto, principalmente no caso de sistemas que utilizam robôs. Vale ressaltar que o principal objetivo de todas essas tecnologias é a promoção da saúde da pessoa monitorada, então justifica-se uma constante busca por soluções que apresentem custos mais baixos.

Por fim, é possível perceber que ainda há muitas possibilidades de desenvolvimento de pesquisas nessa área, como por exemplo, a criação de um modelo computacional capaz de aprender o comportamento de pessoas que moram em ambientes unipessoais, baseado apenas em dados capturados por sensores de ambiente não intrusivos, de fácil instalação e baixo custo, que é a proposta desta pesquisa doutoral.

Por conseguinte, o próximo capítulo apresenta fundamentos teóricos relacionados com a área de reconhecimento de padrões e sensores.

Tabela 3.1: Resumo de Projetos de Tecnologia de Suporte a Qualidade de vida

Tecnologia	Local	Tipo dos Sensores	Fonte
Sensores que coletam parâmetros fisiológicos de uma pessoa e os transmitem remotamente para um software, que analisa os dados e emite um alerta em situações pré-estabelecidas	Brasil	Biosensores	(VIEIRA, 1994)
Analisa imagens corporais de pessoas em uma residência e emite um alerta quando percebe que a pessoa está caída	China	Câmeras de vídeo	(PATENT, 2012)
Conjunto integrado de equipamentos que monitoram um idoso na sua residência, com base em atividades pré-agendadas e é emitido um alerta quando ocorrer algo fora do agendado	Itália	Câmeras de Vídeo, Robô e sensores de ambiente	(CESTA et al., 2011)
Através de sequências de imagens de uma pessoa em um domicílio unipessoal, é emitido um alerta quando são percebidas sequências de imagens fora dos padrões	Japão	Câmeras de Vídeo	(SEKI; SUSUMU, 2010)
Classifica a situação do idoso em Normal, Alerta ou emergência com base em dados fisiológicos capturados remotamente	UFF Brasil	Biosensores	(CARVALHO; COPETTI; FILHO, 2012)
Chip sensor que conecta-se a dispositivos que capturam dados fisiológicos de uma pessoa, e os transmite para um servidor remotamente	UFMG Brasil	Biosensores	(BOTTREL, 2011)
Identifica sequências frequentes de atividades realizadas por uma pessoa em um ambiente domiciliar	Estados unidos	Sensores de ambiente	(GURALNIK; HAIGH, 2002)

Fonte: Autor

Fundamentação Teórica

4.1 Introdução

Este capítulo apresenta os fundamentos teóricos que norteiam esse trabalho e estão organizados da seguinte forma: inicialmente são apresentados conceitos e características da área de reconhecimento de padrões e em seguida são detalhados os métodos utilizados neste projeto, como estimação de função densidade, mineração de padrões sequenciais e detecção de *outliers*. Posteriormente, são apresentados os tipos de sensores utilizados no projeto: o sensor de movimentação e o sensor de temperatura ambiente.

4.2 Reconhecimento de Padrões

Os seres humanos possuem uma grande habilidade em reconhecer e distinguir objetos no dia-a-dia. Desde a mais tenra idade, a maioria das crianças já consegue diferenciar objetos, sons, sensações e categorizá-los. Apesar dessa capacidade inata do ser humano, ainda não é totalmente compreendido como esse processo funciona.

Conseqüentemente, “ensinar” uma máquina a reconhecer padrões é uma tarefa muito difícil. Desde os primórdios da computação, tem sido um grande desafio para os pesquisadores, a criação de algoritmos que simulem a habilidade humana em descrever e classificar objetos (JAIN; DUIN, 2004) (Sá, 2001).

Jain e Duin (2004) definem Reconhecimento de Padrões como a ciência da observação do ambiente, que permite aprender a distinguir padrões de interesse e tomar decisões sobre eles. Já Sá (2001) define como uma disciplina que lida com métodos de descrição e classificação de objetos. Por fim, Tohka (2006) define como a tarefa de colocar objetos em classes corretamente com base nas características desses objetos.

De acordo com Webb (2002), a área de Reconhecimento de Padrões surgiu na década de 60, porém foi nas últimas décadas, com o avanço dos recursos computacionais e o surgimento de novas aplicações, que houve um avanço significativo e hoje é uma área de intensas pesquisas. Sá (2001) e Pal e Pal (2001) corroboram, afirmando que essa é uma área fértil para o desenvolvimento de pesquisas, graças também a interação com outras áreas, como a ciência da computação, física, neurobiologia, estatística, engenharia, dentre outras.

Sá (2001) ainda afirma que os sistemas de Reconhecimento de Padrões são utilizados nas mais diversas áreas, como na agricultura, saúde, comércio, segurança, dentre outros e que esse amplo espectro de aplicabilidade justifica-se pela capacidade em reconhecer objetos de vários formatos, como sinais (*ex: reconhecimento de voz, sinais de eletrocardiograma*), imagens (*ex: reconhecimento de digitais, caracteres, exames médicos*) e também tabelas de valores (*ex: classificação de clientes, identificação de spams*).

Nesse contexto, se faz necessário definir três conceitos fundamentais: *Classe*, *Padrão* e *Característica*. As *classes* podem ser definidas como categorias de objetos associados a um conceito ou protótipo; os *padrões* são representações físicas dos objetos e também são chamados de instâncias ou exemplos e as *características* são os atributos ou medidas que caracterizam esses objetos.

Sá (2001) apresenta um exemplo ilustrativo que classifica os pacientes de acordo com a sua situação cardiológica. Neste cenário, as *classes* representam as possíveis categorias em que o paciente pode se enquadrar: normal, hipertrofia ventricular esquerda, hipertrofia ventricular direita e infarto do miocárdio. Os *padrões* são representados pelos sinais eletrocardiográficos (*ECGs*) dos pacientes e as *características* são informações que definem os sinais *ECGs*, como por exemplo, a amplitude e a duração das ondas.

A estrutura básica de um sistema de reconhecimento de padrões compreende as seguintes etapas, podendo variar de acordo com a aplicação (Sá, 2001) (TOHKA, 2006) (WEBB, 2002) e pode ser vista na Figura 4.1. Vale a pena ressaltar que apesar das etapas serem apresentadas de forma sequencial, pode haver retroalimentação entre elas.




Figura 4.1: Etapas do Processo de Reconhecimento de Padrões. Fonte: Adaptado de Sá (2001)

- **Aquisição dos Padrões**, também chamada de captação de dados ou sensoriamento, tem como objetivo a observação e captação dos objetos do ambiente que se deseja categorizar;
- **Extração de medidas ou características** objetiva extrair as medidas (atributos) que melhor caracterizam a estrutura dos objetos para uma determinada aplicação, geralmente reduzindo sua dimensionalidade, retirando informações redundantes e irrelevantes. O resultado dessa etapa costuma ser chamado por alguns autores de Vetor de Características (*feature vector*);
- **Pré-Processamento** compreende um conjunto de operações executadas sobre os dados com o propósito de adequá-los aos algoritmos que serão utilizados ao longo

processo, como por exemplo: discretização, tratamento de valores nulos e *outliers*, segmentação, dentre outros;

- **Algoritmo**, etapa onde são executados os algoritmos de reconhecimento, sejam eles de classificação, regressão, agrupamento, associação ou outros.
- **Pós-Processamento** realiza a análise dos resultados encontrados, sucedido geralmente pela realização de alguma ação.

A qualidade dos resultados encontrados depende de vários fatores, como a adequação entre as características e algoritmos utilizados e a natureza da aplicação. [Tohka \(2006\)](#) afirma que esse é um processo iterativo, pois caso os resultados não sejam satisfatórios, é possível retornar a alguma etapa e ajustar os dados, recalibrar os parâmetros, mudar os algoritmos, dentre outras atividades. O processo pode ser repetido até que os resultados se apresentem satisfatórios.

Os autores costumam classificar os métodos de reconhecimento de padrões através de duas abordagens. A primeira delas diz respeito à forma de aprendizado do algoritmo, que pode ser **Supervisionado** ou **Não-Supervisionado**.

O **Supervisionado**, também chamado de *Orientado a Conceito*, ocorre quando há uma base de dados de aprendizado e nela há um atributo que informa previamente a categoria correta de cada objeto, auxiliando o processo de criação do *Classificador*. Posteriormente, este é utilizado para categorizar outros objetos em novas bases de dados. É possível citar como exemplos dessa abordagem, os algoritmos de árvore de classificação e regressão e alguns algoritmos de redes neurais.

Já no aprendizado **Não-Supervisionado**, também conhecido com *Orientado a Dados*, não há nenhum atributo que informe previamente a correta categorização dos objetos e esse conhecimento se dá tão somente no momento da execução do algoritmo, e é possível citar como exemplos dessa abordagem, os algoritmos de agrupamento e associação.

A outra abordagem classifica os algoritmos em dois tipos: os **Paramétricos** e os **Não-Paramétricos**. O primeiro grupo representa os algoritmos onde há uma presunção de um conhecimento prévio do modelo de distribuição dos dados. Já no segundo, esse conhecimento prévio não existe e a função é modelada de acordo com os próprios dados. ([WAND; JONES, 1995](#))

Dentre os diversos métodos de reconhecimento de padrões existentes, três deles destacam-se neste trabalho e estão detalhados a seguir: Estimador de Função Densidade, Mineração de Padrões Sequenciais e Detecção de *Outliers*.

4.2.1 Estimador de Função Densidade

De acordo com [Wand e Jones \(1995\)](#), um dos problemas clássicos da estatística diz respeito à estimação da função densidade de probabilidade de amostras aleatórias, através do uso de métodos paramétricos e não-paramétricos. Os autores destacam a importância desses métodos, principalmente dos não-paramétricos, como ferramentas analíticas eficazes para a compreensão das estruturas dos dados observados e também do mecanismo, de onde os dados foram gerados.

Diversos métodos foram propostos e são largamente utilizados em diversas áreas do conhecimento. Dentre eles, é possível citar a máxima verossimilhança de uma função gaussiana (*maximum-likelihood estimation*), que é um método paramétrico, e os não-paramétricos, como o histograma, o estimador Kernel e os métodos do vizinho mais próximo (*k-nearest neighbor*).

O estimador kernel foi o método escolhido para ser usado neste trabalho porque, de acordo com diversos autores, apresenta uma característica importante para a compreensão dos resultados, que é a suavidade da curva gerada, característica esta que o histograma não apresenta.

4.2.1.1 Estimador Kernel

O Estimador de Densidade kernel, também conhecido como o método da janela de Parzen-Rosenblatt, que teve sua origem a partir das publicações de [Rosenblatt \(1956\)](#) e [Parzen \(1962\)](#), consiste em um método não-paramétrico de estimação de densidade, que tem como principal característica a capacidade de estimar a densidade de cada ponto, com base na observação dos seus vizinhos.

A seguir, apresenta-se a fórmula do estimador de densidade kernel:

$$f_h(x) = \frac{1}{(nh)} \sum_{i=1}^n K\left(\frac{x - X_i}{h}\right) \quad (4.1)$$

onde X_i representa um conjunto finito de variáveis aleatórias, n , a quantidade de variáveis, K , uma função kernel que satisfaz $\int_{-\infty}^{+\infty} K(t)dt = 1$ e h , chamado de largura de banda, é um parâmetro de suavização da curva.

A Figura 4.2 apresenta um exemplo ilustrativo da construção de um função densidade. É

possível perceber que para cada x , $f(x)$ é calculada com base no somatório das funções kernel presentes no ponto, e que podem ser vistas na parte inferior da imagem. Dessa forma percebe-se que cada ponto possui o mesmo peso relativo para a construção da curva.




Figura 4.2: Influência de cada observação na construção de Função Densidade. Fonte: [Lucambio \(2008\)](#)

Na Tabela 4.1 e na Figura 4.3 é possível visualizar as funções kernel mais utilizadas e a representação dos seus formatos, respectivamente.

Tabela 4.1: Funções Kernel mais conhecidas

Nome da Função	Fórmula
Uniforme	$\frac{1}{2}$ para $ x \leq 1$
Triangular	$1 - x $ para $ x \leq 1$
Exponencial	$\frac{1}{\sqrt{2\pi}} \exp(-\frac{1}{2}x^2)$
Epanechnikov	$\frac{3}{4}(1 - x^2)$ para $ x \leq 1$
Quartic	$\frac{15}{16}(1 - x^2)^2$ para $ x \leq 1$
triweight	$\frac{35}{32}(1 - x^2)^3$ para $ x \leq 1$

Fonte: Autor

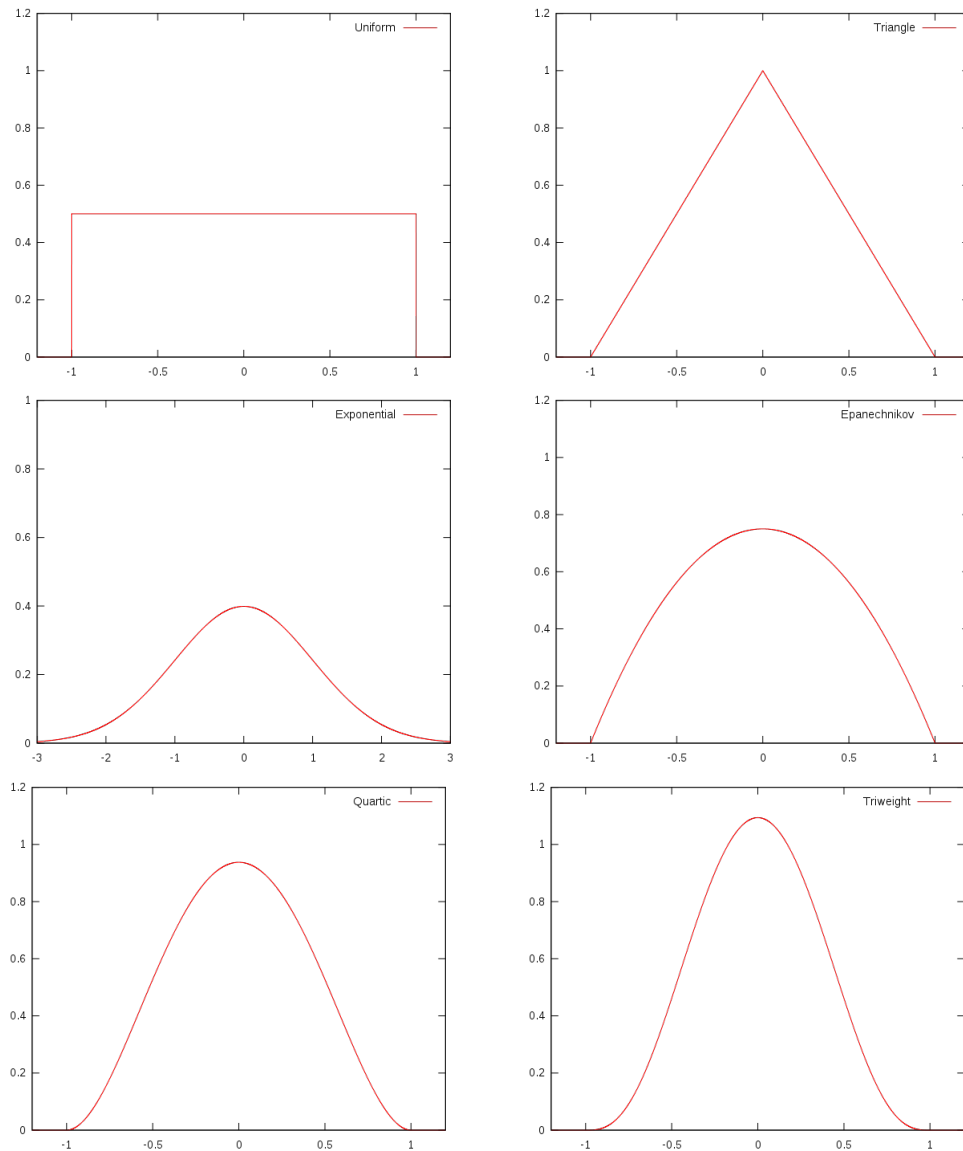


Figura 4.3: Formato das Funções Kernel mais conhecidas. Da esquerda para a direita e de cima para baixo: uniforme, triangular, exponencial (ou gaussiana), epanechnikov, quartic (ou biweight) e triweight. Fonte: [Lucambio \(2008\)](#)

Supondo um cenário composto por 10 variáveis, sendo $X = \{4, 5, 5, 6, 12, 14, 15, 15, 16, 17\}$, $h = 2$ e K , uma função gaussiana, a função densidade em um ponto aleatório, $x = 10$, é calculada da seguinte forma:

$$f_2(10) = \frac{1}{(10 \times 2)} \left[K\left(\frac{10-4}{2}\right) + K\left(\frac{10-5}{2}\right) + \dots + K\left(\frac{10-17}{2}\right) \right] = 0,0214 \quad (4.2)$$

A função densidade completa deste exemplo pode ser vista na Figura 4.4.




Figura 4.4: Exemplo ilustrativo de uma Função Densidade. Fonte: Autor

De acordo com diversos autores e inclusive [Wand e Jones \(1995\)](#), a escolha da função Kernel (K) não é um fator crítico. Contudo, a escolha da largura de banda h é um fator determinante para uma representação adequada dos dados. Na Figura 4.5 é possível observar um exemplo ilustrativo com duas funções densidade para um mesmo conjunto de dados, sendo que a única diferença é o tamanho da largura de banda.

Percebe-se claramente diferenças significativas entre as duas funções. Na primeira função, ocorre o que os autores costumam chamar de *undersmooth*, onde surgem muitas caudas em decorrência de ruídos nos dados, causados pela utilização de uma pequena largura de banda. Na segunda função ocorre o inverso, o que os autores definem como *oversmooth*. Neste cenário, há uma suavização muito forte da curva causada pela escolha de uma largura de banda grande, o que acaba ocasionando uma perda da capacidade de interpretação dos dados.




Figura 4.5: Exemplos de duas funções densidade para um mesmo conjunto de dados, alterando apenas a largura de banda. A primeira possui $h = 0,2$ e a segunda, $h = 4$. Fonte: Autor

Portanto, [Zambom e Dias \(2012\)](#) afirmam que para evitar esse tipo de problema, diversos métodos de escolha da largura de banda h foram propostos, como os métodos *plug-in*, os métodos clássicos e os métodos de largura de banda variável. Este último grupo caracteriza-se por não apresentar uma largura de banda fixa, mas uma largura de banda que varia de acordo com o local da estimativa da função.

4.2.2 Mineração de Padrões Sequenciais

4.2.2.1 Introdução

A mineração de padrões sequenciais é uma área importante da mineração de dados e teve sua origem a partir da publicação de [Agrawal e Srikant \(1995\)](#). De acordo com os autores, o problema surgiu em decorrência de um grande desafio que as grandes empresas de varejo estavam enfrentando à época, principalmente depois do advento da tecnologia de código de barra, que era: como identificar, de forma automatizada, padrões frequentes de compras dos clientes em grandes volumes de dados?

De acordo com [Zaki \(2001\)](#), a mineração de padrões sequenciais lida com a descoberta de um conjunto de eventos que ocorre em sequência, com uma certa frequência mínima. [Pei et al. \(2001\)](#) definem como a área que lida com a descoberta de padrões de subsequências que ocorrem em uma base de dados de sequências.

A mineração de padrões sequenciais é utilizada neste trabalho com o propósito de tentar identificar as movimentações mais frequentes realizadas pela pessoa, por entre os cômodos e móveis da casa. Espera-se compreender a relação temporal existente entre algumas atividades que a pessoa costuma realizar no seu ambiente domiciliar.

4.2.2.2 Definição Formal do Problema

[Zaki \(2001\)](#) e [Agrawal e Srikant \(1995\)](#) afirmam que o problema da mineração de padrões sequenciais pode ser definido da seguinte forma: Seja $I = i_1, i_2, \dots, i_m$ um conjunto de m diferentes itens. Um *evento* representa uma coleção não ordenada composta por k itens $(i_1 i_2 \dots i_k)$ e uma *sequência*, representada por α , corresponde a uma lista ordenada de eventos como $(\alpha_1 \rightarrow \alpha_2 \rightarrow \dots \rightarrow \alpha_q)$. Uma sequência composta por k itens é chamada de sequência de tamanho k , como por exemplo, $(B \rightarrow AC)$.

Diz-se que uma sequência $\alpha = (\alpha_1 \rightarrow \alpha_2 \rightarrow \dots \rightarrow \alpha_q)$ é uma subsequência de uma outra sequência $\beta = (\beta_1 \rightarrow \beta_2 \rightarrow \dots \rightarrow \beta_q)$, se houver inteiros $i_1 < i_2 < \dots < i_n$, tal que $\alpha_1 \subseteq \beta_{i_1}, \alpha_2 \subseteq \beta_{i_2}, \dots, \alpha_n \subseteq \beta_{i_n}$. A título ilustrativo, a sequência $(B \rightarrow AC)$ é uma subsequência de $(AB \rightarrow E \rightarrow ACD)$, já que $B \subseteq AB$ e $AC \subseteq ACD$.

Os algoritmos de padrões sequenciais geralmente buscam identificar sequências que ocorrem com uma frequência mínima na base de dados. Por isso, suporte (*sup*) ou frequência, são termos utilizados para representar o número de registros na base que contém uma determinada sequência α . Suporte mínimo (*min-sup*) representa a quantidade mínima de

registros na base de dados que uma sequência deve ter para ser considerada frequente. Uma sequência é dita máxima se ela não for uma subsequência de uma outra sequência.

Diversos algoritmos foram implementados para identificar sequências frequentes, como o AprioriAll, AprioriSome, GSP e SPADE (*Sequential PAttern Discovery using Equivalence Classes*). Este último foi apresentado por [Zaki \(2001\)](#) e foi escolhido para ser utilizado neste trabalho, principalmente pelo fato de ser o único dentre os algoritmos citados, a ter sua implementação no software R-Project.

4.2.2.3 Algoritmo SPADE

A base de dados utilizada pelo algoritmo SPADE é composta por n transações, contendo a seguinte estrutura: um identificador único de uma transação (SID), também chamado de ID do Cliente em [Agrawal e Srikant \(1995\)](#), o momento de realização de um evento e o conjunto de itens (*itemset*) do evento, ordenados lexicograficamente. Vale a pena ressaltar que o momento de realização de um evento não pode se repetir para uma mesma transação e por isso, esse momento pode ser considerado com um identificador único do evento na transação (EID).

Na Tabela 4.2 é possível visualizar um exemplo de uma base de dados de transação, extraída de [Zaki \(2001\)](#). Nela, pode-se perceber oito itens variando sua representação de A a H, distribuídos em quatro transações e dez eventos.

Tabela 4.2: Base de Dados de Transação

ID da transação (SID)	Momento do Evento (EID)	Itens
1	10	C D
1	15	A B C
1	20	A B F
1	25	A C D F
2	15	A B F
2	20	E
3	10	A B F
4	10	D G H
4	20	B F
4	25	A G H

Fonte: [Zaki \(2001\)](#)

O primeiro passo do algoritmo é transformar a estrutura da tabela original em um conjunto de listas individuais para cada item presente na base de dados, como pode ser visto na Figura 4.6. É possível observar que os registros das listas estão ordenados pelos atributos: identificador da transação (SID) e do identificador do evento (EID).

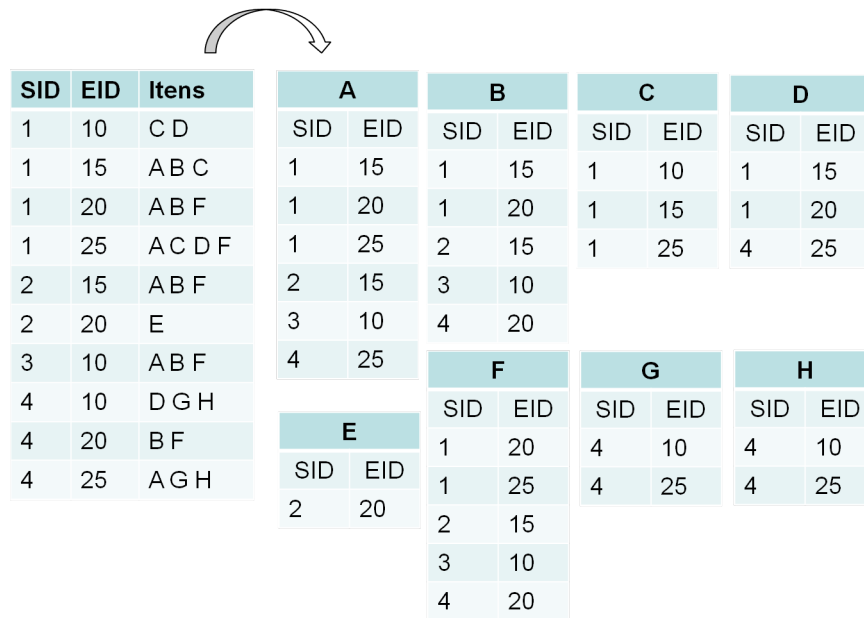


Figura 4.6: Listas contendo os registros de cada item. Fonte: Adaptado de Zaki (2001)

O próximo passo do algoritmo é identificar as seqüências frequentes de tamanho 1, isto é, as seqüências compostas por apenas 1 item. Para realizar essa tarefa, o algoritmo percorre para cada lista, todas as suas entradas e para cada novo SID encontrado, ele incrementa o contador de 1. Ao término da varredura de cada lista, ele calcula o suporte e se este for maior que o suporte mínimo (min_sup), o item é considerado frequente. A saber, o suporte representa a razão entre a quantidade de SID distintos na lista e a quantidade de SID distintos em toda a base de dados.

No exemplo ilustrativo, supondo que seja definido um suporte mínimo de 50%, as seqüências de tamanho 1 consideradas frequentes são: A, B, D e F e os seus respectivos valores de suporte são: 100%, 100%, 50% e 100%. Os outros itens são eliminados do processo. Na Figura 4.7 é possível visualizar o resultado dessa etapa.

A (100%)		B (100%)		D (50%)		F (100%)	
SID	EID	SID	EID	SID	EID	SID	EID
1	15	1	15	1	15	1	20
1	20	1	20	1	20	1	25
1	25	2	15	4	25	2	15
2	15	3	10			3	10
3	10	4	20			4	20
4	25						

Figura 4.7: Listas contendo as sequências frequentes de 1 item. Fonte: Adaptado de [Zaki \(2001\)](#)

A próxima etapa tem como objetivo identificar as sequências frequentes de tamanho 2, isto é, as sequências compostas por 2 itens. Porém, antes vale ressaltar que a combinação de duas sequências de tamanho 1 pode formar 3 sequências de tamanho 2. Por exemplo, as possíveis sequências de tamanho 2 formadas a partir dos itens X e Y , podem ser:

1. $X \rightarrow Y$, significa que Y ocorre em um momento posterior a X ;
2. $Y \rightarrow X$, significa que X ocorre em um momento posterior a Y ;
3. XY , significa que X e Y ocorrem no mesmo momento. Vale salientar que não há YX , pois os itens ocorrem no mesmo momento e estão ordenados lexicograficamente.

O processo de identificação das sequências de tamanho 2 ocorre em duas etapas. Na primeira, o SPADE transforma as listas verticalizadas dos itens considerados frequentes, em uma nova base horizontal composta pelo campo *SID* e um conjunto de pares (Item, EID), como pode ser visto na Figura 4.8. De acordo com autor, este procedimento é feito por questões de otimização, procurando reduzir o número de varreduras na base de dados.

SID	(Item, EID)
1	(A 15) (A 20) (A 25) (B 15) (B 20) (D 10) (D 25) (F 20) (F 25)
2	(A 15) (B 15) (F 15)
3	(A 10) (B 10) (F 10)
4	(A 25) (B 20) (D 10) (F 20)

Figura 4.8: Lista contendo os pares (Item, EID) para cada SID. Fonte: Adaptado de [Zaki \(2001\)](#)

Na segunda etapa, o algoritmo faz uma varredura em cada sequência, procurando por combinações temporais entre os seus pares (Item, EID). Para cada combinação válida encontrada, um contador é incrementado de 1.

Para encontrar sequências do tipo $X \rightarrow Y$ e $Y \rightarrow X$, o algoritmo procura pelos pares (Item, EID) de uma sequência que ocorrem em momentos diferentes. Por exemplo, a identificação dos pares (A 15) e (F 20) da sequência (SID = 1), informa que no momento 15, o item A ocorreu e posteriormente, no momento 20, o item F ocorreu, gerando assim a sequência $A \rightarrow F$.

Para encontrar as sequências do tipo XY , o algoritmo procura pelos pares (Item, EID) de uma sequência que ocorrem no mesmo momento. Por exemplo, os pares (A 15) (B 15) da sequência (SID = 1) informam que os itens A e B ocorreram no mesmo momento 15, gerando assim a sequência AB .

Ao final da varredura, o algoritmo calcula o valor do suporte (*sup*) de cada sequência encontrada e serão consideradas frequentes aquelas que possuem suporte maior ou igual ao suporte mínimo (*sup_min*) definido. No exemplo, as sequências de tamanho 2 consideradas frequentes podem ser vistas na Figura 4.9, juntamente com seus respectivos valores de suporte.

Sequência	Suporte (%)
AB	75
AF	75
BF	100
B→A	50
D→A	50
D→B	50
D→F	50
F→A	50

Figura 4.9: Listas contendo as sequências frequentes com 2 itens. Fonte: Adaptado de [Zaki \(2001\)](#)

Para identificar as sequências de tamanho maior ou igual a 3, o algoritmo utiliza o conceito de equivalência entre classes. De acordo com o autor, duas sequências de tamanho k possuem equivalência entre classes, caso elas possuam um mesmo prefixo $[P_{k-1}]$. No caso especial das sequências de tamanho 1, todas elas pertencem a uma mesma classe, com prefixo nulo.

Na Figura 4.10, é possível visualizar as sequências equivalentes do exemplo.

Prefixo da Classe	Sequências
A	AB, AF
B	BF, B → A
D	D → A, D → B, D → F
F	F → A

Figura 4.10: Equivalência entre Sequências com tamanho 2. Fonte: Adaptado de Zaki (2001)

Uma vez identificadas as sequências equivalentes, estas são combinadas entre si, formando sequências de tamanho $K + 1$. A junção de duas sequências de tamanho K , pode formar as seguintes sequências de tamanho $K + 1$:

- Evento com Evento : A junção de XY com XZ só pode formar a sequência XYZ ;
- Evento com Sequência: A junção de XY com $X \rightarrow Z$ só pode formar a sequência $XY \rightarrow Z$;
- Sequência com Sequência: A junção de $X \rightarrow Y$ com $X \rightarrow Z$ pode resultar em três possíveis sequências: $X \rightarrow YZ$, $X \rightarrow Y \rightarrow Z$, $X \rightarrow Z \rightarrow Y$. Há um caso especial, que é a combinação de uma sequência $X \rightarrow Y$ com ela mesma. O único resultado possível é $X \rightarrow Y \rightarrow Y$

A Figura 4.11 apresenta algumas sequências resultantes de tamanho 3 e seus valores de suporte. É possível observar que apenas as sequências ABF , $BF \rightarrow A$, $D \rightarrow B \rightarrow A$, $D \rightarrow F \rightarrow A$ e $D \rightarrow BF$ são consideradas frequentes, pois possuem suporte maior ou igual a 50

Sequência	Suporte (%)
ABF	75
BF→A	50
D→AB	25
D→A→B	25
....	...

Figura 4.11: Lista contendo algumas sequências de tamanho 3. Fonte: Adaptado de Zaki (2001)

Pode-se observar também que das cinco sequências consideradas frequentes, é possível combinar apenas duas delas, as sequências $D \rightarrow B \rightarrow A$ e $D \rightarrow BF$, já que são as únicas que apresentam equivalência entre classes, possuindo o mesmo prefixo, $D \rightarrow B$. A junção

entre essas duas sequências forma a sequência máxima de tamanho 4, $D \rightarrow BF \rightarrow A$, que possui suporte igual a 50%.

O algoritmo então termina já que não há mais sequências possíveis de serem identificadas.

4.2.3 Detecção de Outliers

4.2.3.1 Introdução

Também conhecida como Detecção de Anomalias ou Detecção de Ruídos, essa é uma área do conhecimento que abrange um conjunto de técnicas que permite identificar elementos considerados fora de padrões previamente estabelecidos.

Apesar de não haver uma definição matemática rígida sobre o conceito de *outlier*, [Grubbs \(1969\)](#) o define como um elemento que parece se desviar claramente dos outros elementos da amostra da qual ele faz parte. Já Lewis e Barnett (1994) apud ([MAIMON; ROKACH; BEN-GAL, 2005](#)) definem como uma observação que parece ser inconsistente com o restante do conjunto dos dados e [Chandola, Banerjee e Kumar \(2009\)](#) definem como um comportamento que não está em conformidade com o esperado.

De acordo com [Chandola, Banerjee e Kumar \(2009\)](#), os estudos sobre anomalias nos dados teve sua origem no final do século XIX e diversos algoritmos foram desenvolvidos para uso nas mais diversas áreas, principalmente em áreas que envolvem segurança, como na detecção de fraudes no uso de cartões de crédito e na identificação de intrusos em redes de computadores, mas também é usado na identificação de objetos considerados anômalos em imagens, dentre outros. ([MAIMON; ROKACH; BEN-GAL, 2005](#)) ([HODGE; J., 2004](#))

A Figura 4.12 apresenta um exemplo ilustrativo extraído de [Chandola, Banerjee e Kumar \(2009\)](#). Nela é possível perceber duas regiões $N1$ e $N2$, que juntas concentram os pontos considerados normais, e é possível perceber também pontos que estão suficientemente distantes dessas regiões, que são os pontos $o1$, $o2$ e o grupo $O3$, considerados como *outliers*.




Figura 4.12: Exemplo ilustrativo de *outliers*. Fonte: [Chandola, Banerjee e Kumar \(2009\)](#)

De acordo com [Chandola, Banerjee e Kumar \(2009\)](#), identificar *outliers* nem sempre é uma tarefa fácil, pois a fronteira entre os dados considerados normais e os *outliers* pode não ser tão precisa. Um outro aspecto diz respeito à noção de *outlier*, que varia a depender do domínio da aplicação, isto é, um pequeno desvio pode ser considerado *outlier* para um certo domínio, mas normal para outro domínio.

É um fato muito comum em processos de análise de dados, a busca pela identificação e eliminação de *outliers*, pois a sua presença pode causar resultados indesejados. Porém um *outlier* nem sempre deve se descartado no processo de análise de dados, pois em muitos cenários, inclusive neste trabalho, o *outlier* é também um objeto de interesse do estudo.

4.2.3.2 Abordagens

Diversos autores costumam segmentar os métodos de detecção de *outliers* de duas formas não disjuntas: métodos univariados e multivariados; e métodos paramétricos e não-paramétricos.

Os métodos univariados são geralmente os métodos mais antigos e se caracterizam por manipular apenas uma dimensão, isto é, uma única variável. Já os métodos multivariados podem manipular mais de uma dimensão, isto é, mais de uma variável.

Os métodos paramétricos são aqueles que assumem que os dados originam-se de um mo-

delo de distribuição previamente conhecido e consideram como um *outlier*, as observações que se desviam desse modelo. Porém, de acordo com [Markou e Singh \(2003\)](#), na maioria dos problemas do mundo real o modelo de distribuição não costuma ser conhecido previamente, reduzindo a importância prática desses métodos.

Já os métodos não-paramétricos não assumem previamente nenhum modelo de distribuição. Tanto o modelo, quanto os parâmetros do modelo são obtidos diretamente dos dados analisados. Portanto, [Markou e Singh \(2003\)](#) afirmam que esses métodos proporcionam mais flexibilidade para os problemas, de uma forma geral.

[Papadimitriou et al. \(2002\)](#) citam algumas das abordagens utilizadas para identificação de *outliers*:

- Baseada em Modelo de Distribuição. Os métodos partem do pressuposto que os dados seguem um modelo de distribuição, como por exemplo, a distribuição normal e são considerados *outliers*, os elementos que se desviam desse modelo. É possível citar como exemplos, o método box plot e o método de Grubbs.
- Baseada em Agrupamento. Os métodos consideram como *outliers* pontos que não pertencem a nenhum grupo ou grupos que são significativamente menores do que os outros.
- Baseada em Densidade. Os métodos dessa abordagem identificam como *outliers* os elementos que possuem uma densidade diferente da densidade dos seus k -vizinhos. É possível citar como exemplos, o algoritmo LOF, LOCI e LDE.

Dentre os algoritmos de detecção existentes, o LoF (*Local Outlier factor*) foi o escolhido para ser utilizado neste trabalho e está detalhado a seguir. Duas foram as razões para a sua escolha, a primeira é que, diferentemente de alguns algoritmos, o LoF não identifica apenas se o elemento é um *outlier* ou não, ele calcula o grau de *outlierness* do elemento, e a segunda razão é que dentre os algoritmos que se enquadram no critério anterior, ele é o único que possui implementação no software R-Project.

4.2.3.3 Algoritmo LOF (*Local Outlier Factor*)

O algoritmo foi apresentado por [Breunig et al. \(2000\)](#) e identifica como *outliers*, pontos que possuem uma densidade significativamente menor que a densidade da sua vizinhança.

De acordo com os autores, o algoritmo apresenta algumas características importantes, como a capacidade de atribuir um grau de desvio (*outlierness*) para cada objeto em

relação aos outros objetos da amostra. Eles informam que a maioria dos algoritmos de detecção de *outliers* costuma identificar os *outliers* de forma binária, isto é, categorizando-os apenas em *outlier* ou *não-outlier*.

Uma outra característica importante do algoritmo refere-se ao fato dele utilizar o cálculo da densidade local para cada objeto, diferentemente de outros métodos de *outliers*, que pressupõem uma densidade global para toda a amostra. Isto é importante porque é comum haver diferença de densidades entre os vários objetos de uma mesma amostra. Na Figura 4.13 é possível visualizar um cenário contendo duas áreas com densidades bem distintas.

É possível perceber claramente que a distância entre pontos do grupo C_2 é menor que a distância entre pontos do grupo C_1 . Isto quer dizer que a densidade em C_2 é maior que a densidade em C_1 e conseqüentemente, se houvesse uma suposição de uma densidade global para toda a amostra, a maioria dos pontos do grupo C_1 seria considerada como *outlier*.




Figura 4.13: Pontos em áreas com densidades bem distintas. Fonte: (BREUNIG et al., 2000)

O primeiro passo para a execução do algoritmo consiste na definição do número de vizinhos (k) desejados. Posteriormente, o algoritmo calcula para cada objeto o , a distância entre ele e os outros objetos p da amostra D , representado por $dist(o, p)$.

A partir de então, ele identifica a menor distância que abranja todos os k vizinhos mais próximos de cada objeto o , e que é definido como $dist_k(o)$, e identifica também os próprios k vizinhos, através de $N_k(o) = \{p | p \in D, dist(o, p) \leq dist_k(o)\}$. Vale a pena salientar que $N_k(o)$ pode ser maior que k , pois pode haver mais de um objeto p com a mesma distância

para o objeto o .

Na Figura 4.14 é possível ver um desenho esquemático contendo um ponto o e um raio com uma distância tal que a sua circunferência abranja os seus k vizinhos mais próximos, sendo $k = 3$.




Figura 4.14: Distância entre um ponto o e seus k vizinhos. Fonte: Adaptado de Breunig et al. (2000)

Posteriormente o algoritmo calcula a densidade de alcance local de cada ponto (*local reachability density - lrd*), através de:

$$lrd_k(o) = 1 / \left(\frac{\sum_{p \in N_k(o)} reachdist_k(o, p)}{|N_k(o)|} \right) \quad (4.3)$$

onde $|N_k(o)|$ é a quantidade de objetos com distância menor ou igual a $dist_k(o)$ e $reachdist_k(o, p)$, o maior valor entre $dist_k(p)$ e $dist(o, p)$.

Com base nos cálculos dos *lrd*, o algoritmo calcula o fator de desvio local (*LOF- Local Outlier Factor*), que é obtido através da seguinte fórmula:

$$LOF_k(o) = \frac{\sum_{p \in N_k(o)} \frac{lrd_k(p)}{lrd_k(o)}}{|N_k(o)|} \quad (4.4)$$

De acordo com Breunig et al. (2000), a maioria dos pontos considerados normais apresenta valores próximos de 1. Já os considerados *outliers* são aqueles que apresentam valores

diferentes de 1 e quanto mais distante desse valor, maior o grau de *outlieness* do ponto.

Na Figura 4.15 é possível visualizar um exemplo ilustrativo com o resultado da aplicação do algoritmo LOF. Nela, percebe-se um conjunto de pontos no eixo do y que se distanciam de forma mais significativa do valor 1, o que significa um maior grau de desvio do objeto em relação aos outros objetos da amostra.




Figura 4.15: Resultado da aplicação do algoritmo LOF com k vizinhos. Fonte: Autor

4.3 Sensores

4.3.1 Introdução

Um sensor é geralmente definido como um dispositivo que recebe e responde a um sinal ou estímulo. Fraden (2010) faz um refinamento desse conceito e define sensor como um dispositivo que recebe um estímulo e responde com um sinal elétrico. O autor define estímulo como uma quantidade, propriedade ou condição que é percebida e convertida em um sinal elétrico.

Fraden (2010) afirma que os sensores podem ser classificados de várias formas, dependendo do propósito. Eles podem, por exemplo, ser classificados de acordo com o material, podendo ser inorgânicos ou orgânicos e suas subcategorias; de acordo com a forma de detecção, que pode ser biológica, química, elétrica, magnética, dentre outras; de acordo com o estímulo, que pode ser acústico, ótico, elétrico, mecânico, dentre outros.

Dentre uma grande variedade de sensores de ambiente não intrusivos e de baixo custo existentes na atualidade, foram escolhidos dois deles para serem utilizados neste projeto: o sensor de movimentação e o sensor de temperatura ambiente.

A decisão pelo uso do sensor de movimentação se deu pelo fato de que a maior preocupação do modelo é perceber se a pessoa monitorada está se movimentando, pois dessa forma ele tem a confirmação de que ela está viva. A escolha pelo sensor de temperatura se deu pela sua capacidade em detectar a temperatura ambiente da residência, e consequentemente detectar temperaturas críticas que podem trazer riscos à saúde de uma pessoa, e principalmente de um idoso.

Os sensores supracitados estão detalhados a seguir.

4.3.2 Sensor de Movimentação

Segundo [Repas \(2013\)](#), o *Passive infrared - PIR* ou também conhecido como *Pyroelectric infrared* é um tipo de sensor infravermelho que tem como base de funcionamento a detecção da diferença de temperatura entre a superfície do objeto em movimento e do ambiente monitorado. Ele baseia-se no fato de que todo objeto com temperatura acima do zero absoluto emite uma radiação térmica, que não é visível ao olho humano, mas é perceptível pelas células piroelétricas.

O fato das pessoas possuírem uma temperatura corporal externa em torno dos 34°C , o que costuma ser maior do que a temperatura dos ambientes, permite que, quando uma pessoa se movimenta e passe pelo raio de cobertura do sensor, as células piroelétricas detectem a diferença de temperatura entre a pessoa (temperatura maior) e o ambiente (temperatura menor) e emitam um sinal.

A Figura 4.16 apresenta o funcionamento de um sensor *PIR*. Nela é possível verificar as células piroelétricas captando a energia térmica, que é amplificada e posteriormente comparada com a energia térmica da leitura anterior e quando for detectada diferença, um sinal é emitido.

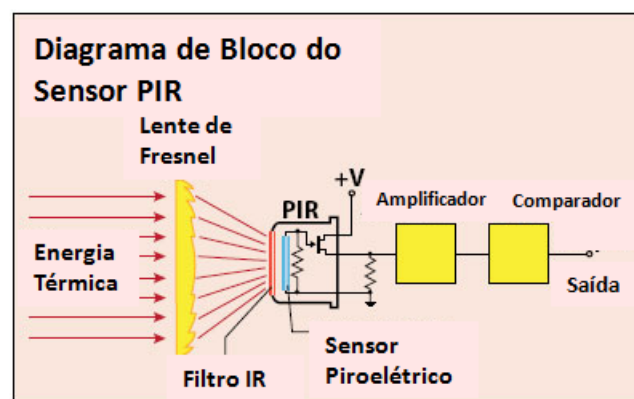


Figura 4.16: Ilustração do Funcionamento de um Sensor PIR. Fonte: Adaptado de [Repas \(2013\)](#)

4.3.3 *Sensor de temperatura*

O funcionamento de um sensor de temperatura baseia-se na transmissão de uma pequena parte da energia térmica do objeto para o sensor, que a converte em um sinal elétrico. Quando o objeto é colocado em contato com o sensor, dá-se uma troca de calor entre as superfícies do objeto e do sensor. O mesmo ocorre quando a transferência é na forma de radiação, a energia térmica na forma de luz infra-vermelha é trocada entre o sensor e o ambiente. (FRADEN, 2010)

4.3.4 *Conclusão*

Este capítulo apresentou os fundamentos teóricos que subsidiam este projeto, detalhando os métodos de reconhecimento de padrões utilizados no projeto, como o estimador de função densidade Kernel, o algoritmo de mineração de padrões sequenciais SPADE e o algoritmo de detecção de *outliers* LOF. Por fim, foram apresentados os dois sensores escolhidos para serem utilizados na fase de sensoriamento do projeto.

O próximo capítulo descreve o modelo proposto, onde é possível perceber a aplicação dos métodos e sensores aqui descritos.

Modelo Proposto

5.1 Introdução

Este capítulo tem como objetivo descrever o modelo proposto, detalhando seu funcionamento e principais elementos. Para essa finalidade, utiliza-se o protocolo ODD (*Overview, Design concepts, and Details*), proposto por [Grimm et al. \(2006\)](#).

A saber, o ODD é um protocolo utilizado para descrever modelos de simulação computacional e é composto por três blocos (Visão Geral, Conceitos de Projeto e Detalhes), que são subdivididos em sete elementos: *Propósito, Variáveis de Estado e Escalas, Visão de Processo e Escalonamento, Conceitos de Projeto, Inicialização, Entrada e Submodelos*, conforme pode ser visto na Figura 5.1.

Bloco	Elemento
Visão Geral	Propósito
	Variáveis de Estado e Escalas
	Visão de Processo e Escalonamento
Conceitos de Projeto	Conceitos de Projeto
Detalhes	Inicialização
	Entrada
	Submodelos

Figura 5.1: Protocolo ODD. Fonte: [Grimm et al. \(2006\)](#)

5.2 Visão Geral

5.2.1 Propósito

O modelo proposto tem como objetivo interpretar dados coletados da casa de uma pessoa que mora sozinha, aprender alguns dos seus comportamentos rotineiros e informar quando forem detectadas situações consideradas de risco para a sua saúde ou para o funcionamento do sistema. O modelo faz parte de um sistema de monitoramento, que está descrito na Figura 5.2.

Quando uma pessoa se move dentro do raio de alcance de um sensor de movimentação, este transmite um sinal contendo o momento da movimentação da pessoa e a identificação

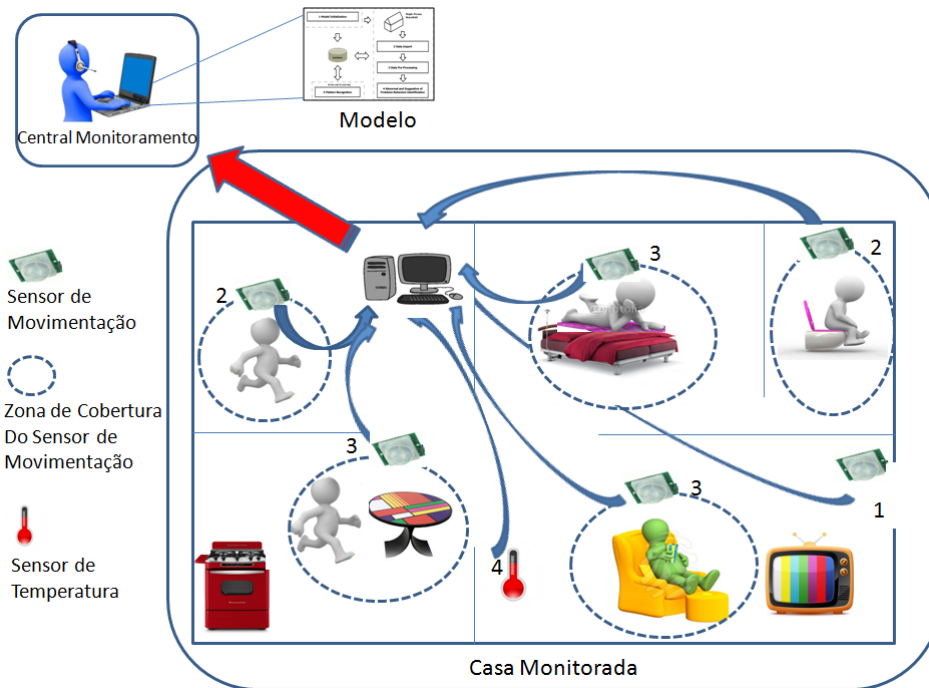


Figura 5.2: Visão geral do funcionamento do sistema de monitoramento. Fonte: Autor

do sensor ativado. No caso do sensor de temperatura, é transmitido um sinal com a temperatura do ambiente, em intervalos de tempo regulares. Esses sinais são capturados e armazenados em um computador instalado na casa da pessoa e com uma frequência pré-determinada, são transmitidos para uma central de monitoramento localizada fora da casa e processados pelo modelo aqui proposto.

A Figura 5.3 apresenta uma visão geral do funcionamento do modelo, onde os sinais oriundos da casa passam pelas seguintes etapas: Pré-Processamento de Dados, Identificação de Situações Anormais e Reconhecimento de Padrões.

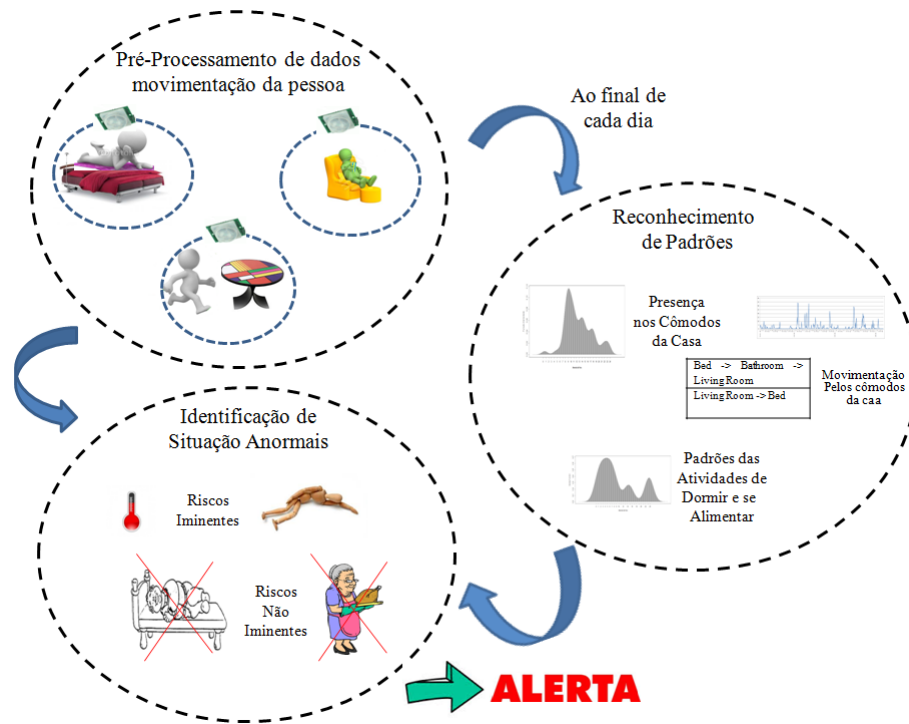


Figura 5.3: Visão geral do modelo proposto. Fonte: Autor

5.2.2 Variáveis de Estado e Escalas

O modelo possui um conjunto de entidades de baixo nível que possibilitam o seu correto funcionamento. A Figura 5.4 apresenta as relações entre essas entidades e a Tabela 5.1 apresenta uma breve descrição delas, juntamente com suas características.

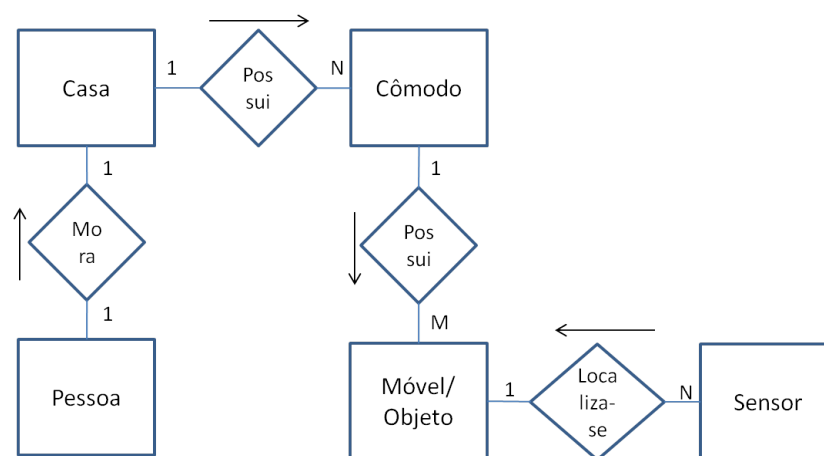


Figura 5.4: Relação entre as entidades do modelo. Fonte: Autor

Através do diagrama, percebe-se que em cada casa mora apenas uma pessoa e que nela há uma quantidade N de cômodos, onde há um conjunto M de móveis e objetos, como portas, camas, sofás, etc. E por fim, cada sensor poderá ser instalado em um desses móveis/objetos.

Tabela 5.1: Variáveis de Estado do Modelo

Entidade/Variável	Descrição	Tipo
Casa		
Número	Número da casa (único no modelo)	Inteiro
Tipo	Categoria do imóvel: casa, apartamento, etc	Caractere
Cidade	Cidade onde a casa está localizada	Caractere
Temperatura Mínima	Temperatura mínima aceitável	Real
Temperatura Máxima	Temperatura máxima aceitável	Real
Cômodo		
Número	Número do cômodo (único em cada casa)	Inteiro
Tipo	Categoria: sala, quarto, cozinha, etc	Caractere
Porta de Entrada/Saída	Informa se o cômodo possui porta de entrada/saída	Lógica
Objeto/Móvel		
Número	Número do objeto (único em cada casa)	Inteiro
Tipo	Categoria: mesa, sofá, porta, cama, etc	Caractere
Pessoa		
Número	Número da pessoa (único no modelo)	Inteiro
Gênero	Gênero da pessoa	Caractere
Idade	Idade da pessoa	Inteiro
Altura	Altura da pessoa (em metros)	Real
Animal	Informa se possui animal de estimação	Lógica
Diarista	Informa se possui diarista	Lógica
Sensor		
Número	Número do sensor (único na casa)	Inteiro
Tipo	Informa se o sensor é de movimento ou temperatura	Caractere

Fonte: Autor

Além das entidades de baixo nível, o modelo também possui um conjunto de parâmetros necessários para o seu adequado funcionamento e que estão detalhados na Tabela 5.2.

Tabela 5.2: Parâmetros do Modelo

Parâmetro	Descrição	Medida
FATOR_MULT	Fator multiplicador usado para calcular o tempo limite máximo do uso de móveis como sofás, camas e mesas, antes da emissão de um alerta	Percentual
FATOR_MULT2	Fator multiplicador usado para calcular o tempo limite máximo para a pessoa ficar fora de casa, antes da emissão de uma alerta	Percentual
FREQ_REFEICAO	Frequência mínima usada para determinar o grau de confiança na realização de uma refeição	Percentual
NUM_PES	Número de pessoas presentes na residência em um determinado momento	Unidade
QTD_ACIO_SIMULT	Quantidade limite de acionamentos que definem o número de pessoas na casa	Unidade
TP_ENTRE_USO_MOVEL	Intervalo de tempo máximo entre dois períodos ininterruptos de uso de móveis, como cama e sofá	Tempo (Minuto)
TP_LIM_SEM_MOVIM	Intervalo de tempo limite usado para identificar situações consideradas críticas, como quedas e desmaios	Tempo (Minuto)
TP_MAX_ACIO	Duração de tempo máxima de acionamento de sensores de movimentação	Tempo (Segundo)
TP_MIN_SEM_ACIO	Duração de tempo mínima para configurar a saída da pessoa de casa	Tempo (Minuto)
TP_SIMULT	Duração de tempo utilizada para verificar a simultaneidade de acionamentos de sensores de movimentação	Tempo (Segundo)
TP_SIMULT_EXT	Duração de tempo utilizada para calcular a maior quantidade de acionamentos simultâneos de sensores de movimentação no intervalo de tempo TP_SIMULT	Tempo (Minuto)
TP_USO_MOVEL	Intervalo de tempo ininterrupto de uso de móveis como cama, sofá e mesa	Tempo (Minuto)

Fonte: Autor

5.2.3 Visão de Processo e Escalonamento

O modelo possui três macroprocessos, conforme pode ser visto na Figura 5.3.

O **Pré-Processamento de Dados** tem como objetivo ler os sinais oriundos da casa monitorada e tentar inferir a atividade que a pessoa está realizando no momento e que é de interesse do modelo, como por exemplo, dormir, fazer uma refeição, movimentar-se pela casa e entrar e sair dela. Ele também realiza mudanças nas estruturas dos dados com o propósito de adequá-los aos algoritmos que serão executados no processo Reconhecimento de Padrões.

Para cada sinal que chega da casa, o modelo também realiza um conjunto de verificações com o objetivo de identificar situações consideradas críticas para a saúde da pessoa, como também para o funcionamento do sistema. Este é o objetivo do processo **Identificação de Situações Anormais**.

Ao final de cada dia, o processo **Reconhecimento de Padrões** é executado com o propósito de atualizar os padrões de comportamento da pessoa, com os dados pré-processados durante o dia.

5.3 *Conceitos de Projeto*

5.3.1 *Conceitos de Projeto*

Pelo fato do modelo aqui proposto não ser um modelo de simulação baseada em agentes, mas um modelo de reconhecimento de padrões, o único item que compõe o elemento *Conceitos de Projeto* do protocolo ODD e que é compatível com esse modelo, é o item **Observação**.

Observação: Os sinais dos sensores coletados da casa da pessoa monitorada são analisados por um conjunto de algoritmos que busca aprender o comportamento da pessoa e também identificar situações consideradas de risco. E para alcançar esse objetivo, diversos métodos são utilizados, como estatística descritiva, estimação de função densidade, mineração de padrões sequenciais e detecção de *outliers*.

5.4 *Detalhes*

5.4.1 *Inicialização*

A etapa de inicialização do modelo pode ser dividida em três atividades principais, conforme apresentada na Figura 5.5. A primeira posiciona os sensores nos cômodos da re-

sidência; a segunda configura os caminhos pelos quais uma pessoa pode passar por entre os cômodos da casa e por fim, a terceira inicializa os parâmetros e variáveis apresentados na Seção 5.2.2. Essas atividades estão detalhadas a seguir.

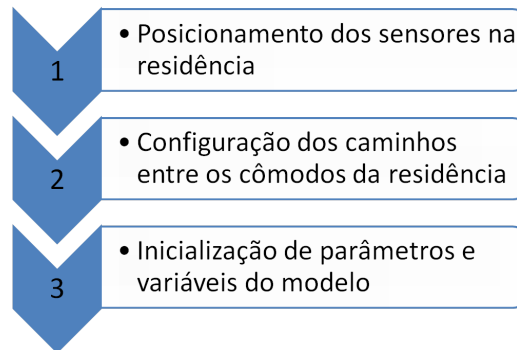


Figura 5.5: Atividades que compõem a etapa de inicialização do modelo. Fonte: Autor

5.4.1.1 *Posicionamento dos Sensores na Residência*

Para o correto funcionamento do modelo, é importante que os sensores instalados na casa da pessoa monitorada obedeçam os seguintes critérios:

1. Na parte interna de cada porta de entrada da residência, deve haver um sensor de movimentação, com o objetivo de perceber a entrada e saída de pessoas no imóvel (Figura 5.6, número 1);
2. Em cada cômodo da residência, deve haver uma quantidade de sensores de movimentação que permita cobrir a área de movimentação de uma pessoa. Almeja-se identificar os padrões de movimentação da pessoa dentro de cada cômodo (Figura 5.6, número 2);
3. Deve haver um sensor de movimentação direcionado para cada móvel onde são realizadas atividades com baixa ativação de sinais, como é o caso das camas, sofás e mesas. O objetivo é compreender os padrões de uso desses móveis, já que eles estão diretamente relacionados com atividades importantes em um ambiente domiciliar, como a atividade de dormir e de se alimentar (Figura 5.6, número 3);
4. Deve haver pelo menos um sensor de temperatura em algum cômodo da residência, com o objetivo de detectar temperaturas consideradas fora dos limites aceitáveis para a pessoa (Figura 5.6, número 4).

É importante salientar que todos os sensores instalados na residência precisam ser previamente configurados. No caso dos sensores de movimentação, é necessário configurar dois

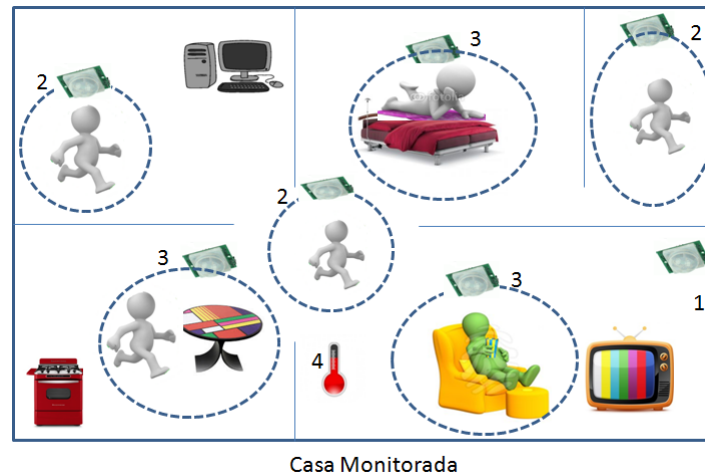


Figura 5.6: Critérios para instalação dos sensores em uma residência. Fonte: Autor

parâmetros: o **alcance do sensor** e a **latência na captação dos sinais**. Este último representa o tempo mínimo entre a captura de dois sinais consecutivos de um mesmo sensor. Para o sensor de temperatura é preciso configurar o **intervalo de tempo de envio do sinal**.

5.4.1.2 Configuração dos Possíveis Caminhos entre os Cômodos da Residência

Para que o modelo possa conhecer os possíveis caminhos pelos quais a pessoa pode caminhar por entre os cômodos da casa e conseqüentemente, aprender seus padrões de movimentação, ele faz uso de um grafo, aqui chamado de grafo de sensores, que pode ser visto no desenho esquemático da Figura 5.7.

De acordo com [Feofiloff, Kohayakawa e Wakabayashi \(2011\)](#), um grafo corresponde a um par (V, A) , onde V , denominado de vértice, representa um conjunto finito e arbitrário de elementos e A , denominado de aresta, representa o conjunto de todos os pares de elementos de V .

Na Figura 5.7 é possível visualizar um exemplo de um grafo de sensores. Os vértices do grafo representam os sensores de movimentação distribuídos pela casa, as arestas representam os caminhos entre os sensores adjacentes e os círculos simulam o raio de alcance dos sensores. O grafo utilizado é do tipo ponderado, pois possui um peso $(d_{12}, d_{23}, \dots, d_{n-1n})$ atribuído a cada aresta, que representa a separação entre zonas de cobertura de sensores adjacentes.

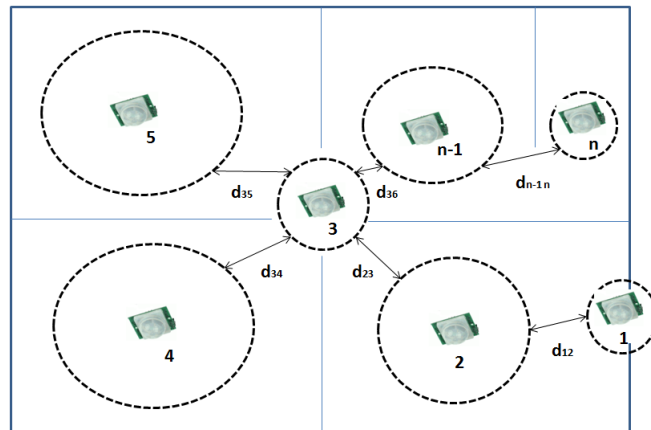


Figura 5.7: Exemplo de um grafo de sensores de movimentação. Fonte: Autor

Portanto, é importante que todos os caminhos possíveis de serem percorridos entre os sensores de movimentação estejam representados no grafo de sensores, para evitar a emissão de alarmes falsos.

5.4.1.3 Inicialização de Parâmetros e Variáveis do Modelo

As características das entidades de baixo nível do modelo, apresentadas na Tabela 5.1, são inicializadas com base em dados extraídos de um questionário aplicado ao idoso, antes do início do monitoramento.

Os parâmetros apresentados na Tabela 5.2 são inicializados de forma empírica, tendo como base, a aparente higidez do idoso e a proximidade entre as áreas de cobertura dos sensores de movimentação. Vale salientar que o parâmetro NUM_PES deve ser inicializado com o número de pessoas presente na casa, no momento inicial do monitoramento.

5.4.2 Entrada

Os dados referentes às entidades apresentadas na Tabela 5.1 são inseridos no banco de dados do modelo antes do início da execução do sistema e ocorre de forma manual. Os sinais gerados pelos sensores, contudo, são inseridos através de uma rotina específica de importação de dados, que é executada a cada intervalo de tempo.

Os registros com os sinais chegam em um formato de texto, mais especificamente, no formato *csv* (*comma-separated values*). A *string* que compõe os registros possui a seguinte

sequência de dados: *data e horário de ativação do sinal, identificador único do sensor e o valor capturado pelo sensor*, como por exemplo: *08/03/2012 13:00:00;1;0*. No caso dos sinais gerados por um sensor de movimentação, o campo *valor* possui 0 (zero) e no caso do sensor de temperatura, o campo *valor* apresenta a temperatura do ambiente, medida no momento.

5.4.3 Submodelos

Conforme apresentado na Seção 5.2.3, o modelo possui três macroprocessos, subdivididos em submodelos, que estão detalhados a seguir:

5.4.3.1 Processo 1: Pré-Processamento de Dados

Este processo tem como objetivo identificar a movimentação da pessoa por entre os ambientes da casa e tentar inferir possíveis atividades que ela esteja realizando. Ele também realiza transformações nas estruturas dos dados para adequá-los aos algoritmos de reconhecimento de padrões.

Ele é composto por três submodelos, que podem ser vistos na Figura 5.8: o primeiro lida com a identificação do número de pessoas presentes na residência; o segundo busca identificar os momentos em que são realizadas as atividades de dormir e se alimentar; e o último contabiliza o número de ativações de cada sensor e o tempo que a pessoa costuma ficar em cada cômodo da residência.

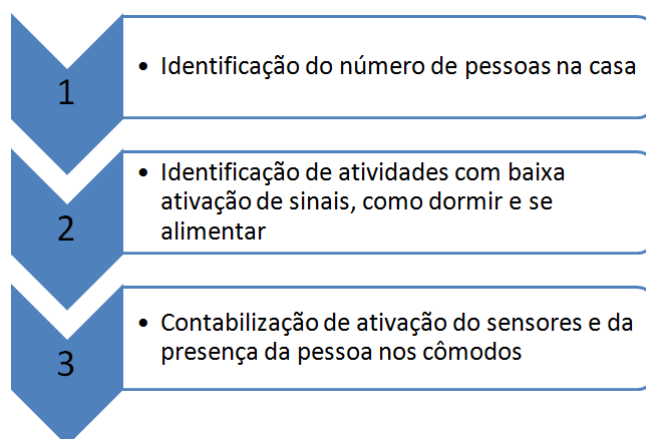


Figura 5.8: Submodelos que compõem o processo Pré-Processamento de Dados. Fonte: Autor

Submodelo 1.1: Identificação do número de pessoas na casa

A percepção do número de pessoas presentes na residência é uma informação muito importante para o modelo, pois a execução de diversos algoritmos depende dela. Portanto, a cada sinal que chega da casa, o modelo precisa verificar se há alguma relação com a entrada ou saída de pessoas da residência e em caso afirmativo, contabilizar essa movimentação.

Esta etapa é composta por quatro algoritmos, sendo que os três primeiros possuem o mesmo objetivo, que é identificar a entrada e saída de pessoas na residência e o que os distingue é apenas o cenário, e o quarto e último algoritmo, objetiva corrigir possíveis distorções resultantes dos três algoritmos anteriores. Estes podem ser vistos nas Figuras 5.9, 5.10, 5.11 e 5.12, respectivamente.

Alg01: Identificação de entrada na residência quando ela estiver vazia (Figura 5.9).

O algoritmo só é executado quando o modelo percebe que não há ninguém na residência e o seu funcionamento ocorre da seguinte forma: inicialmente é verificado se o sinal ativado vem de um sensor localizado na porta de entrada da residência e em caso afirmativo, presume-se que alguém entrou na casa e então o número de pessoas na residência, NUM_PES é incrementado de 1, como também essa informação é gravada no banco de dados.

Contudo, se o sinal tiver vindo de outro sensor de movimentação, que não o de uma porta de entrada, o modelo identifica essa situação como anormal, pois espera-se que o primeiro acionamento de um sensor em uma residência vazia, seja de um sensor localizado na porta de entrada. Neste caso, o modelo emite um alerta.

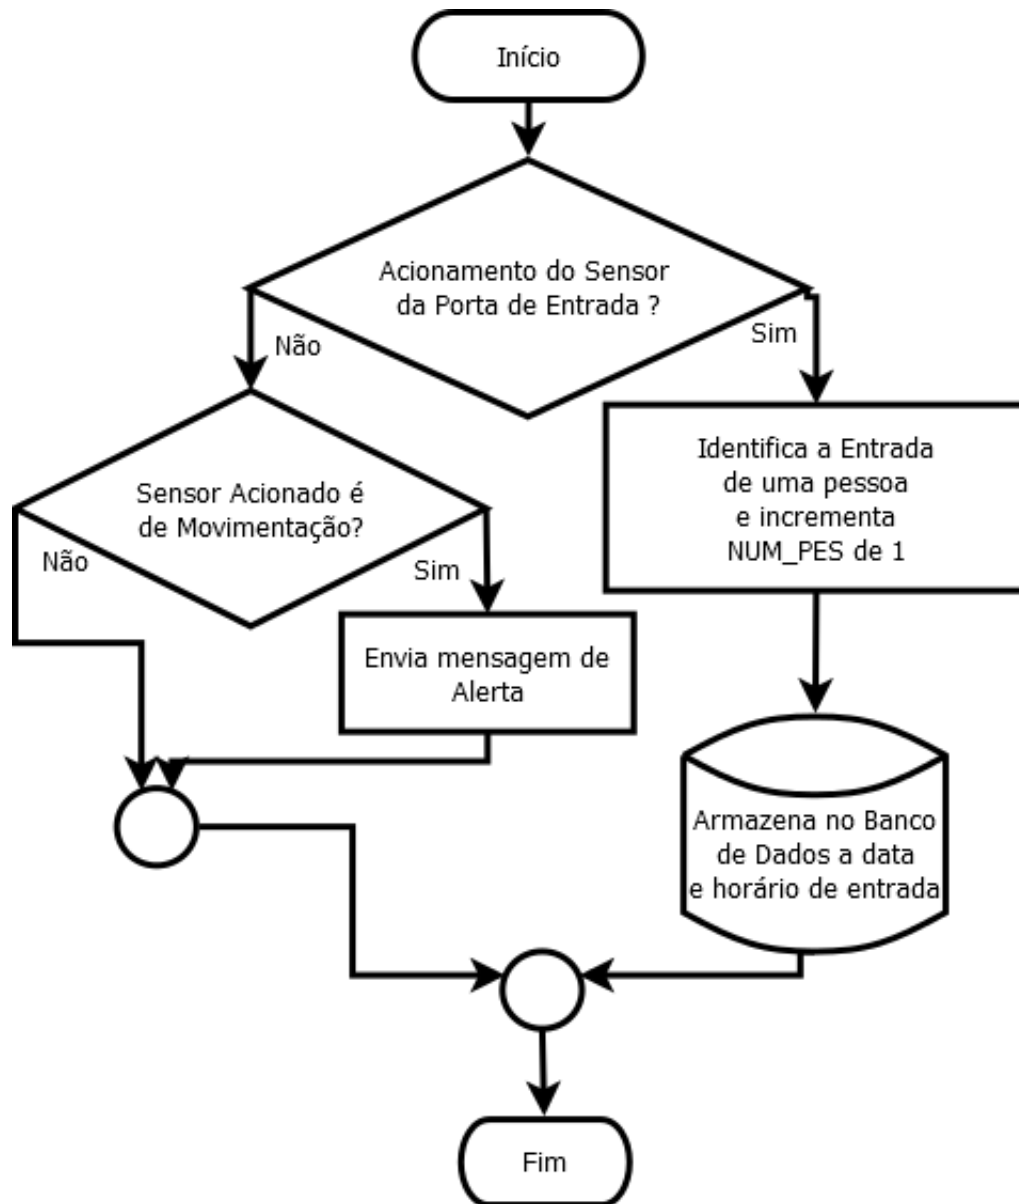


Figura 5.9: Alg01 - Identificação de entrada na residência quando ela estiver vazia. Fonte: Autor

Alg02: Identificação de entrada/saída da residência quando houver uma única pessoa (Figura 5.10).

O algoritmo é executado quando o modelo percebe que há apenas uma única pessoa na residência e funciona da seguinte forma: ele verifica inicialmente se o sinal ativado vem de um sensor localizado na porta de entrada da residência e em caso afirmativo, verifica se o acionamento imediatamente anterior é de um sensor ligável àquele, através do grafo de sensores. Em caso afirmativo, presume-se que a pessoa que está dentro da casa, movimentou-se em direção à porta de entrada, porém o modelo não tem ainda como afirmar se a pessoa saiu da casa.

Para confirmar se a pessoa efetivamente saiu da casa, o algoritmo não deve detectar o acionamento de nenhum sensor de movimentação por um período maior que `TP_MIN_SEM_ACIO`. Neste caso, é atribuído a `NUM_PES` o valor 0 (zero) e essa atualização é gravada no banco de dados.

Caso o acionamento imediatamente anterior tenha sido de um sensor não ligável ao sensor da porta, através do grafo de sensores, presume-se que a pessoa que está dentro da residência não se movimentou em direção à porta de entrada, mas que uma outra pessoa adentrou a residência. Neste caso, o algoritmo incrementa de 1 (um) o número de pessoas na residência, `NUM_PES` e grava no banco de dados.

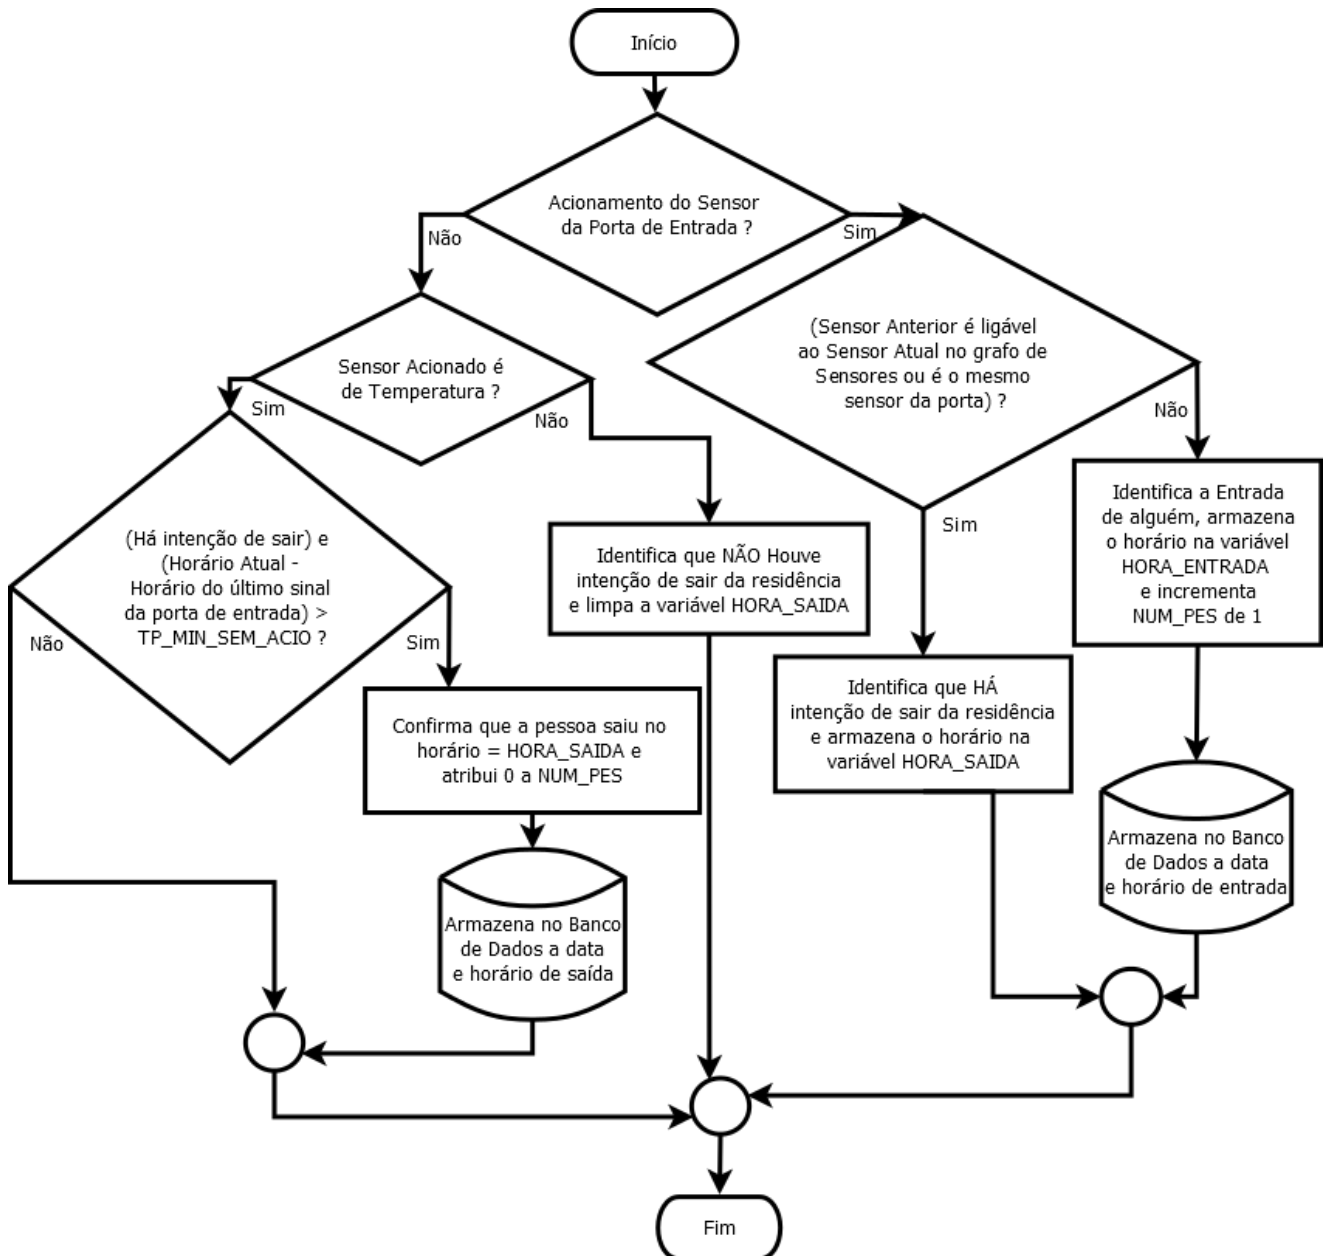


Figura 5.10: Alg02 - Identificação de entrada e saída da residência quando há apenas uma pessoa. Fonte: Autor

Alg03: Identificação de entrada/saída da residência quando houver mais de uma pessoa (Figura 5.11).

O algoritmo é executado quando o modelo percebe que há mais de uma pessoa na residência e o seu funcionamento se dá da seguinte maneira: ele inicia verificando se o sinal ativado vem de um sensor localizado na porta de entrada da residência e em caso afirmativo, verifica se nos últimos TP_MAX_ACIO houve o acionamento de algum sensor ligável

àquele, através do grafo de sensores. Em caso positivo, presume-se que uma das pessoas presentes na casa movimentou-se em direção à porta de entrada, mas até esse momento, o modelo ainda não tem como afirmar se ela efetivamente saiu.

Para confirmar se todas as pessoas saíram da residência, o algoritmo precisa não detectar o acionamento de nenhum sensor de movimentação por um período maior que `TP_MIN_SEM_ACIO`. Neste caso, é atribuído o valor 0 (zero) a `NUM_PES` e essa atualização é gravada no banco de dados.

Contudo, se os primeiros sinais de movimentação forem oriundos somente de sensores não ligáveis ao sensor da porta de entrada, então supõe-se que ainda ficou alguém na residência, o valor 1 é decrescido de `NUM_PES` e este é armazenado no banco de dados.

Caso não tenha havido o acionamento de nenhum sensor ligável ao sensor interno da porta nos últimos `TP_MAX_ACIO`, entende-se que ninguém na casa se movimentou em direção à porta, e então presume-se que uma outra pessoa entrou na residência, e o valor de `NUM_PES` é incrementado de 1 e armazenado no banco de dados.

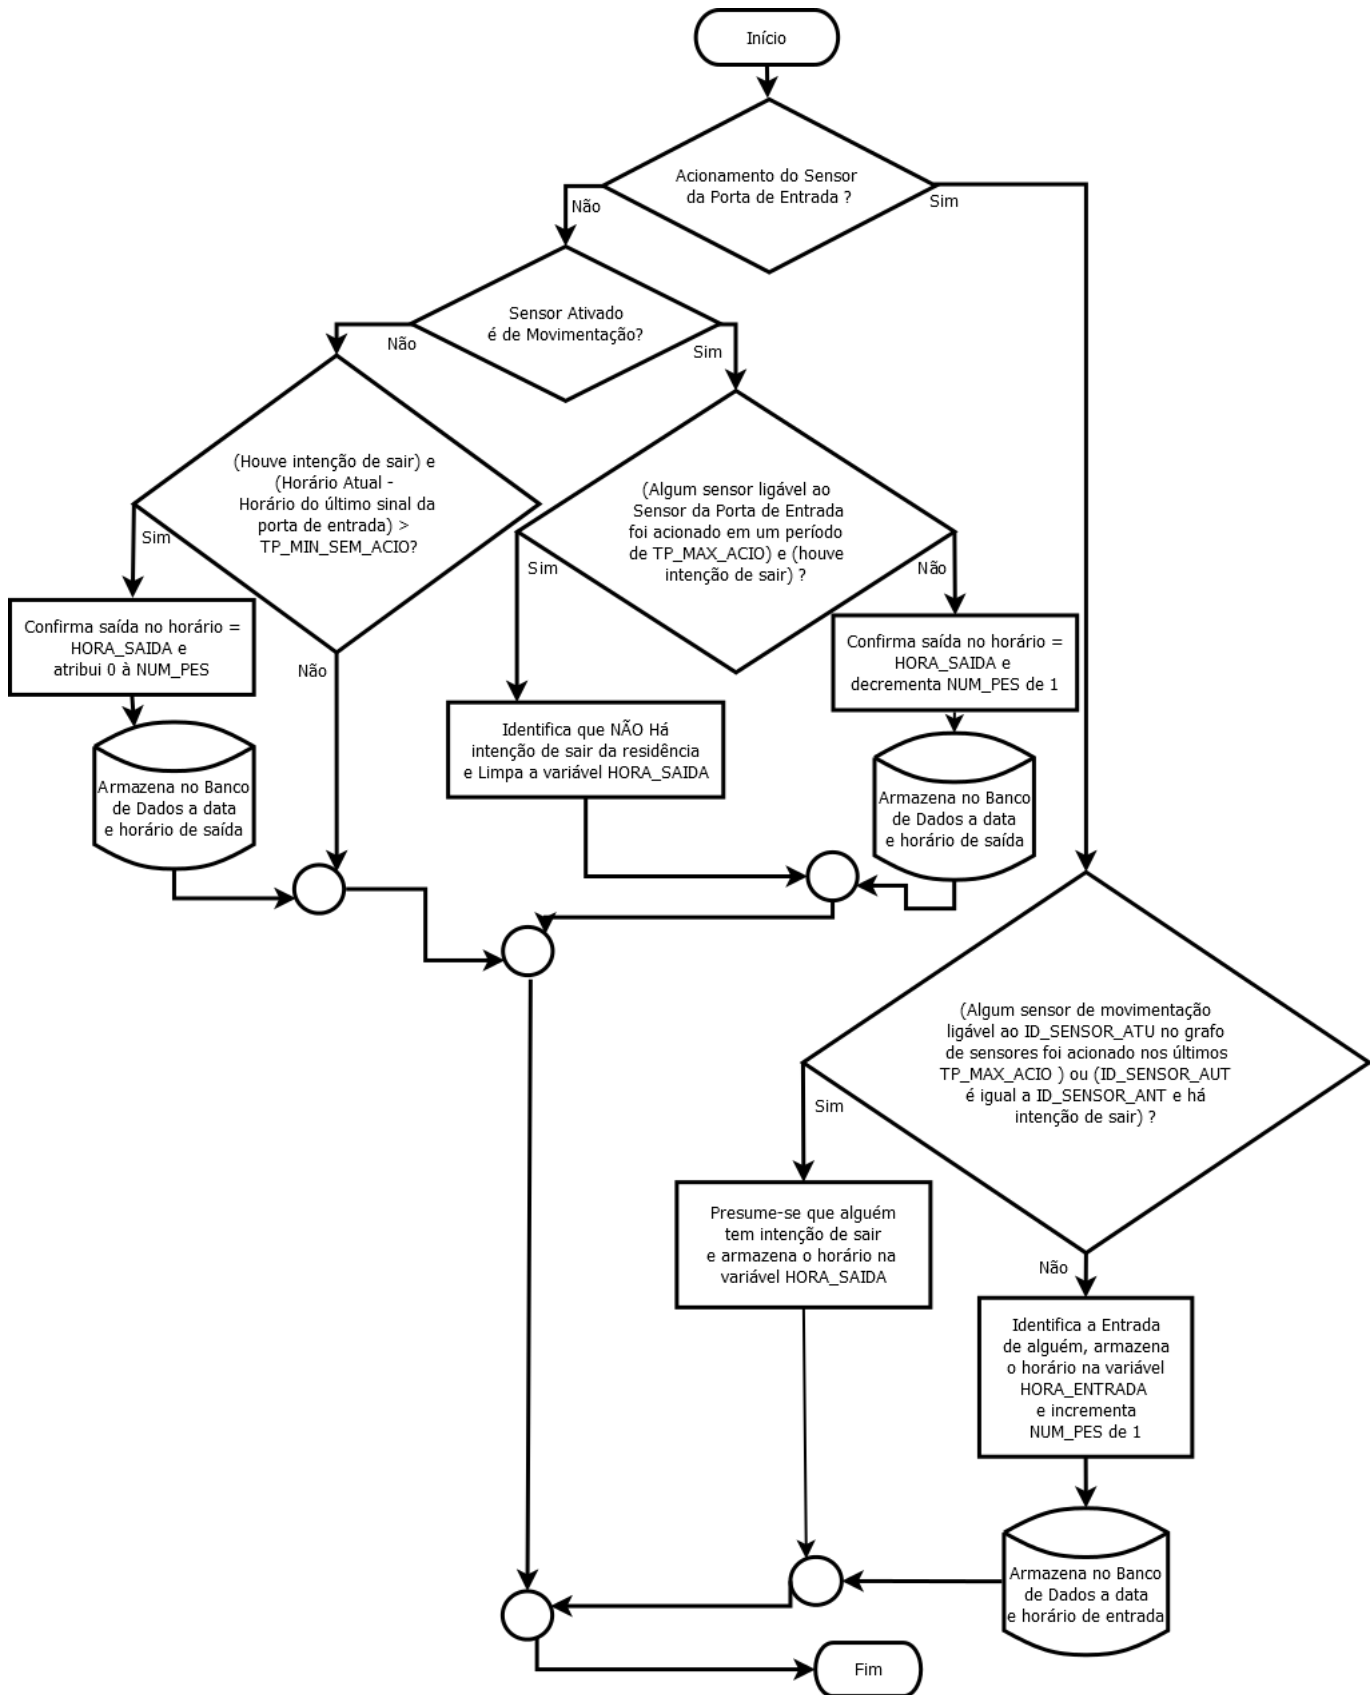


Figura 5.11: Alg03 - Identificação de entrada e saída da residência quando há mais de uma pessoa. Fonte: Autor

Alg04: Confirmação ou correção do número de pessoas na residência (Figura 5.12).

Este algoritmo tem como objetivo corrigir possíveis distorções quanto a detecção do número de pessoas presentes na residência e se faz necessário devido a imprecisão dos três algoritmos anteriores em identificar a movimentação de entrada e saída de pessoas da residência. Essa imprecisão é causada pelo tipo de sensor utilizado no modelo, que é o sensor de movimentação *PIR*.

O modelo verifica se há inconsistência entre o número de pessoas que ele presume haver na residência e a quantidade de acionamentos simultâneos dos sensores de movimentação, que chega da residência.

O algoritmo funciona da seguinte forma: é calculada para os últimos `TP_SIMULT_EXT` minutos, a quantidade de ativações que ocorrem entre diferentes sensores de movimentação, com uma diferença de tempo de `TP_SIMULT` segundos e é atribuída à variável `QTD_ACIO`.

Caso `QTD_ACIO` seja maior do que o parâmetro `QTD_ACIO_SIMULT`, então significa que há mais de uma pessoa na casa. Neste caso, o número de pessoas, `NUM_PES`, é atualizado para 2 e gravado no banco de dados. Caso contrário, verifica-se se `QTD_ACIO` é menor do que `QTD_ACIO_SIMULT` e em caso afirmativo, `NUM_PES` é atualizado com 1 e gravado no banco de dados.

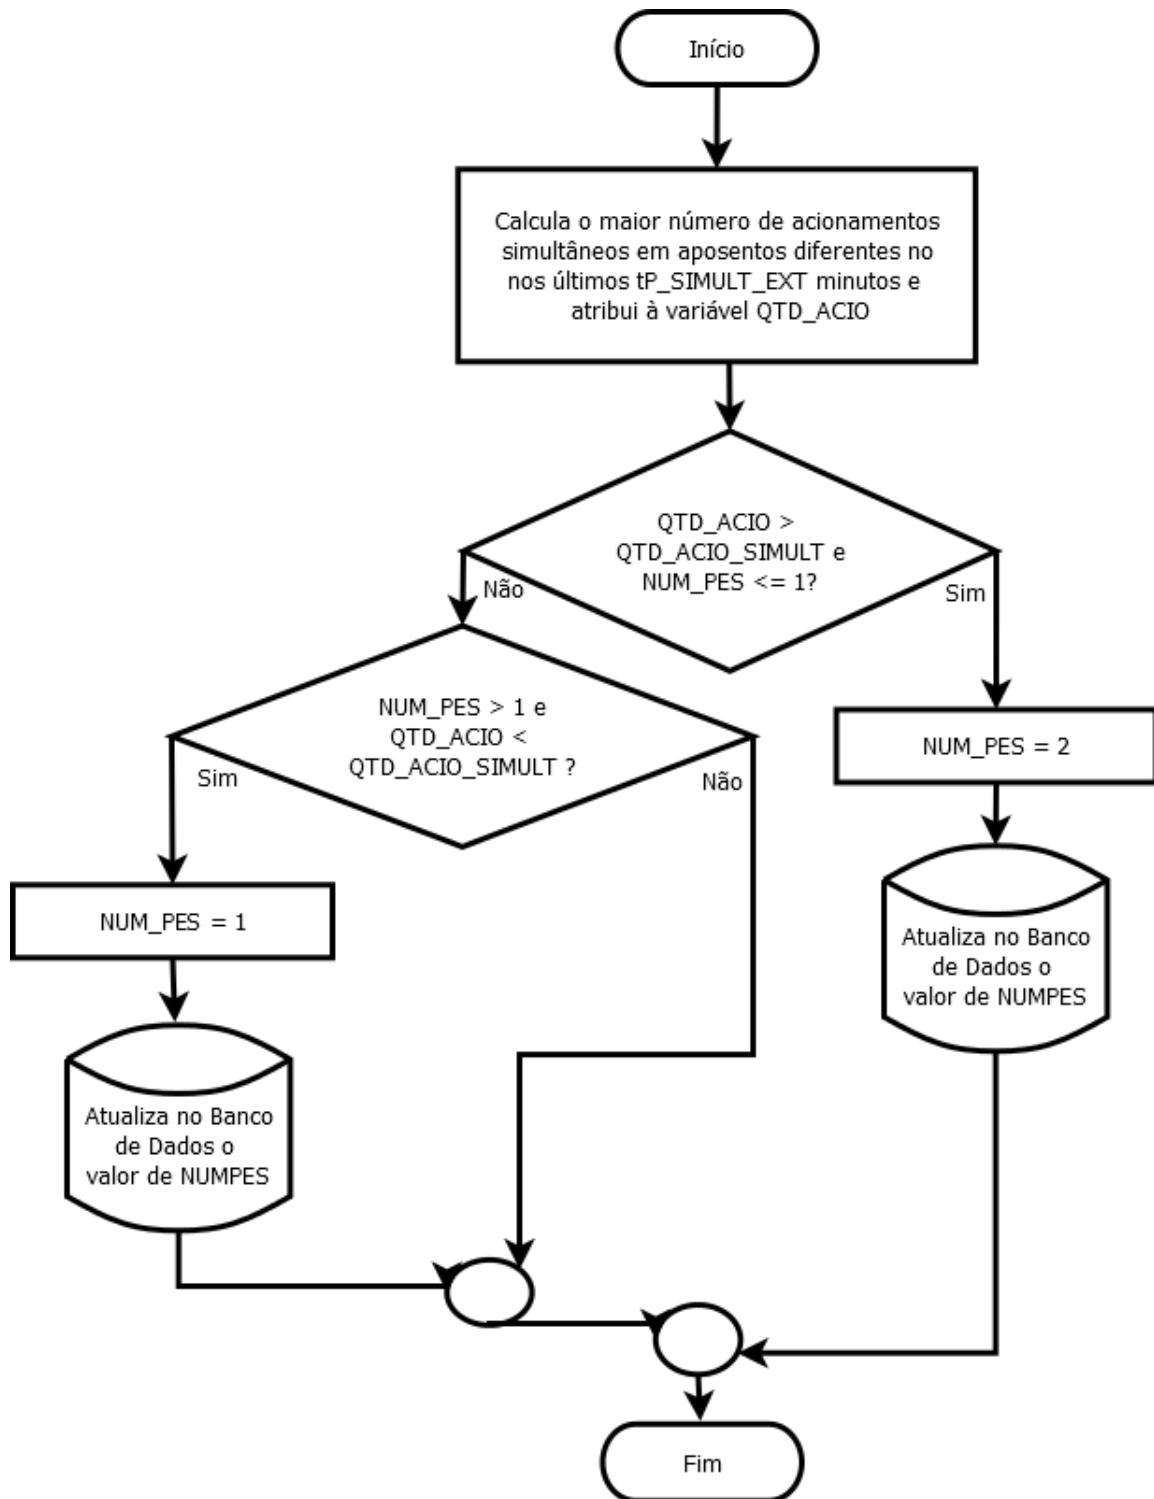


Figura 5.12: Alg04 - Confirmação ou correção no número de pessoas na residência. Fonte: Autor

Submodelo 1.2: Identificação de atividades com baixa ativação de sinais de movimentação

O modelo busca identificar os momentos em que a pessoa faz uso de móveis como camas,

sofás e mesas, pois são locais onde costumam ser realizadas atividades que emitem poucos sinais de movimentação, como é o caso das atividades de dormir e de se alimentar.

A importância dessa percepção se dá por duas razões. A primeira, e mais imediata, é que ela consegue evitar a emissão de alertas indevidos sobre falsas situações de desmaios e mal súbitos, isto porque a partir do momento em que o modelo percebe que a pessoa está em um desses móveis, ele já espera que a frequência no envio dos sinais de movimentação se reduza de modo significativo, e que o retardo na chegada dos sinais não representa nenhuma situação de risco imediato.

A segunda razão é que, a longo prazo, essas informações permitirão aos algoritmos de reconhecimento de padrões estimarem os hábitos da pessoa com respeito às atividades de dormir e se alimentar, que são consideradas essenciais para a saúde de uma pessoa.

Portanto, os dois próximos algoritmos trabalham de forma integrada e objetivam identificar informações pertinentes às atividades acima citadas.

Alg05: Cálculo dos períodos ininterruptos do uso de móveis relacionados com baixa emissão de sinais de movimentação

Para que o modelo possa contabilizar a duração de tempo em que a pessoa usa um determinado móvel, ele precisa identificar o momento em que ela se aproxima do móvel até o momento em que ela se afasta. E esse é o objetivo do algoritmo, que pode ser visto na Figura 5.13.

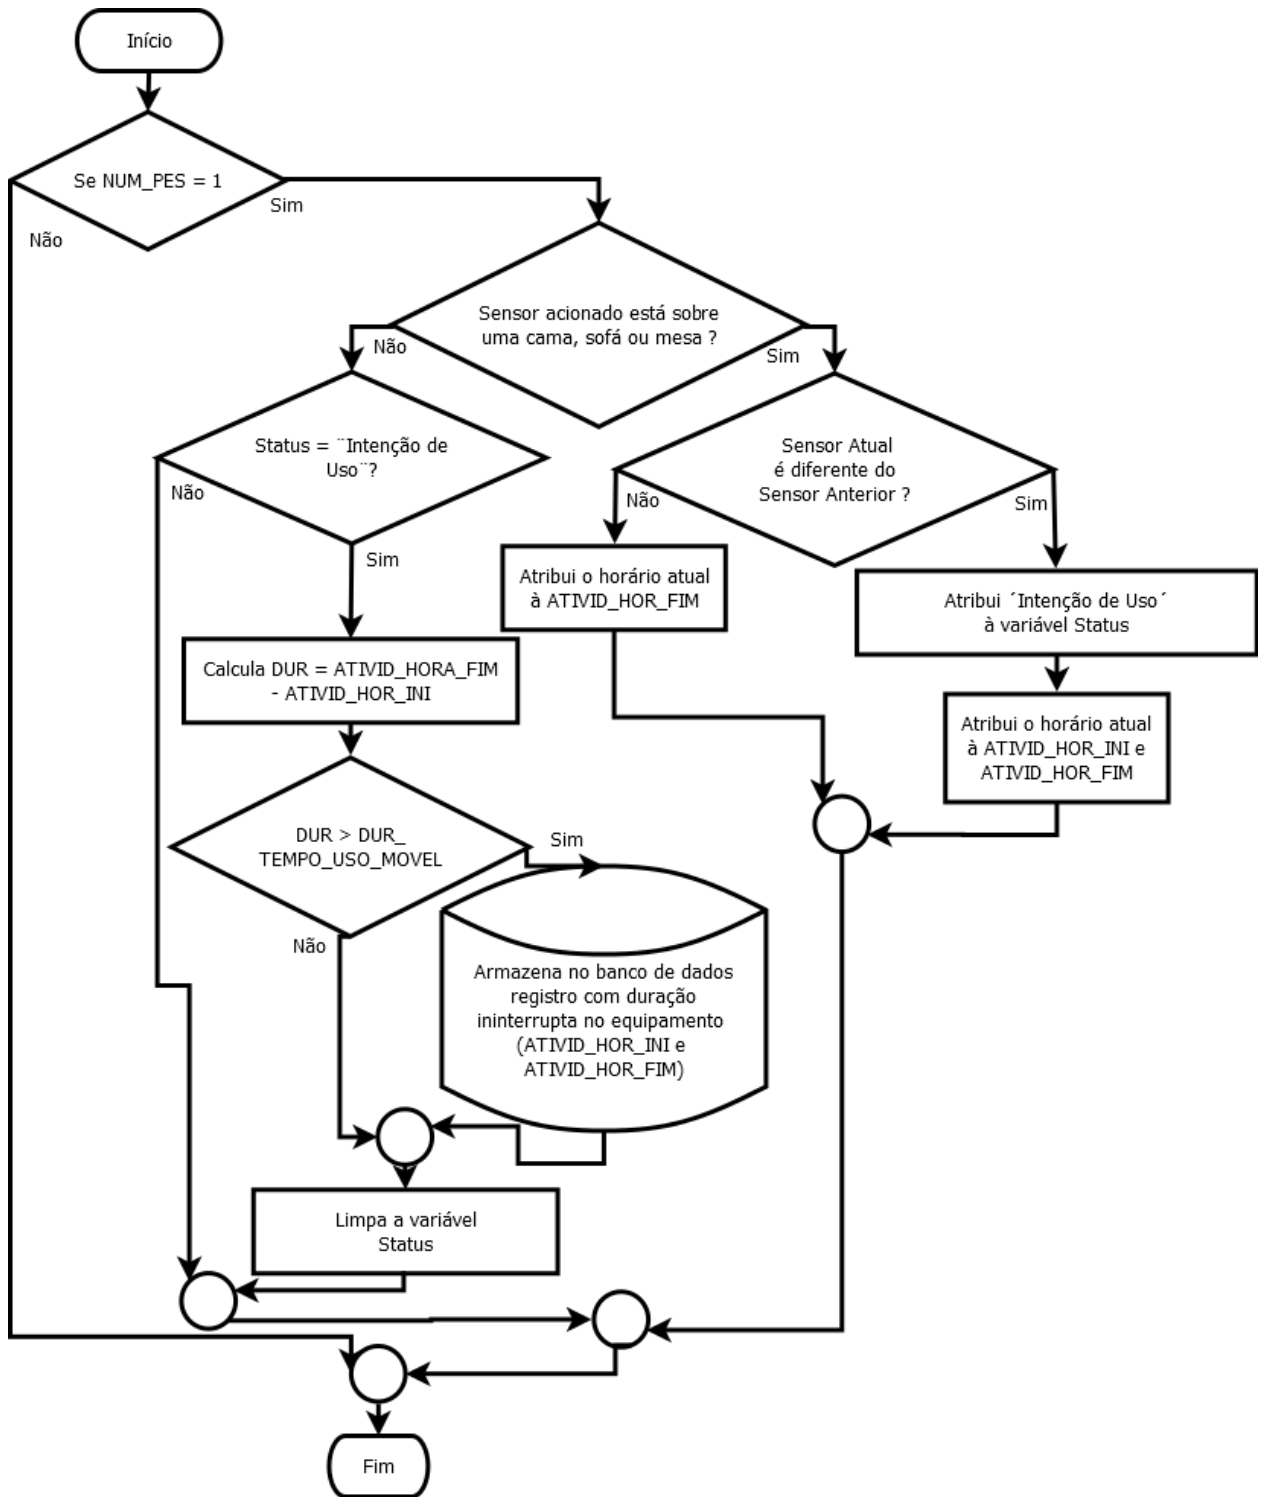


Figura 5.13: Alg05 - Determinação dos intervalos ininterruptos de uso de móveis relacionados com atividades de baixa emissão de sinais. Fonte: Autor

O funcionamento se dá da seguinte forma: ele inicia verificando se há somente uma pessoa em casa, pois só é executado nesta condição. Posteriormente, verifica se o sinal vem de

um sensor localizado sobre um sofá, cama ou mesa e em caso positivo, verifica qual foi o sensor acionado anteriormente. Caso tenha sido um sensor diferente, presume-se que a pessoa acabou de se aproximar do móvel e inicia-se a contagem do período. Caso o sinal anterior tenha sido acionado pelo mesmo sensor, o modelo presume que a pessoa continua no mesmo móvel e a contagem do período continua.

Quando o sinal acionado não for mais do sensor localizado sobre o móvel em questão, o algoritmo verifica se o tempo que a pessoa ficou no móvel é menor do que o valor do parâmetro `TP_USO_MOVEL` e em caso positivo, presume-se a pessoa não chegou efetivamente a usá-lo e despreza esse período. Caso contrário, o modelo entende que a pessoa passou um período usando o móvel, calcula a duração desse tempo e armazena no banco de dados, para fins históricos.

Alg06: Verificação de prologamento no tempo de uso de móveis relacionados com baixa emissão de sinais de movimentação

É comum ao se realizar uma atividade, como dormir ou cochilar, a pessoa se levantar para realizar uma outra atividade de curta duração, como beber água, usar o vaso sanitário ou tomar um remédio, e logo após, voltar e continuar realizando a atividade anterior.

Por essa razão, esse algoritmo tem como objetivo calcular o intervalo de tempo entre dois períodos consecutivos de uso dos móveis já citados e verificar se esse intervalo é tão curto que permita ao modelo inferir que os dois períodos compreendem, de fato, um período maior e único.

A título ilustrativo, segue um exemplo. Uma pessoa vai para a cama às 21:30 e fica até às 00:10. Depois ela se levanta para ir ao banheiro e retorna para a cama após 10 minutos. Às 3:30, ela se levanta novamente, vai ao banheiro e retorna para a cama 7 minutos depois. Somente às 6:30, ela se levanta definitivamente. Neste cenário, o algoritmo verifica que a diferença entre cada intervalo consecutivo (21:30 às 00:10), (00:20 às 03:30) e (03:37 às 06:30) é muito pequeno e que a atividade de dormir em verdade, começou às 21:30 e só terminou às 06:30, com dois momentos curtos de interrupção (10 minutos e 7 minutos).

O algoritmo pode ser visto na Figura 5.14 e funciona da seguinte maneira: ele lê os registros com os períodos ininterruptos em que a pessoa ficou em um sofá, cama ou mesa e entre cada registro, verifica se o tempo entre o final do primeiro e o início do segundo, é menor do que o valor do parâmetro `TP_ENTRE_USO_MOVEL`. Em caso positivo, entende-se que o intervalo entre os registros é tão curto, que provavelmente a pessoa se levantou para realizar uma outra atividade brevemente e voltou, dando continuidade à atividade anterior. Porém, caso o tempo entre os registros seja maior, entende-se que foram atividades que ocorreram em momentos distintos.

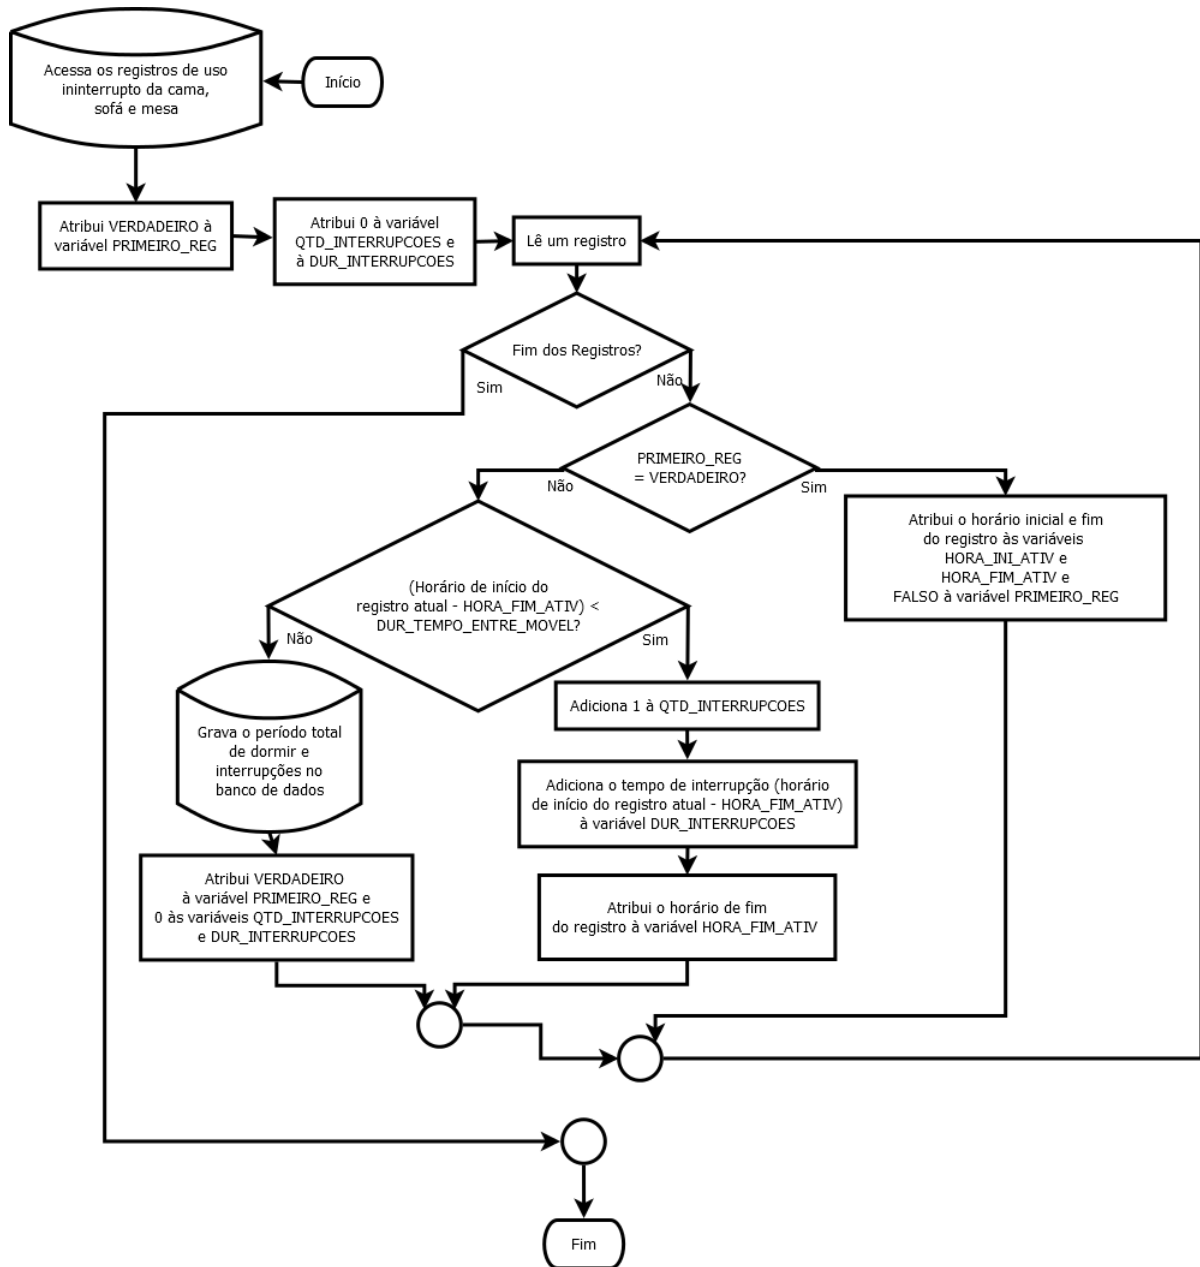


Figura 5.14: Alg06 - Verificação de prolongamento do uso de móveis relacionados com atividades de baixa emissão de sinais. Fonte: Autor

Ao final, o algoritmo atualiza no banco de dados os períodos de uso do sofá, cama e mesa, conforme pode ser visto no exemplo ilustrativo da Tabela 5.3.

Tabela 5.3: Dados sobre atividades com baixa emissão de sinais

Data	Móvel	Hora de Início	Hora de Término	Duração da Atividade	Quantidade de Interrupções	Tempo das Interrupções
01/10/2014	Cama	22:30:00	06:42:00	8:12:00	2	00:07:40
01/10/2014	Sofá	13:10:00	14:00:00	0:50:00	0	00:00:00
02/10/2014	Cama	22:00:00	06:00:00	8:00:00	1	00:03:00
...						
31/10/2014	Cama	23:00:00	06:10:00	7:10:00	1	00:04:12

Fonte: Autor

Submodelo 1.3: Contabilização de ativações dos sensores de movimentação e do tempo de presença da pessoa nos cômodos

O modelo busca identificar os cômodos da casa que são frequentados pela pessoa ao longo de todo o dia. Portanto, os próximos dois algoritmos têm como objetivo contabilizar a quantidade de acionamento de cada sensor, como também o tempo que a pessoa costuma frequentar cada cômodo da residência.

Alg07: Contabilização da quantidade de acionamento dos sensores de movimentação

Este algoritmo contabiliza, para cada hora do dia, a quantidade de acionamento de cada sensor de movimentação. Isto permite que os algoritmos de reconhecimento de padrões consigam perceber os horários em que os sensores são mais ou menos ativados, permitindo ao modelo inferir atividades que a pessoa costuma realizar.

O algoritmo pode ser visto na Figura 5.15 e funciona da seguinte forma: ele verifica se a pessoa está sozinha em casa e apenas em caso afirmativo, incrementa de 1, a quantidade de ativações do sensor para aquele intervalo de hora. Na Tabela 5.4 é possível visualizar um exemplo ilustrativo com os dados agrupados pelo algoritmo.

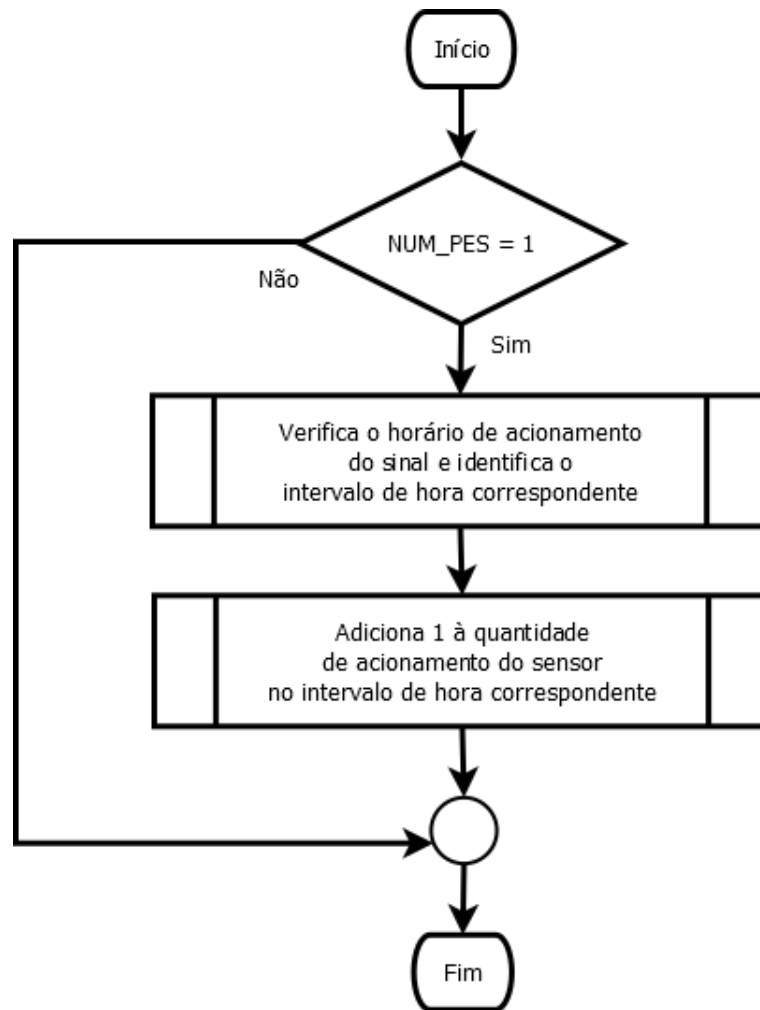


Figura 5.15: Alg07 - Contabilização do número de acionamento dos sensores, por intervalo de hora. Fonte: Autor

Tabela 5.4: Quantidade de acionamento dos sensores, por intervalo de hora

Data	Intervalo de Hora	Sensor	Qtde de Acionamentos
01/10/2014	05:00 às 06:00	Sensor da Cozinha	10
01/10/2014	05:00 às 06:00	Sensor da Sala	12
01/10/2014	05:00 às 06:00	Sensor da Mesa	8
...
31/10/2014	23:00 às 24:00	Sensor da Cama	17

Fonte: Autor

Alg08: Contabilização do tempo de presença da pessoa nos cômodos

O algoritmo tem como objetivo calcular o tempo que a pessoa fica em cada cômodo da

casa, para cada intervalo de hora e pode ser visualizado na Figura 5.16. O seu funcionamento ocorre da seguinte maneira: ele inicia verificando se o sensor recém-ativado está localizado em um cômodo diferente do sensor ativado anteriormente e em caso afirmativo, percebe-se que a pessoa se movimentou e mudou-se de cômodo. Neste momento, o algoritmo calcula o tempo que a pessoa esteve presente no cômodo anterior e grava no banco de dados. A Tabela 5.5 apresenta um exemplo ilustrativo com o resultado do algoritmo.

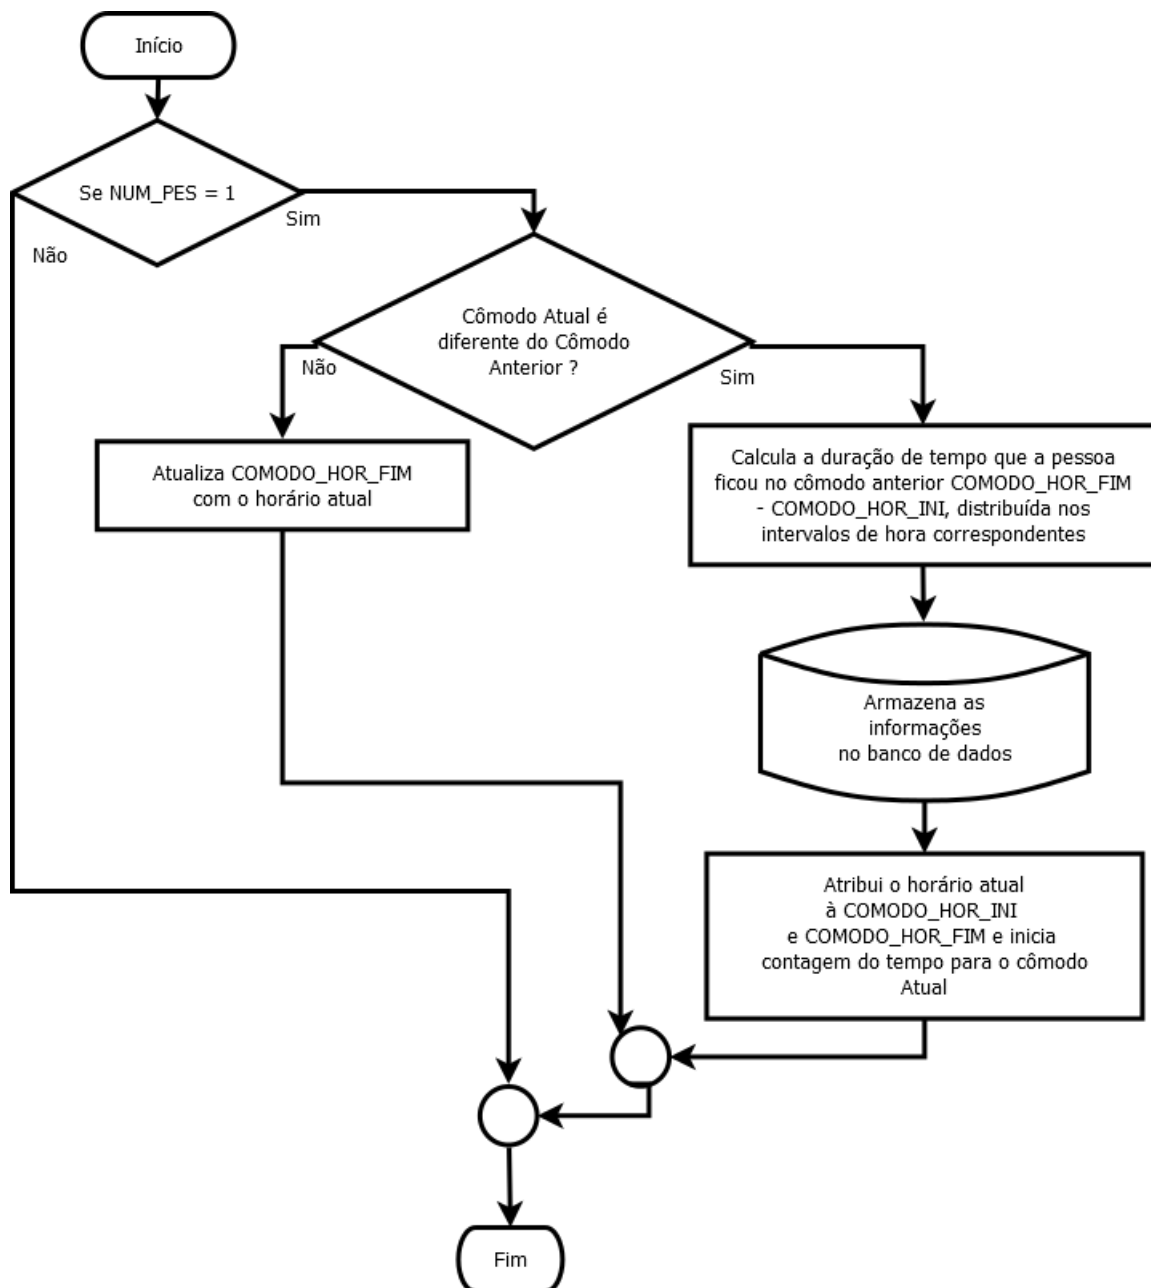


Figura 5.16: Alg08 - Contabilização do tempo presente nos cômodos, por intervalo de hora.
Fonte: Autor

Tabela 5.5: Período de presença da pessoa nos cômodos, por intervalo de hora

Data	Intervalo de Hora	Cômodo	Tempo (min)	Tempo (%)
01/10/2014	05:00 às 06:00	Sala	50	83,33
01/10/2014	05:00 às 06:00	Banheiro	10	16,67
01/10/2014	06:00 às 07:00	Quarto	30	50
...				
01/10/2014	20:00 às 21:00	Quarto	25	41,67

Fonte: Autor

5.4.3.2 Processo 2: Reconhecimento de Padrões

Este processo é executado ao final de cada dia e tem como objetivo atualizar os padrões de comportamento da pessoa, incluindo os dados pré-processados durante o dia e está segmentado em quatro submodelos, que podem ser visualizados na Figura 5.17.

O primeiro submodelo busca aprender os padrões de presença da pessoa em cada cômodo da residência; o segundo identifica os padrões sequenciais frequentes de movimentação por entre os cômodos da casa; o terceiro busca aprender padrões relacionados especificamente com as atividades de dormir e se alimentar; e o quarto, identifica padrões de movimentação de entrada e saída da residência.

É importante informar que o aprendizado dos padrões supracitados ocorre de forma segmentada, para cada hora do dia.

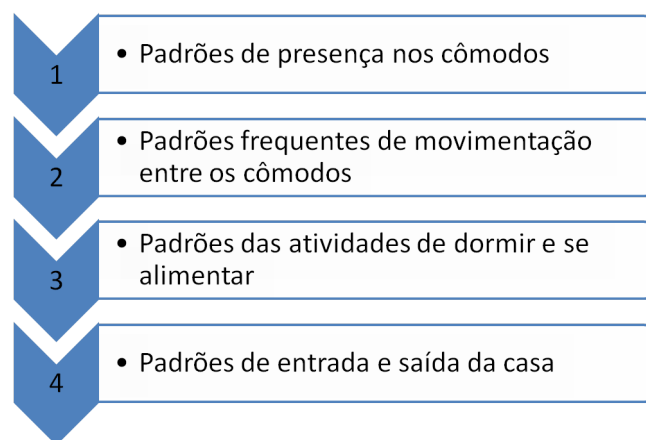


Figura 5.17: Submodelos que compõem o processo de reconhecimento de padrões. Fonte: Autor

Submodelo 2.1: Padrões de presença nos cômodos

Para um modelo que almeja monitorar as atividades de uma pessoa dentro da sua casa, se faz necessário conhecer os cômodos da casa que a pessoa mais frequenta, à cada hora do dia e para essa finalidade, é aplicado sobre os sinais de ativação dos sensores de movimentação de cada cômodo e móvel, um método de estimação de função densidade e neste caso, o estimador kernel.

Submodelo 2.2 - Padrões de movimentações frequentes por entre os cômodos da residência

Além da capacidade de estimar os locais da casa onde a pessoa costuma ficar, o modelo também identifica sequências frequentes de movimentação da pessoa por entre os diferentes cômodos e móveis da residência. Para essa finalidade, é executado um algoritmo de mineração de padrões sequenciais, o SPADE.

Contudo, para que o algoritmo SPADE possa ser executado de forma adequada, se faz necessário primeiro, adequar os dados disponíveis no modelo com a estrutura exigida pelo algoritmo, como definido a seguir:

- O *ID da Sequência* representa cada dia da série de dados.
- O *ID do Evento ou Transação* representa o horário de ativação do sensor.
- A *quantidade de itens da sequência* possui sempre o valor 1, já que cada ativação refere-se à apenas um único sensor.
- O *ID dos itens da sequência* apresenta o código do sensor ativado.

Vale a pena ressaltar que para cada execução do algoritmo, deve haver apenas sinais emitidos em um mesmo intervalo de hora. Na Tabela 5.6 é possível visualizar um exemplo ilustrativo com dados pré-configurados para a execução do algoritmo SPADE.

Tabela 5.6: Exemplo de dados pré-configurados para a execução do algoritmo SPADE. Intervalo das 06:00 às 07:00

ID da Sequência	ID do Evento	Qtde de Itens	Itens
01/01/2014	06:35	1	9
01/01/2014	06:42	1	2
01/01/2014	06:48	1	1
01/01/2014	06:53	1	4
02/01/2014	06:27	1	9
02/01/2014	06:40	1	2
...			
21/01/2014	06:50	1	4

Fonte: Autor

Submodelo 2.3: Padrões das atividades de dormir e se alimentar

As atividades de dormir e se alimentar são obrigatórias para todo ser humano e mudanças nos seus hábitos podem trazer riscos à sua saúde. De acordo com estudiosos da área, uma noite de sono atípica, principalmente em idosos, pode gerar sérios efeitos colaterais ao longo do seu dia, ficando a pessoa mais propensa à quedas ([WHO, 2004](#)).

Por essa razão, o modelo busca identificar os horários rotineiros de início e término dessas atividades, como também, a duração média de tempo que a pessoa costuma levar para realizá-las.

Para a identificação desses padrões, o modelo recupera os dados pré-processados pelos algoritmos do submodelo *1.2-Identificação de atividades com baixa emissão de sinais de movimentação* do Processo *Pré-Processamento de Dados* e aplica sobre eles, o estimador kernel.

Vale a pena salientar que no caso da atividade de dormir, o modelo não tem como afirmar que a pessoa está dormindo, ele consegue apenas afirmar que a pessoa esteve na cama durante o período compreendido entre o primeiro e o último acionamento do sensor da cama.

Os padrões relacionados com a alimentação são identificados com base na detecção da presença da pessoa à mesa durante os horários pré-definidos das principais refeições, que são informados pela própria pessoa antes do início do monitoramento.

Além da duração de tempo que a pessoa costuma levar para realizar as principais refeições,

o modelo também calcula a frequência com que elas ocorrem. Isto é necessário porque essas atividades são opcionais e nem sempre ocorrem dentro do domicílio. Na Tabela 5.7 é possível visualizar um exemplo ilustrativo com as frequências de algumas refeições.

Tabela 5.7: Frequência na realização das principais refeições em casa

Dia da Semana	Refeição	Frequência(%)
Segunda	Café da Manhã	90
Segunda	almoço	80
...
Geral	almoço	70
Geral	Jantar	30

Fonte: Autor

Submodelo 2.4: Movimentação de entrada e saída da residência

Por fim, um outro aspecto importante do comportamento da pessoa e que deve ser aprendido pelo modelo, refere-se aos padrões de movimentação de entrada e saída da residência, e principalmente, do tempo que a pessoa costuma ficar fora de casa.

Para tanto, o modelo recupera os dados pré-processados pelos algoritmos do submodelo 1.1-*Identificação do número de pessoas na casa* do Processo *Pré-Processamento de Dados* e aplica sobre eles, métodos de estatística descritiva.

5.4.3.3 Processo 3: Identificação de Situações Anormais

Este processo tem como objetivo verificar se o sinal recém importado se enquadra em duas categorias de situações consideradas críticas para o modelo: a primeira, que verifica situações consideradas de risco para a saúde da pessoa e a segunda, que busca identificar problemas com o funcionamento do sistema.

Submodelo 3.1: Situações consideradas de risco para a saúde da pessoa

O modelo distingue as situações de risco em duas categorias: a de risco iminente, que compreende situações que trazem algum risco imediato para a pessoa, como um possível mal súbito ou desmaio ou uma temperatura fora dos limites aceitáveis; e a de risco não iminente, que compreende algumas mudanças no comportamento da pessoa que podem levar

posteriormente a uma situação de risco à sua saúde, como mudanças no comportamento de dormir e de se alimentar.

Situações de Risco Iminente As situações consideradas de risco iminente podem ser vistas na Figura 5.18 e estão descritas a seguir:

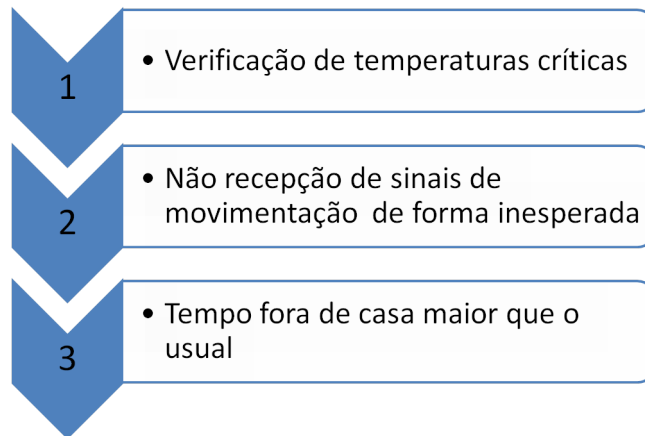


Figura 5.18: Situações de risco iminente à saúde da pessoa. Fonte: Autor

Alg09: Verificação de temperaturas críticas

Uma situação considerada crítica para uma pessoa, principalmente para um idoso, ocorre quando a temperatura do ambiente onde ele se encontra ultrapassa limites mínimos ou máximos aceitáveis, o que pode colocar em risco a sua saúde. Portanto esse algoritmo almeja detectar valores de temperatura na residência que estejam fora de limites aceitáveis.

O algoritmo em questão funciona da seguinte forma: ele verifica se o sinal é de um sensor de temperatura e em caso afirmativo, ele compara o valor da temperatura recém chegado da casa com os valores de temperatura aceitáveis e pré-configurados no modelo. Caso o valor importado esteja abaixo do limite inferior ou acima do limite superior, uma mensagem de alerta, informando o problema, é emitida. O algoritmo pode ser visto na Figura 5.19

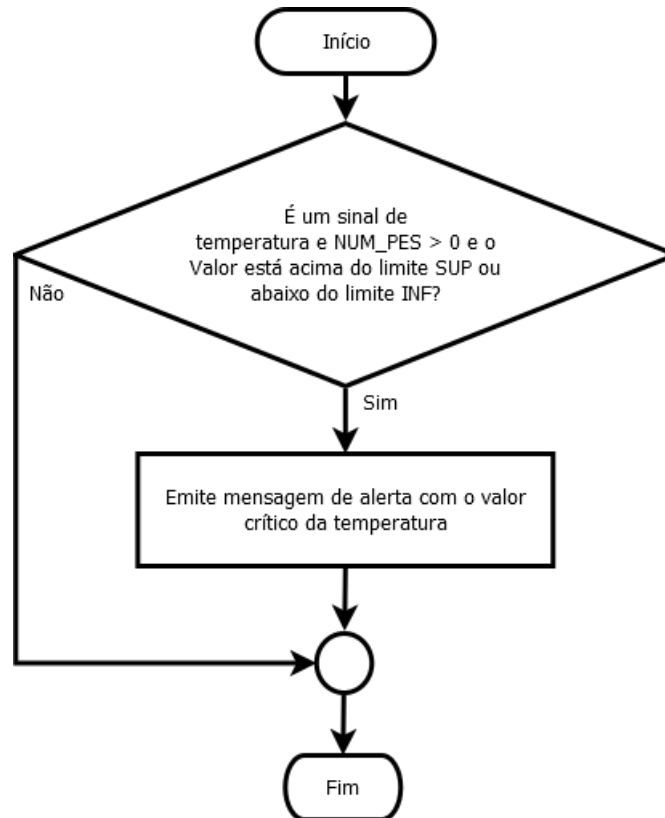


Figura 5.19: Alg09 - Verificação de valores críticos de temperatura. Fonte: Autor

Alg10: Não recepção de sinais de movimentação da residência de forma inesperada

Uma das situações consideradas mais críticas pelo modelo é quando param de chegar sinais de movimentação de forma inesperada, o que pode representar uma situação de desmaio ou queda, que impossibilite a pessoa de se mover e pedir ajuda. Para tanto, é necessário fazer uma distinção entre dois cenários.

O primeiro cenário ocorre quando a pessoa está sentada ou deitada em um sofá, mesa ou cama, passa mal e não consegue se levantar, ficando no local mais tempo do que o usual e esperado pelo modelo e o segundo cenário ocorre quando a pessoa está de pé, sofre uma queda e fica sem a capacidade de movimentação.

O algoritmo pode ser visto na Figura 5.20 e funciona da seguinte forma: quando o modelo detecta que o último sinal de movimentação foi enviado por um sensor localizado em um sofá, cama ou mesa, ele entende que a pessoa está provavelmente realizando alguma atividade com baixa ou nenhuma emissão de sinais, como dormir ou cochilar. Então, para que se configure uma situação de risco, o modelo precisa analisar o histórico de uso do referido móvel, no turno correspondente e caso perceba que a pessoa já está no local há mais tempo do que o limite máximo esperado, então um alerta é emitido.

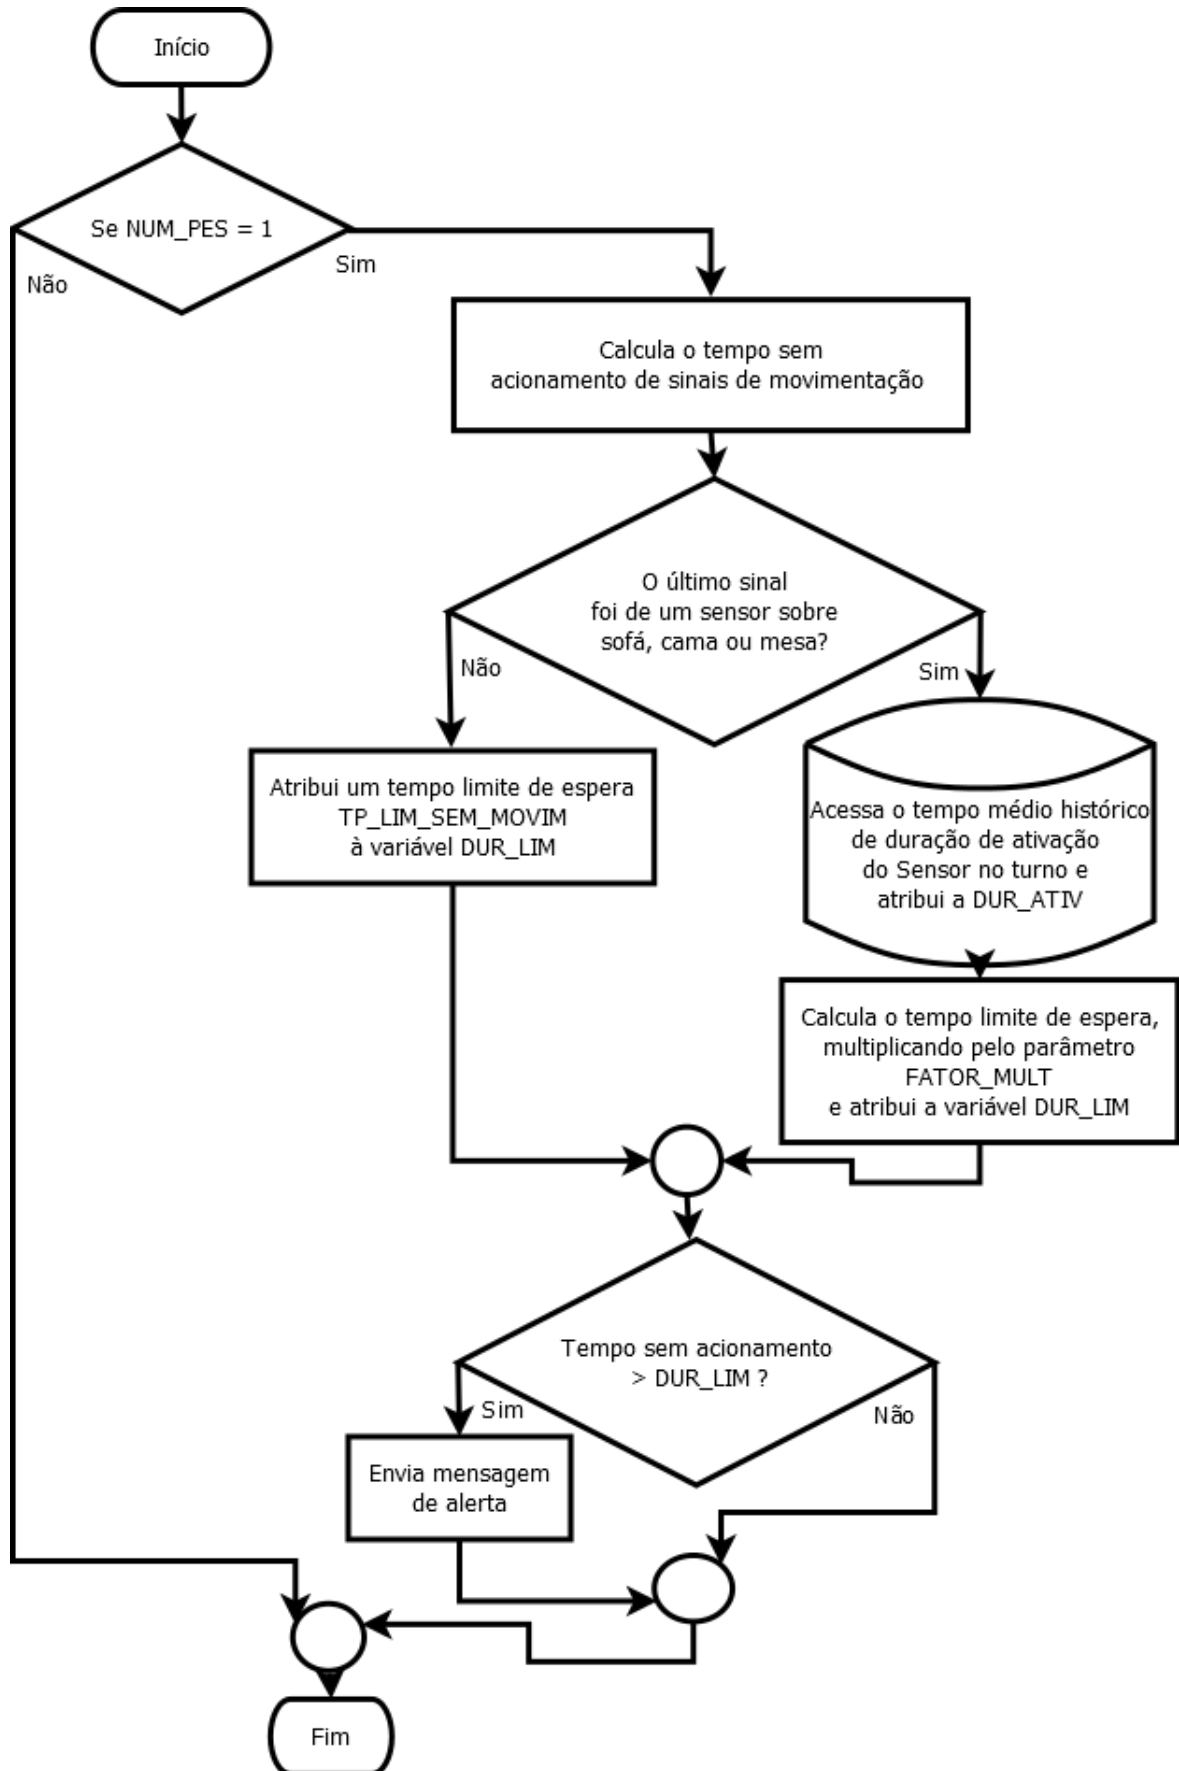


Figura 5.20: Alg10 - Não recepção de sinais de movimentação por um período maior do que o esperado. Fonte: Autor

O limite máximo esperado é calculado através da multiplicação do tempo médio que a pessoa usa o móvel pelo fator multiplicador FATOR_MULT.

Quando o modelo percebe que o último sinal de movimentação foi enviado por um sensor localizado em áreas onde a pessoa não costuma ficar parada por muito tempo, como locais de passagem ou locais onde são realizadas atividades com alta emissão de sinais, ele avalia se o intervalo de tempo desde a emissão do último sinal é maior do que o parâmetro TP_SEM_MOVIM e em caso afirmativo, um alerta é emitido.

Vale a pena salientar que o parâmetro TP_SEM_MOVIM deve ser configurado de acordo com a hígidez da pessoa monitorada, pois quanto menos hígida for a pessoa, menor deve ser o valor do parâmetro, isto porque provavelmente, menor deve ser o tempo que a pessoa costuma ficar em pé.

Alg11: Tempo Fora de Casa Maior que o Usual

Apesar do objetivo principal do modelo ter como foco a análise da movimentação da pessoa dentro do seu domicílio, ele tem a capacidade de detectar uma outra situação, que também pode ser de interesse dos familiares e amigos de idosos que vivem sozinhos, que é a percepção de que a pessoa saiu de casa e está demorando mais tempo que o usual para retornar.

O algoritmo pode ser visto na Figura 5.21 e funciona da seguinte forma: quando o modelo identifica que não há ninguém em casa, ele fica verificando se o tempo que a pessoa já se encontra fora da casa está dentro dos seus padrões rotineiros, para o respectivo turno do dia. Caso o algoritmo perceba que esse tempo é maior que o limite máximo esperado, então um alerta é emitido.

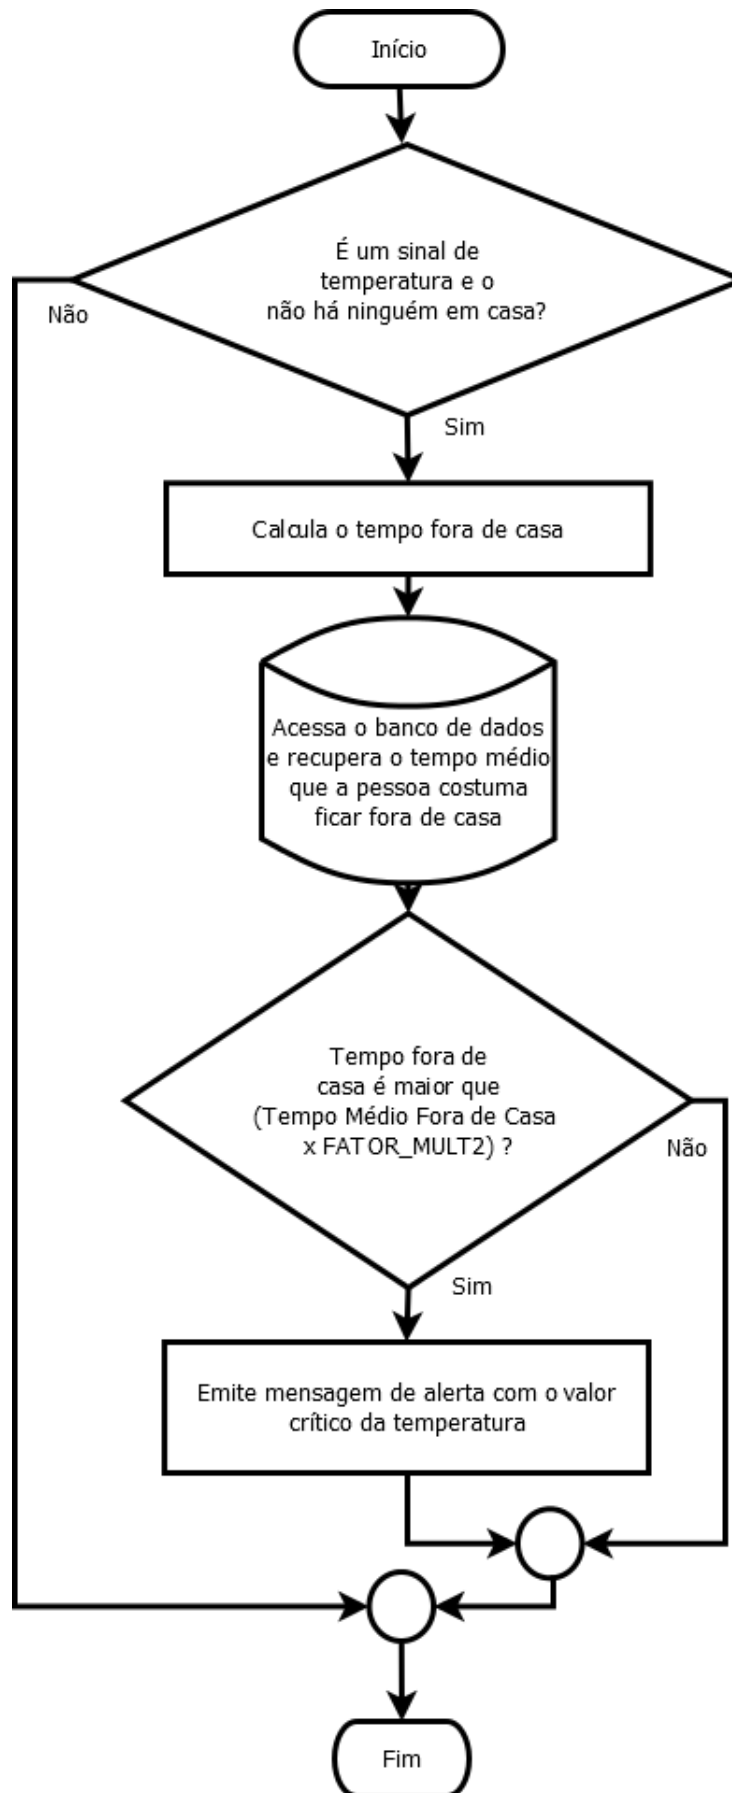


Figura 5.21: Alg11 - Verificação do tempo fora de casa. Fonte: Autor

Esse limite máximo esperado é calculado através da multiplicação do tempo médio que a pessoa costuma ficar fora de casa pelo fator multiplicador FATOR_MULT2.

Situações de Risco Não Iminente

Segundo [Tapia \(2003\)](#), estudiosos da área de geriatria afirmam que a percepção de mudanças em atividades cotidianas como dormir, se alimentar, se exercitar, dentre outras é muito valiosa para uma detecção antecipada de futuros problemas físicos e mentais.

Portanto, essa etapa possui um caráter preventivo e tem como objetivo perceber mudanças no comportamento da pessoa durante a realização de atividades consideradas chave para a sua saúde, como dormir e se alimentar.

Alg12: Mudanças de comportamento da atividade de dormir

O algoritmo busca detectar alterações em alguns aspectos relacionados com essa atividade, como mudanças no horário de dormir e de acordar, na duração de tempo da atividade e ainda, na quantidade e na duração dos despertares.

Para esse fim, o modelo faz uso de um método de detecção de *outliers*, o LoF (*Local Outlier Factor*), que é executado sobre os dados apresentados na Tabela 5.8.

Tabela 5.8: Aspectos da atividade de dormir identificados pelo modelo

Item	Descrição	Formato do dado
1	Horário de Dormir	hh:mm:ss
2	Horário de Acordar	hh:mm:ss
3	Tempo na Cama	hh:mm:ss
4	Tempo dos Despertares	hh:mm:ss
5	Quantidade de Despertares	inteiro

Fonte: Autor

Alg13: Mudanças de comportamento da atividade de se alimentar

Este algoritmo busca detectar uma situação considerada importante, que ocorre quando o modelo não consegue detectar a presença da pessoa à mesa nos horários habituais das suas principais refeições.

Para esse fim, o algoritmo inicia verificando se já passou o horário de alguma das principais refeições pré-definidas no modelo, sem que tenham sido detectados sinais do sensor da

mesa. Em caso afirmativo, ele verifica se a frequência da referida refeição, calculada na Etapa de *Reconhecimento de Padrões*, é maior que o parâmetro `FREQ_REFEICAO`, e em caso afirmativo, um alerta é emitido.

Submodelo 2: Verificação de mal funcionamento dos sensores

Como qualquer equipamento eletrônico, os sensores instalados na residência podem apresentar problemas e parar de funcionar. Portanto, essa etapa busca verificar se algum sensor de movimentação ou temperatura parou de funcionar e conseqüentemente, de enviar sinais.

No caso dos sensores de movimentação, o modelo consegue perceber falha de acionamento toda vez que é identificada uma sequência de ativação não reconhecida pelo grafo de sensores. Vale a pena salientar que o grafo de sensores é o elemento do modelo que armazena todos os possíveis caminhos por entre os cômodos da residência. Portanto, é ele quem conhece os possíveis sequenciamentos de ativação dos sensores de movimentação.

O algoritmo pode ser visto na Figura 5.22 e funciona da seguinte forma: ele verifica se o sinal é de um sensor de movimentação e se a pessoa está sozinha em casa e em caso afirmativo, verifica se o sinal atual e o imediatamente anterior são de sensores ligáveis no grafo. Em caso negativo, o modelo entende que houve uma falha, pois ou a pessoa se movimentou por um caminho desconhecido pelo modelo ou algum(uns) sensor(es) não funcionou(aram). Neste caso, o algoritmo realiza uma pesquisa no grafo de sensores para identificar quais foram os sensores que deveriam ter sido acionados e não foram. Por fim, um alerta é emitido para a central de monitoramento, contendo os identificadores desses sensores não ativados.

No caso do sensor de temperatura, como ele é programado para enviar um sinal a cada intervalo de tempo pré-determinado, a verificação de falhas é feita de forma distinta e um alerta é emitido para a central de monitoramento, sempre que o modelo não identificar sinais por um período maior do que o parâmetro **latência no envio dos sinais**.

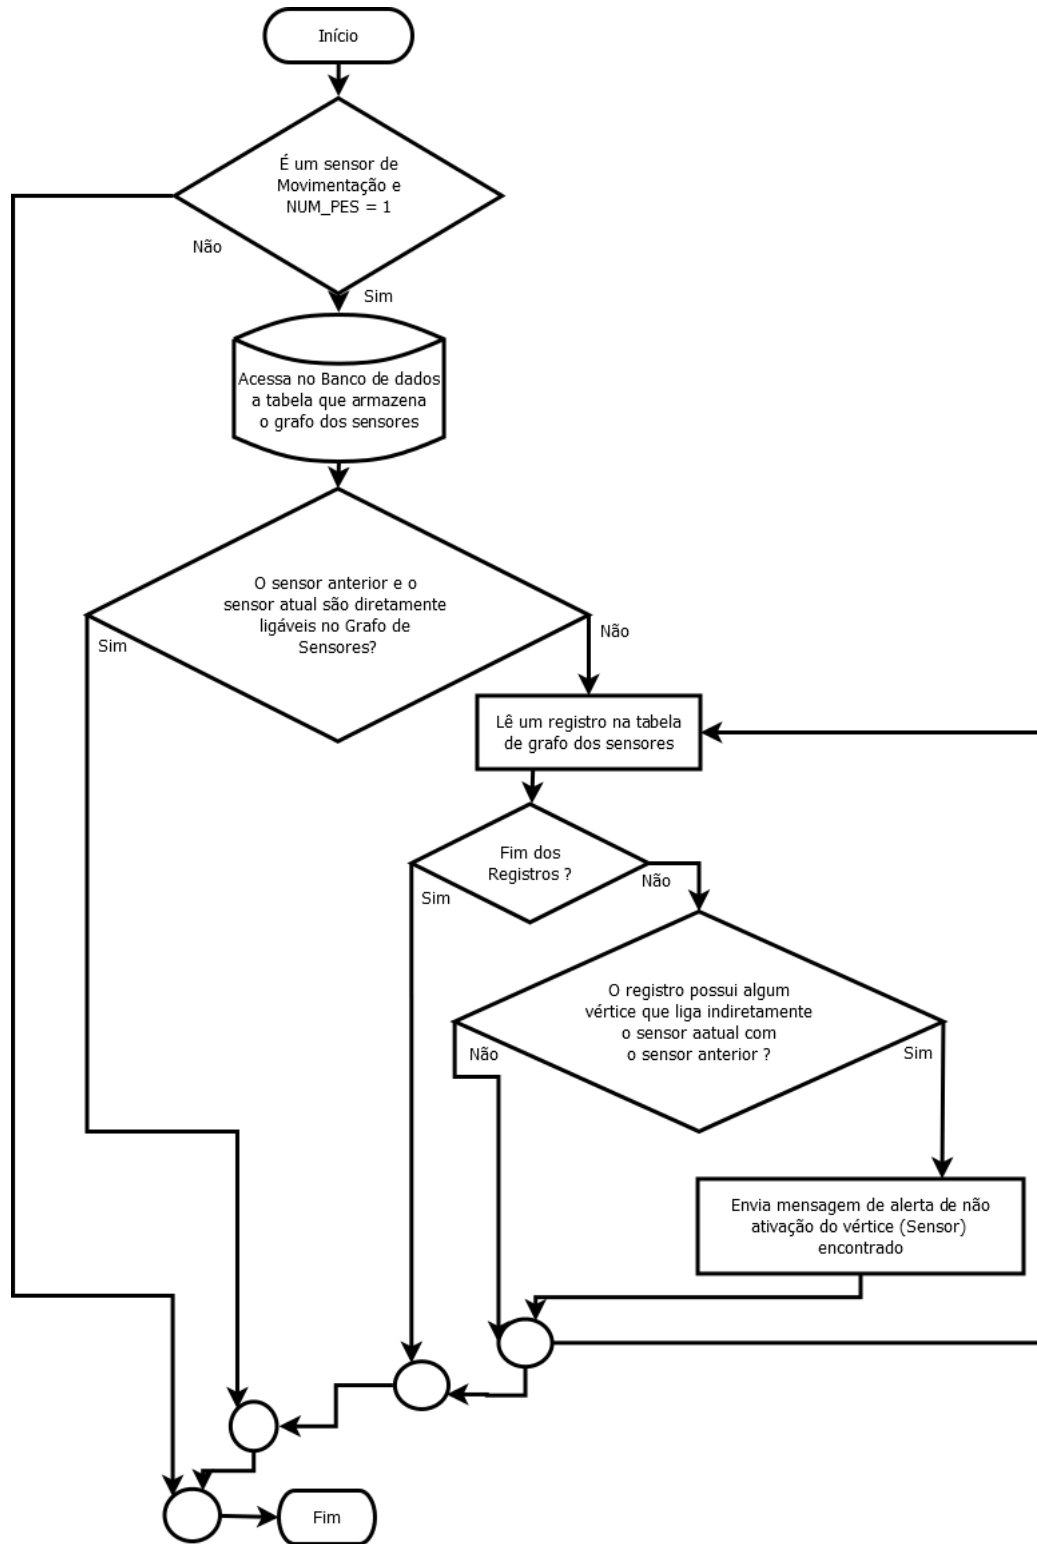


Figura 5.22: Alg12 - Verificação de inconsistência na sequência de ativação dos sensores de movimentação. Fonte: Autor

5.5 Conclusão

Este capítulo descreveu o modelo proposto, através do protocolo ODD. Inicialmente foi apresentada uma visão geral do modelo, com também suas entidades, variáveis e parâmetros. Posteriormente ele foi detalhado, sendo apresentadas suas entradas de dados, processo de inicialização e por fim os submodelos que o compõem.

A Tabela 5.9 apresenta uma lista contendo a relação entre as Questões/Hipóteses que norteiam esse trabalho e os métodos e técnicas utilizados no modelo.

Tabela 5.9: Mapeamento entre as Questões/Hipóteses do projeto e os métodos/técnicas utilizados para solucioná-las

Questão / Hipótese	Submodelo	Método ou Técnica Utilizada
1		
1.1	Reconhecimento de Padrões	Estatística Descritiva, Estimador kernel e SPADE
1.2	Reconhecimento de Padrões	Estatística Descritiva e Estimador kernel
1.3	Reconhecimento de Padrões	Estatística Descritiva e Estimador kernel
2		
2.1	Identificação de Situações Anormais	Estatística Descritiva
2.2	Identificação de Situações Anormais	Estatística Descritiva e Detecção de <i>outliers</i>
3		
3.1	Identificação de Situações Anormais	Estatística Descritiva e Teoria dos Grafos

Fonte: Autor

O próximo capítulo detalha os experimentos realizados com o modelo e os resultados encontrados.

Experimentos com o modelo

6.1 *Introdução*

Este capítulo tem como objetivo descrever alguns experimentos realizados com o modelo. Inicialmente é feita uma breve descrição dos primeiros testes realizados com dados extraídos de um ambiente virtual e posteriormente, são detalhados os experimentos realizados na casa de dois idosos que moram sozinhos e os resultados são apresentados e analisados.

6.2 *Experimentos com dados extraídos de uma simulação computacional baseada em agentes*

No início do projeto, quando a arquitetura física de monitoramento não havia sido ainda implementada, isto é, quando ainda não era possível a instalação dos dispositivos eletrônicos em uma residência, decidiu-se pela criação de um modelo de simulação computacional que pudesse simular o comportamento de um idoso dentro de um domicílio unipessoal e gerar dados da sua movimentação.

Este se tornou o objetivo de um trabalho de mestrado do programa, que foi proposto por [Almeida \(2013\)](#). Neste, foi criado um programa de simulação computacional baseada em agentes, que simula a realização de um conjunto de tarefas rotineiras de uma pessoa que mora em um domicílio unipessoal e grava a sua movimentação em um arquivo físico.

A partir desse programa, foi possível dar início ao processo de criação e testes dos algoritmos do modelo aqui proposto.

6.2.1 *Breve descrição do programa de simulação baseada em agentes*

Antes de iniciar a rotina de simulação, o programa exige que sejam cadastrados os horários habituais em que a pessoa costuma realizar atividades como dormir, acordar, tomar café, almoçar, tomar banho, etc. Essas informações são extraídas de um questionário, respondido pela própria pessoa monitorada.

Posteriormente, deve-se escolher ou criar uma planta baixa de uma casa e posicionar os agentes *sensores*, tanto os de movimentação, quanto o de temperatura, conforme pode ser visto no exemplo da Figura 6.1. Nela, é possível visualizar os cômodos e móveis de uma residência, como também os agentes *sensores de movimentação*, representados pelo *x* e o agente *sensor de temperatura*, representado pelo *o*.

A saber, no contexto de uma simulação computacional, um agente é uma entidade que possui objetivos e, para atingi-los, deve ser capaz de se comunicar com outros agentes e interagir com o ambiente no qual estão inseridos. (SIGNORETTI, 2012) apud (ALMEIDA, 2013)




Figura 6.1: Exemplo de uma planta baixa de uma casa e os sensores nela posicionados. Fonte: Almeida (2013)

O programa exige também uma configuração da *latência* e do *alcance* dos agentes sensores. A *latência* corresponde ao tempo mínimo entre duas ativações consecutivas de um mesmo sensor e o *alcance*, neste ambiente virtual, corresponde a uma área quadrada ao redor do sensor. Para exemplificar, um *alcance* com valor 2 compreende uma área ao redor do sensor de 2 *patches* em cada direção, conforme pode ser visto na Figura 6.2.

A saber, um *patch*, no contexto de uma simulação baseada em agentes, corresponde a um agente estático que cobre uma pequena área do ambiente modelado. Na Figura 6.2, ele está representado pelos quadrados em azul.




Figura 6.2: Área de alcance de um sensor de movimentação no ambiente virtual. Fonte: (ALMEIDA, 2013)

Ao iniciar a rotina de simulação, o programa cria um plano com as tarefas a serem realizadas pelo agente *idoso*, diariamente. Este começa então a se movimentar pela casa no intuito de realizar as tarefas programadas e ao passar pelo raio de alcance de algum agente *sensor de movimentação*, o programa grava em disco, dados dessa movimentação.

6.2.2 Análise acerca dos testes realizados com o uso do programa de simulação

Os testes realizados com dados extraídos do programa de simulação computacional realmente contribuíram para a construção dos algoritmos do modelo. Contudo, algumas observações devem ser feitas.

A primeira e mais relevante está relacionada com o fato de que o programa de simulação proposto por Almeida (2013) foi concebido para montar uma programação fixa de atividades realizadas por um idoso, diariamente, com base nas respostas de um questionário. Contudo, mesmo o programa tendo sido preparado para flexibilizar de uma certa forma, os horários de início e término das atividades, essa obrigatoriedade na realização das atividades, e ainda mais, dentro de determinadas faixas horárias, não condiz com as situações diversas e inesperadas que ocorrem em um ambiente real.

Uma outra questão também relevante, é que o programa não simula a presença de mais de uma pessoa dentro da casa, ele simula a casa com apenas uma pessoa ou vazia. Contudo, em um ambiente real, esse cenário é bastante comum e traz uma grande complexidade para o modelo.

Outro ponto a ser abordado diz respeito movimentação do agente *idoso*. No programa, ele sempre se movimenta de uma forma muito rápida por entre os cômodos da residência e a relação entre a velocidade do seu caminhar e a distância percorrida não são condizentes com a movimentação de uma pessoa em um ambiente real e este fato faz com que menos sinais de movimentação sejam gerados, trazendo consequências para o aprendizado do comportamento da pessoa.

Ainda relacionado com a movimentação do agente *idoso*, quando ele chega até o móvel para realizar uma atividade qualquer, seja dormir, tomar banho, cochilar ou almoçar, o agente *sensor* para de emitir sinais e só retoma quando a pessoa finaliza a atividade, o que não costuma ocorrer em um ambiente real, onde o sensor continua emitindo sinais, porém com uma frequência mais baixa.

Em linhas gerais, um ambiente real apresenta uma complexidade maior do que os cenários

simulados pelo programa proposto por Almeida (2013) e por essa razão percebeu-se a necessidade de experimentar o modelo em um ambiente real.

6.3 Experimentos com dados extraídos de ambientes reais

Após finalizada a implementação da arquitetura física de monitoramento, que é composta por um conjunto de dispositivos eletrônicos e uma rede de sensores sem fio (resultado do trabalho de mestrado do aluno Charles Soares, ainda em construção), foram escolhidos dois idosos que moram sozinhos para a realização dos experimentos, que estão descritos a seguir.

6.3.1 Características dos Idosos Monitorados

O idoso 1 possui 67 anos, é do sexo masculino e mora em um apartamento na cidade de Salvador. Ele apresenta uma deficiência visual bastante significativa, tendo perda total da capacidade visual de um olho e possui em torno de 10% da capacidade visual do outro olho; o idoso 2 tem 71 anos, é do sexo feminino e mora em uma casa na cidade de Camaçari.

A Tabela 6.1 apresenta um resumo com algumas questões respondidas pelos idosos quando da aplicação do questionário, antes do início do monitoramento.

Tabela 6.1: Resumo do questionário aplicado às pessoas monitoradas

Pergunta	Idoso 1	Idoso 2
Qual horário costuma dormir?	23h às 2h	24h à 1h
Qual horário costuma acordar? em dias úteis	5h às 6h	8h
Qual horário costuma acordar? nos fins de Semana e feriado	6h às 7h	8h às 9h
Quantas vezes costuma levantar durante a noite para ir ao banheiro ?	3 a 4	0
Qual(is) horário(s) costuma tirar cochilo?	10h às 11h 13h às 14h	Nenhum
Qual horário costuma tomar café da manhã?	6h às 7h (preparo) 7h às 8h (consumo)	8h às 8:30h 8h às 8:30h
Qual horário costuma almoçar?	13h às 14h Não costuma almoçar em casa	11h às 12h
Qual horário costuma jantar?	19h às 20h (preparo) 21h às 23h (consumo)	19h às 20 h 19h às 20 h
Qual(is) horários costuma assistir TV?	14h às 16h 17h às 1h	19h à 1h
Qual(is) horário(s) costuma tomar banho?	8h às 9h 21h às 22h	8:30h 17h às 18h
Qual(is) horário(s) costuma sair de casa ?	13h às 14h	Não específico Não específico
Qual(is) horários e frequência com que outras pessoas frequentam sua casa?	8h às 11h - Qui 18h às 22h - ter à Sáb	Seg à Sab (exceto Qui) Fins de Semana

Fonte: Autor

6.3.2 Inicialização do Modelo

6.3.2.1 Especificação e Configuração dos Ambientes

A Figura 6.3 apresenta os desenhos esquemáticos das duas residências monitoradas, com a representação dos cômodos, móveis e sensores neles instalados.

A residência (a) representa o apartamento do idoso 1, possui aproximadamente $40m^2$ e

contem quatro cômodos: uma sala, uma cozinha, um quarto e um banheiro. A residência (b) representa a casa do idoso 2, possui aproximadamente $90m^2$ e contém uma sala, uma cozinha, um quarto, um corredor, um banheiro e uma área de serviço. As áreas externas das residências não são monitoradas pelo modelo.

Os sensores de movimentação estão representados por números, que variam de 1 a 9, e o de temperatura, pelo T. Os círculos ao redor dos sensores de movimentação representam, de forma aproximada, o raio de alcance dos sensores.

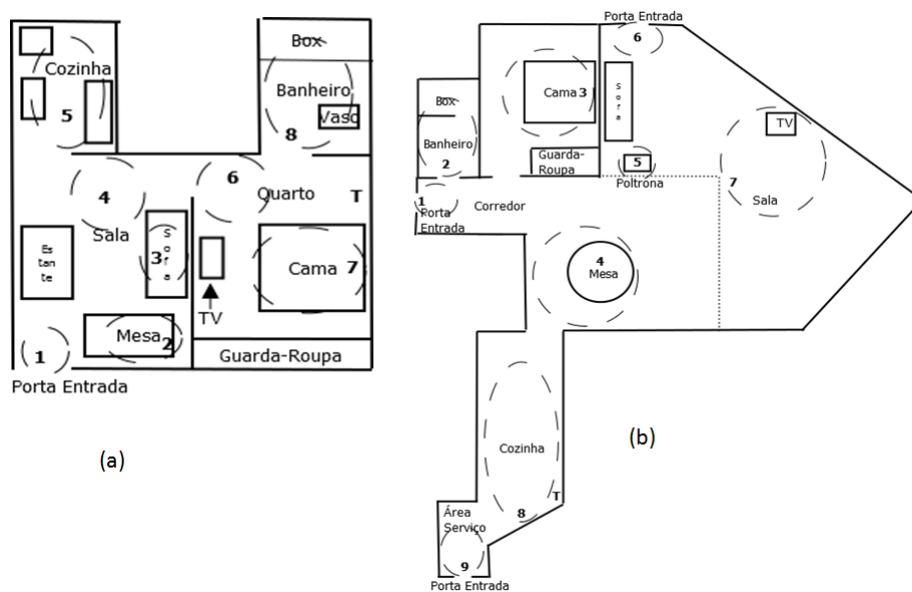


Figura 6.3: Residências monitoradas: (a) - Idoso 1 e (b) - Idoso 2. Fonte: Autor

Cada casa foi monitorada durante 25 dias e da casa do idoso 1, foram gerados 43.233 registros de movimentação e 21.070 de temperatura e da casa do idoso 2, 86.765 registros de movimentação e 20.880 de temperatura.

6.3.2.2 Configuração do grafo de sensores

A Tabela 6.2 apresenta informações dos sensores que estão presentes no grafo de sensores da casa dos dois idosos. Nela, é possível perceber, além da identificação dos sensores adjacentes, a distância aproximada entre suas áreas de cobertura. Percebe-se também que a quantidade de sensores adjacentes no grafo da casa do idoso 2 é maior do que a do idoso 1 e isso se justifica pelo fato da casa do idoso 2 ser maior do que a casa do idoso 1 e possuir cômodos maiores, gerando um maior número de caminhos entre os sensores.

Tabela 6.2: Relação dos sensores presentes no grafo de sensores da casa dos dois idosos

Idoso 1			Idoso 2		
ID Sensor 1	ID Sensor 2	Distância Aproximada (m)	ID Sensor 1	ID Sensor 2	Distância Aproximada (m)
1	2	1,50	1	2	0,50
1	3	2,0	1	3	2,00
1	4	2,5	1	4	2,00
2	3	0,5	1	5	2,50
2	4	2,0	1	7	3,00
3	4	1,0	2	3	2,00
3	4	1,0	2	4	3,00
4	5	0,5	2	5	3,50
4	6	0,5	2	7	4,00
6	7	1,0	3	4	2,50
6	8	1,5	3	5	2,50
7	8	1,0	3	7	3,00
			4	5	1,50
			4	7	1,50
			4	8	0,50
			5	6	2,50
			6	7	1,00
			8	9	1,00
			1	6	6,00
			1	9	6,00
			6	9	10,00

Fonte: Autor

6.3.2.3 Inicialização de parâmetros do modelo

Na Tabela 6.3 estão apresentados os valores iniciais dos parâmetros utilizados no modelo. Vale a pena salientar que esses valores foram propostos com base nos seguintes critérios: aparente higidez do idoso, tamanho da casa e distância entre os sensores de movimentação.

Tabela 6.3: Inicialização dos parâmetros utilizados no modelo

Parâmetro	idoso 1	Idoso 2
FATOR_MULT	2 desvios padrões da média	2 desvios padrões da média
FATOR_MULT2	2 desvios padrões da média	2 desvios padrões da média
NUM_PES	1	1
TP_ENTRE_USO_MOVEL	15'	15'
TP_MAX_ACIO	5"	5"
TP_MIN_SEM_ACIO	15'	15'
TP_SEM_MOV	15'	30'
TP_SIMULT	0"	1"
TP_SIMULT_EXT	60'	60'
TP_USO_MOVEL	5'	10'

Fonte: Autor

6.3.3 Padrões de Comportamento Encontrados

A seguir são apresentados os padrões de comportamento que o modelo foi capaz de aprender.

6.3.3.1 Padrões de Presença nos Cômodos e Móveis da Residência

As funções de estimação densidade das Figuras 6.4 e 6.5 apresentam, para cada hora do dia, a quantidade de ativações dos sensores de movimentação em cada cômodo e móvel monitorado, o que de uma certa forma, representa o padrão de movimentação da pessoa dentro da casa. A Figura 6.4 apresenta os padrões de movimentação de ambos os idosos na sala, cozinha e banheiro.

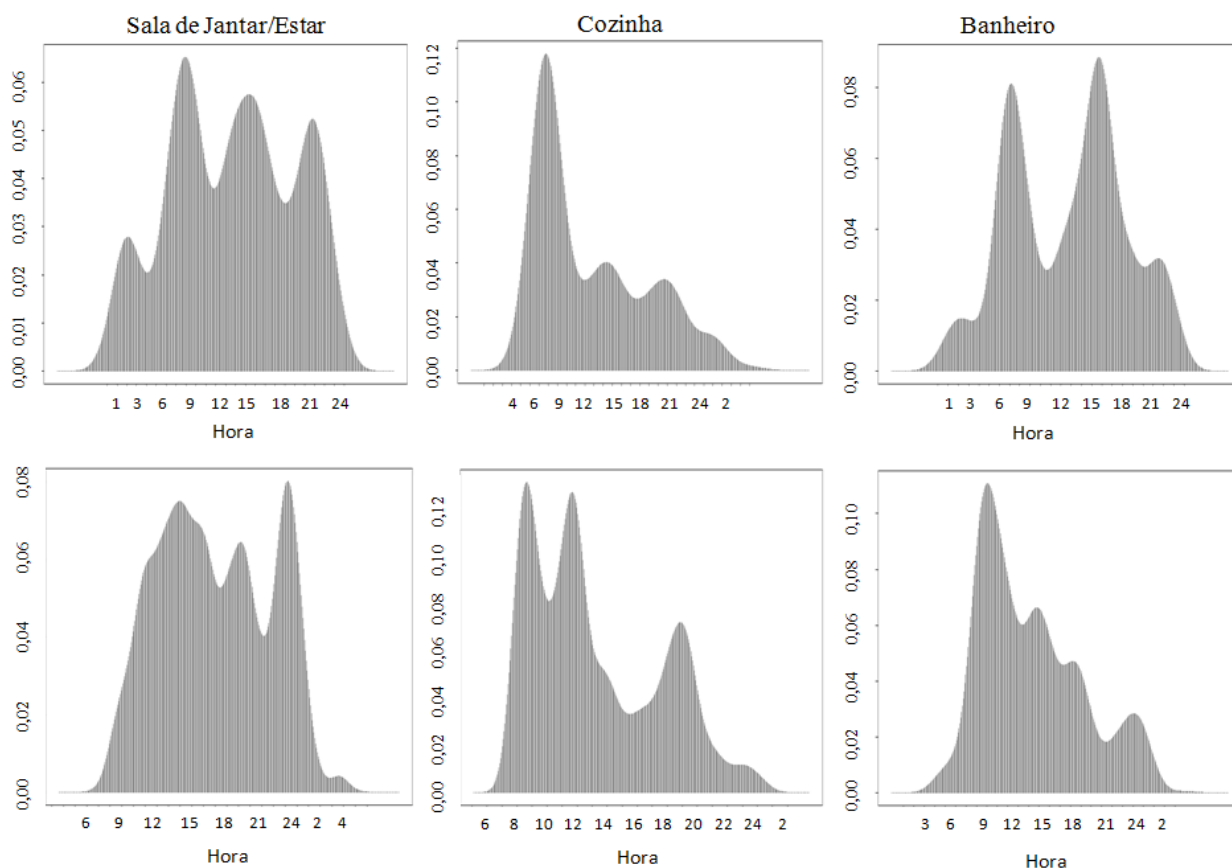


Figura 6.4: Densidade de ativações dos sensores instalados na sala, cozinha e banheiro. A largura de banda (h) foi calculada de forma automática através do algoritmo proposto por [Wand e Jones \(1995\)](#). Fonte: Autor

Sala de Estar/Jantar: Há uma presença constante de ambos os idosos na sala, ao longo de todo o dia. A função densidade do idoso 1 apresenta picos no início da manhã, meio da tarde, final da noite e uma pequena elevação na madrugada. O pico no início da manhã pode estar relacionado com o momento do café da manhã e os outros podem estar relacionados com atividades de entretenimento, já que o sofá e o computador ficam localizados na sala. Vale a pena ressaltar que apesar da significativa perda de visão que possui, o idoso afirma fazer uso do computador de forma constante.

Quanto ao idoso 2, percebe-se uma forte presença, e quase que contínua, durante todo o turno da tarde e da noite. Esse comportamento pode ser explicado por conta da realização de atividades relacionadas com a TV, o computador e a mesa. É importante mencionar que a presença durante o turno da manhã não é tão expressiva (e não somente na sala) por conta da presença da diarista. Isto porque o modelo para de aprender os padrões de comportamento quando detecta a presença de mais de uma pessoa na casa.

Cozinha: A função densidade do sensor da cozinha do idoso 1 apresenta um grande pico entre 7:00 e 9:00 e duas elevações discretas, uma no meio da tarde e outra durante a noite. O pico da manhã está consistente com o horário habitual de preparação do café da manhã. A elevação percebida durante a noite ocorre um pouco depois do horário de preparação do jantar, informado pelo idoso e a elevação no turno da tarde não possui nenhuma correspondência com as respostas do questionário.

Quanto ao idoso 2, é possível perceber dois grandes picos, um em torno das 8:00 e o outro, próximo do meio-dia. Eles estão em conformidade com os momentos de preparo do café da manhã e do almoço, conforme questionário e coincidem com o momento que antecede a chegada da diarista e posterior a sua saída. Uma outra elevação, porém um pouco mais discreta, pode ser percebida em torno das 19:00 e está de acordo com o momento de preparação do jantar.

Banheiro: O banheiro é utilizado pelo idoso 1, principalmente no início da manhã e no final da tarde. O pico no início da manhã pode estar relacionado com atividades habituais relacionadas com o momento do acordar e também com o horário do banho, conforme questionário. A discreta elevação percebida em torno das 22:00, também pode estar relacionada com o horário do banho. Contudo, o maior pico ocorre no final da tarde, mas não é possível fazer nenhuma associação com alguma atividade específica. Um aspecto que deve ser mencionado é quanto a uma pequena elevação percebida durante a madrugada, entre 1:00 e 5:00, que pode estar relacionada com os despertares noturnos do idoso.

O idoso 2 faz uso do banheiro, principalmente durante o turno da manhã, entre 8:00 e 9:00, que pode representar a realização de atividades relacionadas com o acordar e também com o momento do banho, conforme questionário. É possível observar outras três elevações menores, uma após o almoço, outra no final da tarde, que está condizente com outro horário do banho e uma última, no final da noite, que talvez esteja relacionada com a realização de atividades habituais que antecedem a atividade de dormir.

A Figura 6.5 apresenta as funções densidade de ativação dos sensores instalados na mesa e sofá/poltrona, de ambos os idosos.

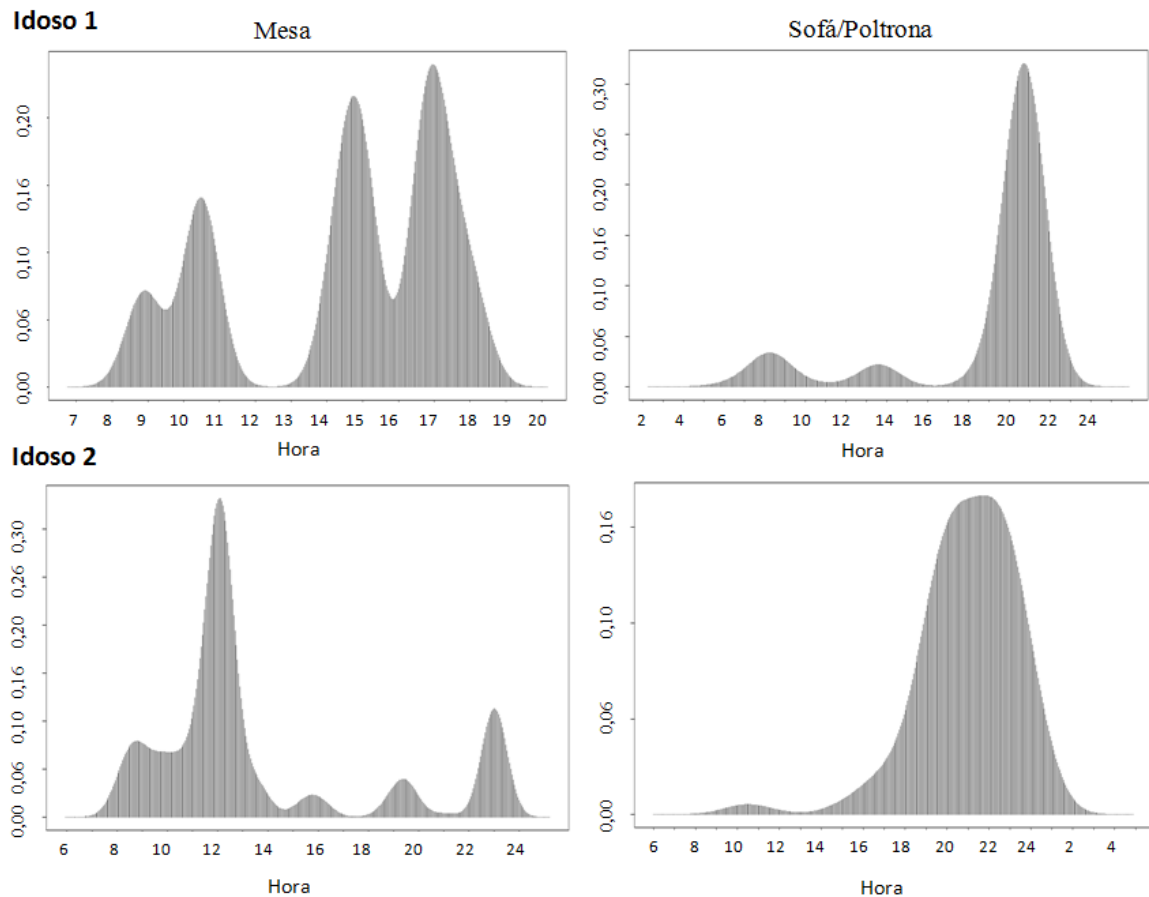


Figura 6.5: Densidade de ativações dos sensores da mesa e do sofá. A largura de banda (h) usada para o cálculo da função da mesa e do sofá foram 0,5 e 1,0, respectivamente. Fonte: Autor

Mesa: A presença do idoso 1 na mesa ocorre em vários momentos do dia, com uma pequena elevação em torno das 9:00, que pode representar o momento do café da manhã, apesar desse horário ser ligeiramente posterior ao reportado no questionário. É possível perceber também um pico em torno das 11:00 e outros dois, ao longo da tarde, que podem ser justificados pelo uso do computador. Quanto ao momento do jantar reportado pelo idoso, não foi possível detectar sua presença à mesa. Em relação ao almoço, conforme esperado, não foi detectada movimentação, já que o idoso não costuma almoçar em casa.

Percebe-se uma presença crescente do idoso 2 à mesa durante o turno da manhã, culminando com um pico no horário do almoço, em torno do meio-dia. A presença no início da manhã pode estar relacionada com o horário do café da manhã e o pico ao meio-dia, condiz com o horário do almoço. Apesar do idoso ter informado que tem como hábito jantar em casa, foi percebida apenas uma pequena movimentação no intervalo. Contudo, no final da noite, entre 23:00 e 24:00, percebe-se uma elevação mais acentuada, que talvez esteja relacionada com atividades de entretenimento, como o ato de assistir televisão.

Sofá/Poltrona: O idoso 1 informa que costuma tirar um cochilo no final da manhã, entre 10:00 e 11:00 e também no início da tarde, entre 13:00 e 14:00 e que o sofá, além da cama, é um dos locais onde ele costuma realizar essa atividade. Contudo, no sofá não foi percebida a sua presença durante esses intervalos. Entretanto, é perceptível uma acentuada movimentação no final da noite.

Quanto ao uso do sofá/poltrona por parte do idoso 2, observa-se uma acentuada presença durante toda a noite e esse comportamento condiz com o horário habitual de assistir TV, conforme questionário.

6.3.3.2 Padrões da Atividade de Dormir

A Figura 6.6 apresenta as funções densidade dos momentos de “dormir” e “acordar” dos idosos.

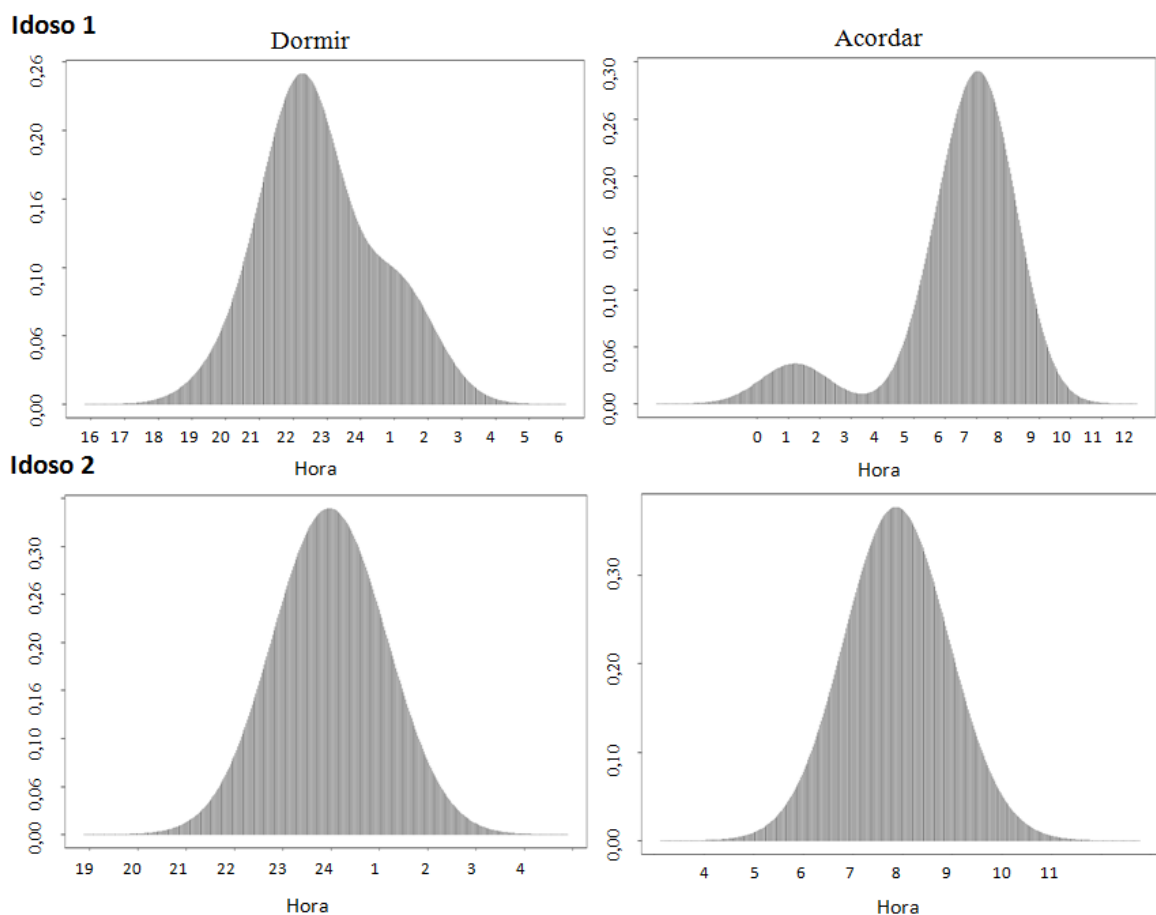


Figura 6.6: Funções Densidade dos horários habituais de “dormir” e “acordar” dos idosos. A largura de banda utilizada para o cálculo das funções foi 1,0. Fonte: Autor

No que diz respeito ao idoso 1, foi identificada a atividade de dormir em 21 dos 25 dias monitoradas. Em 2 dos 4 dias restantes, o idoso claramente não dormiu em casa, pois é possível perceber a sua saída da casa e o seu retorno no dia posterior, além de não ter sido detectado nenhum acionamento dos sensores de movimentação, durante esse período. Nos outros 2 dias, contudo, foram detectados sinais de sensores durante a madrugada, mas não foi possível identificar a atividade de dormir, e supõe-se que isso ocorreu, devido a algum tipo de falha no sistema de monitoramento.

Ele foi para a cama, em média, às 22:48, horário ligeiramente anterior ao intervalo informado no questionário. Quanto ao momento de acordar, ele se levantou, em média, às 6:58, o que está consistente com o horário informado. O tempo de duração na cama foi, em média, de 7 horas e 36 minutos, com um desvio padrão de 2 horas e 36 minutos. Em 43% dos dias, o idoso se levantou de 3 a 5 vezes durante a noite, valores compatíveis com a quantidade de despertares noturnos reportada.

Quanto ao idoso 2, foi percebida a atividade de dormir em 22 dos 25 dias monitorados. Em 2 dos 3 dias restantes, percebe-se que a pessoa não dormiu em casa, pois foi identificada uma movimentação de saída da casa e nenhum sinal dos sensores de movimentação foi percebido durante a noite e madrugada. Em uma única noite, porém, apesar de terem sido detectados sinais dos sensores ao longo da madrugada, o modelo não conseguiu identificar a atividade de dormir. Credita-se esse fato a possíveis falhas técnicas no sistema de monitoramento.

Ele foi para a cama, em média, às 23:58 e se levantou às 7:52, horários bem próximos daqueles informados no questionário. O tempo de duração na cama foi, em média, de 7 horas e 54 minutos, com um desvio padrão de 44 minutos. Em 72% dos dias, o idoso se levantou uma única vez durante a noite para ir ao banheiro, com uma duração em média de 1 minuto e meio. Essa informação difere do reportado pelo idoso, que afirma que não costuma ir ao banheiro durante a madrugada.

Com base nos dados acima, é possível perceber que o tempo médio de duração da atividade de dormir dos dois idosos é bem próximo, com uma diferença de menos de 20 minutos, porém, o desvio padrão do idoso 1 é bem maior do que o do idoso 2, o que demonstra uma regularidade maior do idoso 2 quanto ao tempo de realização da atividade.

6.3.3.3 Padrões de movimentação entre cômodos da residência, em alguns intervalos de hora

A Tabela 6.4 apresenta movimentações frequentes de ambos os idosos, entre os cômodos e móveis de suas residências, identificadas através do algoritmo SPADE. Vale a pena salientar que o valor do suporte mínimo utilizado foi de 55% para a identificação das sequências 1,2,3,6,7 e 8 e 20% para as sequências 4 e 5. Esses valores foram propostos de forma empírica, após sucessivas tentativas.

Tabela 6.4: Padrões de Movimentação entre os cômodos e móveis da residência

Seq	Pessoa	Intervalo	Padrão Sequencial	Suporte (%)
1	Idoso 1	07:00 - 08:00	Cama - > Banheiro - > Quarto - > Sala	68
2			Cama - > Quarto - > Sala	84
3		21:00 - 22:00	Sala - > Banheiro - > Cama	57
4	Idoso 2	04:00 - 05:00	Cama - > Banheiro - > Cama	23
5			Cama - > Banheiro - > Cama	27
6		08:00 - 09:00	Cama - > Banheiro - > Cozinha	91
7		23:00 - 24:00	Cozinha - > Banheiro - > Cama	68
8			Poltrona - > Banheiro - > Cama	59

Fonte: Autor

É possível perceber que em 84% dos dias monitoradas, entre às 07:00 e 08:00, o idoso 1 saiu da cama, caminhou pelo quarto e foi para a sala e, que em 68% dos dias, ele passou no banheiro, antes de ir para a sala. Essa movimentação demonstra um típico comportamento do momento de acordar e está compatível com o seu horário habitual de despertar. O intervalo das 21:00 às 22:00 apresenta um comportamento típico do momento de dormir, com uma frequência de 57%. Nele, percebe-se a saída do idoso da sala, passando pelo banheiro e indo depois para a cama.

De forma análoga, observam-se movimentações semelhantes do idoso 2, contudo, em intervalos de horários ligeiramente diferentes. Percebe-se que em 91% dos dias, entre 08:00 e 09:00, o idoso saiu da cama, passou no banheiro e foi para a cozinha, uma movimentação típica do momento de acordar. No intervalo entre 23:00 e 24:00, observa-se um comportamento condizente com o momento de dormir, com uma frequência de 68%. Vale a pena chamar a atenção para os intervalos das 04:00 às 05:00 e das 05:00 às 06:00. Percebe-se claramente os despertares noturnos do idoso, onde ele sai da cama, vai ao banheiro e retorna para a cama.

Com base nas informações apresentadas na Tabela 6.4, percebe-se que os suportes das movimentações do idoso 2, pelo menos no início da manhã e no final da noite, são maiores do que as do idoso 1 e isto demonstra uma maior regularidade do comportamento do idoso 2.

6.3.3.4 Padrões de entrada e saída da residência

No que diz respeito aos padrões de movimentação de entrada e saída do idoso 1, o modelo identificou que ele saiu de casa em 100% dos dias monitorados, com uma média de 2,52 saídas por dia e uma duração média de aproximadamente 2 horas e 41 minutos, fora de casa. O cálculo dessa duração não leva em conta os dias em que o idoso dormiu fora de casa.

De acordo com a Figura 6.7, movimentações de saída do idoso 1 podem ser percebidas ao longo de todo o dia, com uma incidência maior durante o turno da manhã e principalmente durante à tarde, correspondendo estas, a 84% de sua movimentação. Durante o intervalo das 11:00 às 14:00, horário de almoço do idoso, ocorreram 17% das ocorrências de saída.

Foram percebidas saídas do idoso 2 em 56% dos dias monitorados, com uma duração média de 2 horas e 15 minutos, fora de casa. O cálculo dessa duração também não leva em conta os dias em que o idoso dormiu fora de casa. Na Figura 6.7 é possível perceber que a maior incidência da saída do idoso 2 ocorre no turno da tarde.




Figura 6.7: Horários habituais de saída da casa. Idoso 1 à esquerda e o idoso 2 à direita. Fonte: Autor

A presença de mais de uma pessoa na casa do idoso 1 foi detectada em 44% dos dias monitorados, podendo ser percebida em praticamente todos os dias da semana, com exceção

das quartas-feiras. A presença às segundas-feiras pode estar relacionada com a visita da diarista, que de acordo com o idoso, frequenta a sua casa quinzenalmente.

Na casa do idoso 2 foi identificada a presença de mais de uma pessoa em 80% dos dias, que pode ser justificada pela presença da diarista, que trabalha durante cinco dias da semana, sempre no turno da manhã e também pela presença dos familiares, nos finais de semana.

A Figura 6.8 apresenta a quantidade de ativações consideradas simultâneas na casa de ambos os idosos, para cada hora de todos os dias monitorados.

Percebe-se uma quantidade e uma frequência maior de sinais simultâneos na casa do idoso 2 em comparação com a casa do idoso 1 e isto justifica-se pela presença mais constante da diarista e, provavelmente, de familiares e amigos. Vale ressaltar que essa é uma das razões para a grande diferença entre a quantidade de sinais de movimentação gerados da casa dos dois idosos. A casa do idoso 2 gerou mais que o dobro de sinais que a casa do idoso 1.

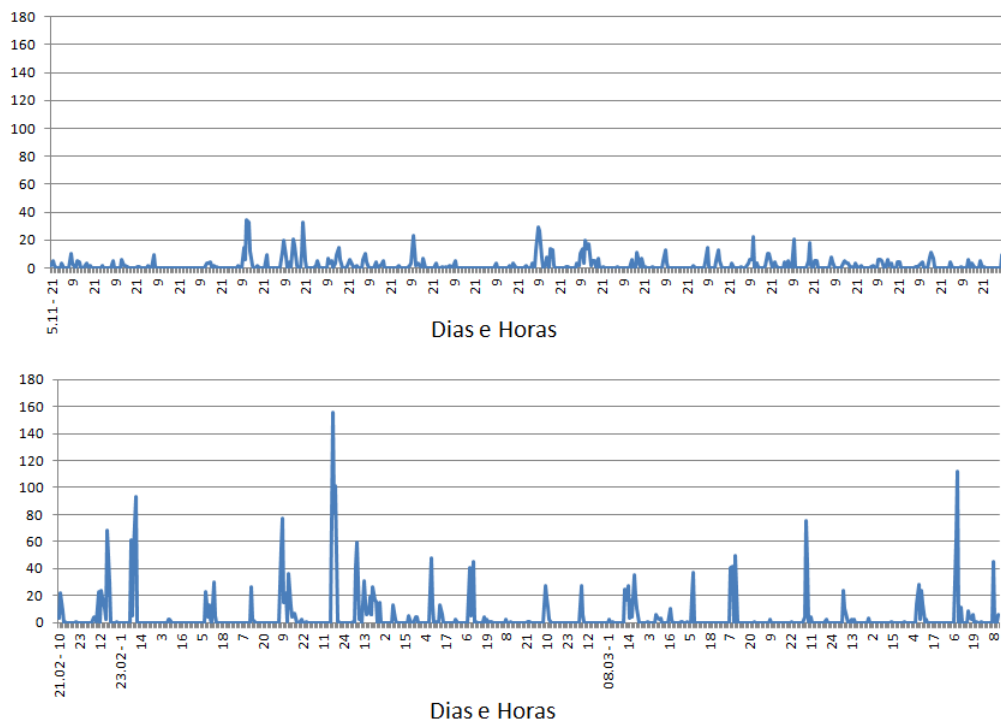


Figura 6.8: Quantidade de ativações simultâneas para cada hora, durante todos dias monitorados. Fonte: Autor

6.3.4 Situações Anormais Encontradas

Além da descoberta de alguns padrões de comportamento dos idosos, o modelo também demonstrou a capacidade de identificar situações consideradas críticas para a saúde dos idosos e para o funcionamento do sistema.

6.3.4.1 Situações de Risco Iminente

Risco de queda ou desmaio: Durante os dias monitorados, o modelo gerou muitos alertas de risco iminente para ambos os idosos. Contudo, nenhum deles representou de fato uma situação de desmaio ou queda, e a principal causa desses falsos alarmes, foram os pontos cegos existentes dentro das casas, principalmente na casa do idoso 2, além de problemas técnicos no sistema de monitoramento, como falta de energia e falha nos sensores.

Porém, alguns alertas poderiam ter representado uma situação de risco iminente, como por exemplo, em uma madrugada na casa do idoso 1, o modelo identificou a sua presença no banheiro durante mais de 4 horas ininterruptamente e com uma baixa de emissão de sinais, um comportamento completamente atípico. O modelo também alertou quanto a ausência de ambos os idosos nas suas casas, durante um período maior do que o usual. Isto ocorreu todas as vezes em que os idosos dormiram fora de casa.

Temperaturas Críticas: Na casa do idoso 1 não foram detectadas temperaturas críticas, apenas temperaturas que variaram entre 22 e 28 graus, o que já era esperado. Vale salientar que o valor mínimo identificado, 22 graus, foi em decorrência do uso do ar condicionado.

Em contra-partida, na casa do idoso 2, foram detectadas temperaturas inesperadas, que variaram de 18 a 50 graus. Contudo, o idoso não relatou nenhuma queixa quanto à percepção dessas temperaturas. Portanto, acredita-se que elas foram causadas por falha no sensor ou pelo fato dele ter sido instalado na cozinha da casa, apesar de ter sido mantida uma distância do fogão, de aproximadamente 4 metros.

6.3.4.2 Identificação de Situações de Risco Não Iminente

Atividade de Dormir: Com o objetivo de tentar identificar mudanças em aspectos importantes da atividade de dormir, foi aplicado o algoritmo de detecção de *outliers*, LoF, sobre os dados apresentados nas Tabelas 6.5 e 6.6. Cada linha dessas tabelas apresenta

aspectos da atividade de dormir de uma única noite.

Tabela 6.5: Dados pré-processados da atividade de dormir do idoso 1

Seq	Horário de Dormir	Horário de Acordar	Tempo na Cama	Tempo de Interrupções	Quantidade de Interrupções
1	22:43:30	07:32:48	08:59:18	00:16:11	3
2	21:53:44	07:00:48	09:05:32	00:01:32	1
3	21:34:29	06:16:55	08:32:29	00:09:57	4
4	19:50:13	06:20:22	10:30:09	00:17:30	1
5	23:08:03	08:06:05	08:38:20	00:19:42	4
6	00:53:37	07:34:29	06:23:51	00:00:00	0
7	22:30:41	00:48:48	01:58:44	00:19:23	0
8	22:49:39	07:11:42	08:17:13	00:04:50	1
9	00:43:22	07:15:28	06:15:26	00:16:40	3
10	01:00:43	01:36:45	00:33:07	00:02:55	1
11	21:05:39	05:41:34	08:35:55	00:00:00	0
12	21:46:31	07:49:48	09:44:37	00:18:40	4
13	21:54:24	07:12:30	08:56:53	00:21:33	4
14	22:04:04	06:55:39	08:28:03	00:03:32	2
15	23:03:07	06:05:52	07:01:04	00:01:41	1
16	22:35:34	06:07:50	07:29:37	00:02:39	2
17	02:03:43	05:48:25	03:06:15	00:38:27	5
18	21:55:21	07:53:04	09:48:25	00:09:18	2
19	01:14:07	07:16:22	05:57:55	00:04:20	3
20	21:07:11	07:11:25	10:04:14	00:00:00	0
21	22:34:54	07:02:02	07:35:00	00:51:07	4

Fonte: Autor

Tabela 6.6: Dados pré-processados da atividade de dormir do idoso 2

Seq	Horário de Dormir	Horário de Acordar	Tempo na Cama	Tempo de Interrupções	Quantidade de Interrupções
1	00:08:19	08:39:40	08:31:21	00:00:00	2
2	00:53:45	07:46:45	06:53:00	00:00:00	0
3	23:16:30	07:49:47	08:33:17	00:00:00	0
4	23:46:48	07:49:32	08:02:44	00:01:18	1
5	23:30:46	07:47:01	08:13:18	00:02:57	1
6	00:51:10	07:50:31	06:57:25	00:01:56	1
7	00:28:21	08:46:17	08:16:07	00:01:49	1
8	23:24:53	07:43:50	08:17:48	00:01:09	1
9	23:39:14	07:47:06	08:06:15	00:01:37	1
10	00:23:19	08:00:29	07:35:17	00:01:53	1
11	23:50:18	08:02:07	08:10:31	00:01:18	1
12	00:40:07	07:07:46	06:27:39	00:00:00	0
13	22:53:30	08:32:06	09:37:31	00:01:05	1
14	00:00:33	07:43:41	07:41:26	00:01:42	1
15	00:15:16	07:50:53	07:33:55	00:01:42	1
16	23:50:00	07:49:21	07:58:00	00:01:21	1
17	23:34:12	08:16:15	08:40:39	00:01:24	1
18	23:56:30	07:50:17	07:52:25	00:01:22	1
19	00:43:48	07:23:27	06:39:39	00:00:00	0
20	23:21:56	07:49:47	08:27:51	00:01:14	1
21	00:51:11	08:23:45	07:31:01	00:00:00	0
22	23:04:21	07:40:23	08:36:02	00:00:00	0

Fonte: Autor

Os resultados da aplicação do algoritmo LoF, para ambos os idosos, podem ser vistos na Figura 6.9. Para o idoso 1 é possível perceber três pontos que se distanciam dos demais, os pontos 7, 10 e 17. Estes representam noites cujo comportamento do idoso foi bem diferente em relação às outras noites, principalmente no que tange ao tempo de duração da atividade. O tempo médio do idoso 1 na cama girou em torno de 7 horas e 36 minutos, mas durante essas três noites, foi de aproximadamente, 2 horas, 33 minutos e 3 horas, respectivamente.

No caso do idoso 2 são percebidas pequenas variações em três pontos, 2, 12 e 19 e todos apresentam a mesma característica, que é um tempo na cama um pouco menor que 7 horas. Contudo, não apresentam mudanças significativas.

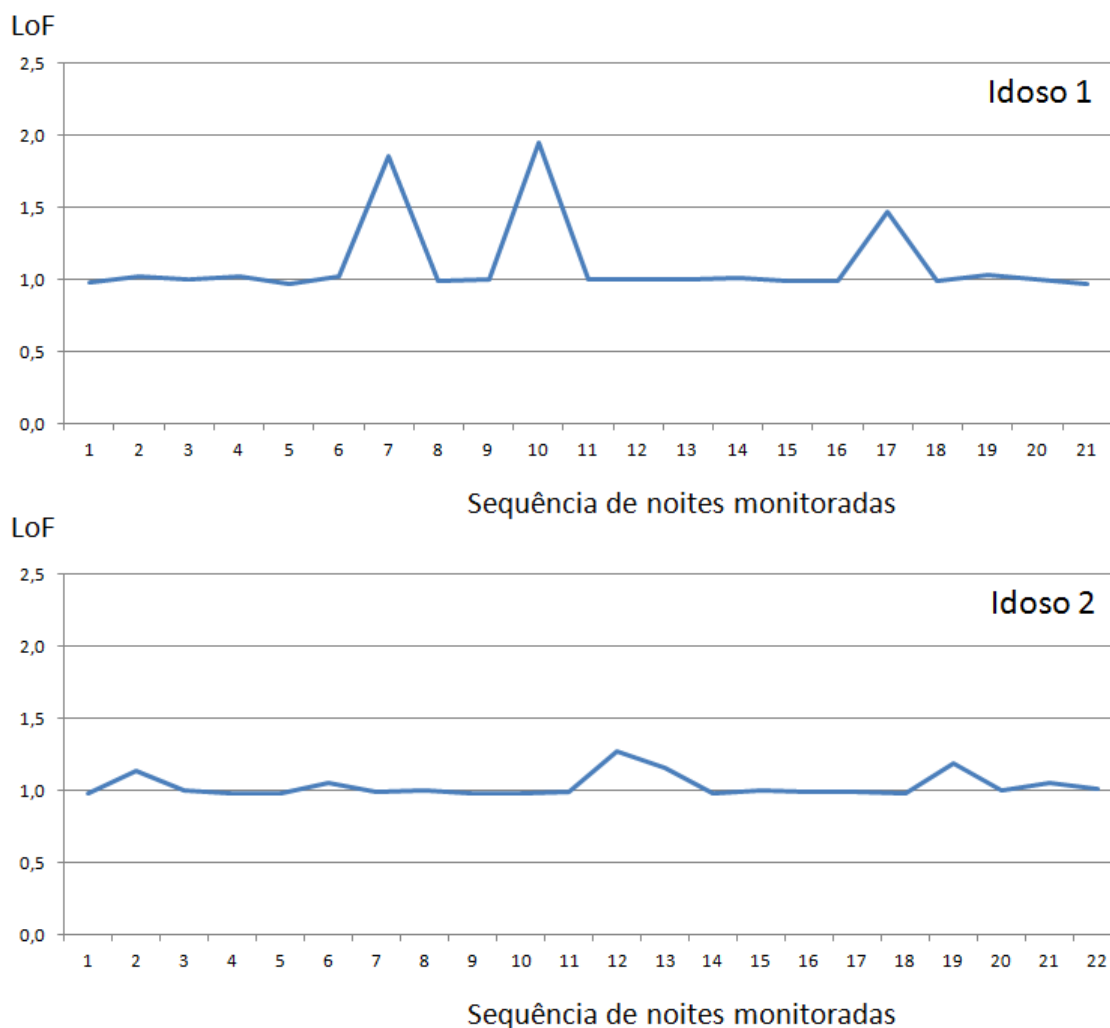


Figura 6.9: Resultado da aplicação do algoritmo LoF sobre dados da atividade de dormir do idoso 1 (acima) e idoso 2 (abaixo). Fonte: Autor

Os dados apresentados acima corroboram com a percepção de que o idoso 2 possui uma maior regularidade de comportamento em relação ao idoso 1.

Atividades relacionadas com a alimentação: O idoso 1 informou que não costuma almoçar em casa, mas tem o hábito de tomar café da manhã e jantar. Entretanto, em 77% dos dias, o modelo não conseguiu identificar o momento do café da manhã e em 53%, o momento do jantar.

No caso do idoso 2, apesar dele informar que faz todas as principais refeições em casa, o modelo não conseguiu identificar o momento do café da manhã, almoço e jantar em 76%, 60% e 72% dos dias, respectivamente. No que diz respeito ao café da manhã e o almoço, acredita-se que a presença da diarista contribuiu para essa baixa capacidade de aprendizado, pois como já exposto, o modelo para de aprender os padrões quando percebe

que há mais de uma pessoa na casa. Quanto ao jantar, o valor justifica-se pelo fato do idoso não realizar a atividade, habitualmente, na mesa, mas na poltrona da sala.

É importante lembrar que o modelo não tem como garantir que a pessoa fez uma refeição, ele apenas deduz a realização da atividade, sempre que percebe a presença da pessoa na mesa, durante o momento esperado da refeição.

6.3.5 Inconsistência na ativação dos sensores de movimentação

Foram gerados inúmeros alertas de falhas no sequenciamento dos sinais de movimentação, em ambas as casas e percebeu-se que a principal causa está relacionada com a configuração da área de cobertura de alguns sensores, que demonstraram serem insuficientes, e principalmente dos sensores que ficam em locais de passagem. Falhas técnicas nos sensores também podem ter sido a causa de alguns desses alertas.

6.4 Conclusão

Este capítulo apresentou alguns experimentos realizados com o modelo. Inicialmente, foi feita uma breve descrição de experimentos realizados com dados extraídos de uma simulação virtual e a importância deles para a construção dos algoritmos do modelo aqui proposto. Posteriormente, foram detalhados dois experimentos realizados com dados capturados da residência de dois idosos que moram sozinhos e os padrões de comportamento encontrados, como também algumas situações de risco identificadas, foram apresentados e analisados.

No próximo capítulo são apresentadas algumas considerações acerca do projeto.

Considerações finais

7.1 Conclusões

As hipóteses que nortearam esse trabalho traduziram a expectativa que os autores tinham quanto a possibilidade de criar um modelo computacional capaz de aprender os hábitos de uma pessoa que mora sozinha, utilizando tão somente dados gerados por sensores de ambiente e de baixo custo, como o *PIR* e o de temperatura, e que mesmo com as suas imprecisões, ainda assim, fosse possível aprender determinados comportamentos rotineiros da pessoa e identificar algumas situações de risco.

Em resposta à Questão 1, da Seção 1.6, é possível afirmar que o modelo foi capaz de identificar, para cada hora do dia, os ambientes da casa onde as pessoas monitoradas mais costumam ficar, além de identificar alguns dos seus padrões frequentes de movimentação por entre os cômodos e móveis das residências. Essas informações são importantes para um sistema de monitoramento domiciliar, pois elas permitem estimar a probabilidade de encontrar as pessoas nos ambientes na casa, a cada hora do dia.

Quanto à atividade de dormir, o modelo conseguiu identificar diversos aspectos importantes, como o horário habitual de ir para cama, de levantar, o tempo na cama, a quantidade de despertares e o tempo desses despertares. Além disso, o modelo conseguiu também perceber os dias em que as pessoas não dormiram em casa. Entretanto, durante algumas noites, o modelo não foi capaz de detectar a atividade de dormir de ambos os idosos, mesmo tendo sido identificados sinais nas residências. Essas falhas podem ser creditadas a problemas técnicos no sistema de monitoramento.

Quanto a questão da alimentação, o modelo não foi capaz de identificar, de forma consistente, os horários de realização das principais refeições, como o almoço, o café da manhã e o jantar.

De uma forma geral, o modelo conseguiu detectar a movimentação de entrada e saída dos idosos em suas casas. Contudo, a percepção da presença de mais de uma pessoa na casa não ocorreu de forma precisa, se tornando uma das maiores dificuldades encontradas durante o processo de aprendizagem. E isto se deve a dois aspectos: o primeiro está relacionado com a sobreposição das áreas de cobertura de alguns sensores, principalmente, em ambientes pequenos. Nesses ambientes, a movimentação de uma única pessoa pode gerar sinais simultâneos em diferentes sensores, e induzir o modelo a supor que há mais de uma pessoa na casa; e o segundo aspecto, refere-se a possíveis falhas técnicas nos sensores

de movimentação, que podem fazer um sensor emitir sinais de forma ininterrupta, por um determinado período de tempo, causando também a identificação de sinais simultâneos.

Para mitigar esse problema, sugere-se, sempre que possível, evitar a sobreposição da cobertura dos sensores, tentando manter uma distância mínima de um metro entre as áreas de cobertura dos sensores adjacentes.

Em resposta à Questão 2 da Seção 1.6, o modelo também apresentou evidências da sua capacidade em identificar situações consideradas de risco para a saúde das pessoas monitoradas.

Durante o período de monitoramento não ocorreu nenhuma situação de queda ou desmaio, pelo menos, não reportada pelos idosos. Entretanto, o modelo gerou uma quantidade significativa de falsos alarmes e isto ocorreu, provavelmente, por conta dos pontos cegos existentes dentro das casas, isto é, locais não cobertos pelos sensores de movimentação. Essa situação ficou mais evidente na casa do idoso 2, por conta das maiores dimensões dos seus cômodos. Outras possíveis causas foram falhas nos sensores e falta de energia.

Para resolver o problema dos pontos cegos, sugere-se aumentar o número de sensores de movimentação, de forma a cobrir uma área maior de movimentação, evitando contudo sobreposições entre os sensores e quanto ao problema da falta de energia, sugere-se o uso de um sistema de monitoramento que utilize bateria como fonte de energia, o que já está sendo proposto no trabalho de mestrado, ainda em construção, do aluno Charles Soares.

Quanto a capacidade de perceber a ausência dos idosos por um tempo maior que o usual, o modelo emitiu alertas todas as vezes em que os idosos saíram e dormiram fora de casa.

Quanto a mudanças no comportamento dos idosos que pudessem impactar o seu estado de saúde, o modelo foi capaz de identificar alguns comportamentos atípicos da atividade de dormir, principalmente, diferenças significativas na duração da atividade.

Em resposta à Questão 3 da Seção 1.6, o modelo gerou diversos alarmes relacionados com movimentações inesperadas dentro das residências e isto quer dizer que o alcance de algum(ns) sensor(e)s de movimentação não foi configurado de forma adequada ou a quantidade de sensores foi insuficiente.

No que diz respeito à percepção de temperaturas fora dos limites aceitáveis, o modelo chegou a detectar em uma das casas, temperaturas que chegaram até 50 graus. Contudo, credita-se esse fato à possíveis falhas no sensor ou à sua proximidade a uma fonte de calor, como o fogão.

Sugere-se evitar a instalação do sensor de temperatura próximo a fontes de calor.

Por fim, vale a pena discorrer sobre dois outros aspectos que foram identificados durante os experimentos do modelo.

Uma percepção já esperada, mas que ficou muito evidente durante o período de monitoramento é quanto a grande sensibilidade do modelo em relação ao sistema de monitoramento, isto é, aos dispositivos eletrônicos. Falhas nesses dispositivos impactam diretamente em diversos aspectos do aprendizado do comportamento, além de causar a emissão de alarmes falsos.

O último aspecto diz respeito à questão da privacidade. Uma das premissas que nortearam esse trabalho foi a busca por um sistema que mitigasse a sensação de invasão de privacidade, por parte das pessoas monitoradas. E essa foi uma das razões de terem sido escolhidos apenas sensores de ambiente, como o de temperatura e o *PIR*. Contudo, mesmo assim, foi possível perceber o desconforto de algumas pessoas em conviver com um sistema de monitoramento. Esse foi o relato do idoso 1, que solicitou a retirada dos equipamentos antes da data planejada, por conta do desconforto causado a pessoas do seu convívio. Essa também foi a razão de terem sido monitorados 25 dias, ao invés de 30, conforme planejamento inicial.

7.2 Contribuições

Com base nas pesquisas realizadas ao longo desse trabalho, e principalmente, na constatação do aumento de idosos morando sozinhos, foi possível observar o aumento no número de pesquisas e produtos relacionados com a área de monitoramento remoto e assistência domiciliar.

Por isso, espera-se que o modelo proposto nesse trabalho possa vir a contribuir para a criação de produtos e serviços de assistência domiciliar remota, de baixo custo, não intrusiva e de fácil utilização. E que esses produtos e serviços consigam identificar de forma antecipada situações de riscos para a pessoa monitorada, possibilitando conseqüentemente, um atendimento de socorro antecipado.

Por fim, espera-se com a conclusão deste projeto, que possamos contribuir para levar mais qualidade de vida para pessoas que moram sozinhas, auxiliando-os no suporte a uma vida mais independente e segura.

7.3 *Atividades Futuras de Pesquisa*

O modelo aqui proposto foi construído para analisar dados gerados exclusivamente por sensores de movimentação e temperatura. Contudo, como já era esperado, esses sensores não são tão precisos para afirmar determinadas atividades que ocorrem dentro de um ambiente domiciliar, como por exemplo, a contabilização do número de pessoas na casa, a identificação do posicionamento da pessoa ao usar a cama e o sofá (como sentado ou deitado), dentre outras.

Entretanto, sabe-se que na atualidade, existe no mercado, uma grande variedade de equipamentos e sensores com formatos, funcionalidades e preços distintos. Portanto, sugere-se como trabalhos futuros, a criação de modelos capazes de compreender o comportamento de uma pessoa em um domicílio unipessoal, através do uso de uma maior variedade de sensores de ambiente não intrusivos e de baixo custo, como por exemplo, o uso adicional de sensores ultrassônicos, *infrared*, de flexão, dentre outros.

Para melhor subsidiar a sugestão acima apresentada, sugere-se um outro projeto que tenha como objetivo realizar um estudo sobre um conjunto de sensores ambientes não-intrusivos e de baixo custo, analisando características como confiabilidade, robustez, custo, dentre outras.

Sugere-se também a inclusão de um botão de pânico, instalado em algum(ns) cômodo(s) da residência e que estaria conectado ao sistema de monitoramento. Ele teria como propósito servir como uma alternativa para o idoso solicitar ajuda, em situações de extrema gravidade.

Espera-se que os trabalhos aqui sugeridos possam ser aplicados a um número maior de pessoas, segmentadas por faixa etária e sexo, para que dessa forma, possa se buscar a identificação de padrões coletivos, através da correlação entre características físicas dessas pessoas e os seus comportamentos, dentro dos seus ambientes domiciliares.

Por fim, esperamos produzir um produto comercial para assistência domiciliar patenteadado, com base nos estudos realizados nesse trabalho.

Referências

- AGRAWAL, R.; SRIKANT, R. Mining sequential patterns. *11th Intl. Conference on Data Engineering*, 1995.
- ALMEIDA, F. B. *Um modelo baseado em agentes para simulação de indivíduos em residências unipessoais*. Dissertação (Mestrado em modelagem computacional e tecnologias industriais) — SENAI - CIMATEC, Salvador, 2013.
- ATKINSON, R.; CASTRO, D. *Digital Quaiity of Life - Understanding the Personal and Social Benefits of the Information Technology Revolution*. 2014. URL: <http://www.itif.org/files/DQOL.pdf>. Acessado em 28-Janeiro-2014.
- BBC, R. *Technologies for Long-Term Care and Home Healthcare: Global Markets*. 2013. URL: <http://www.bccresearch.com/report/download/report/hlc079b>. Acessado em 04-Fevereiro-2014.
- BLAINEY, G. *Uma Breve História do Mundo*. new York: Editora Fundamento, 2011.
- BOTTREL, F. *Chip monitora cotidiano de idosos*. 2011. URL: http://www.correiobraziliense.com.br/app/noticia/ciencia-e-saude/2010/07/19/interna_ciencia_saude,203166/index.shtml. Acessado em 17-Abril-2011.
- BREUNIG, M.; H., K.; NG, R.; SANDER, J. Lof: Identifying density-based local outliers. In: *ACM SIGMOD*. Dalles, USA: [s.n.], 2000.
- BREWER, D.; TEETER, E. Egypt and the egyptians. In: *The Journal of African History*. United Kingdom: Cambridge University Press, 2001. v. 42, p. 117–172.
- BRITO, M. *Estudos da família no Brasil colonial*. 2004. URL: <http://www.pe.anpuh.org/resources/pe/anais/encontro5/01-imaginario/Artigo%20de%20Mar%EDlia%20Barbosa%20de%20Brito.pdf>. Acessado em 19-Janeiro-2014.
- CALIFORNIA, U. *Life in the Middle Ages*. 2014. URL: <http://www.ucpress.edu/content/chapters/11633.ch01.pdf>. Acessado em 16-Janeiro-2014.
- CARVALHO, S.; COPETTI, A.; FILHO, O. *Um Sistema Computacional Inteligente de Assistência Domiciliar à Saúde*. 2012. URL: http://www.tempo.uff.br/arquivos/cbis2010_stcarvalho.pdf. Acessado em 14-Julho-2012.
- CAVOUKIAN, A.; FISHER, A.; KILLEN, S.; A., H. D. Remote home health care technologies: how to ensure privacy? built it in: *Privacy by Design*. Springer, 2010.

- CESTA, A. et al. Monitoring elderly people with the robocare domestic environment: Interactions synthesis and user evaluation. *Computational Intelligence*, v. 27, n. 1, 2011.
- CHANDOLA, V.; BANERJEE, A.; KUMAR, V. Anomaly detection: A survey. *ACM Computing Surveys*, p. 1–72, September 2009.
- COSTANZA, R. et al. Novelty detection: A review - part 1: Statistical approaches. *Ecological Economics*, v. 63, p. 267–276, 2007.
- COWAN, R. The industrial revolution in the home: Household technology and social change in th 20th century. In: *Technology and Culture*. [S.l.]: The Johns Hopkins University Press, 1976. v. 17, p. 1–23.
- DARKINS, A. W.; CARY, M. A. *Telemedicine and Telehealth Principles, Policies, Performance, and Pitfalls*. New York: Springer Publishing Company, Inc, 2000. URL: http://books.google.com.br/books?id=0GY5lZBY0J8C&pg=PA1&hl=pt-BR&source=gbs_toc_r&cad=4#v=onepage&q&f=false.
- EUROMONITOR. *Special Report: Rise in Single-Person Households Globally Impacts Consumer Spending Patterns*. 2012. URL: <http://www.docstoc.com/docs/152262301/Rise-in-Single-Person-Households-Globally-Impacts-Consumer>. Acessado em 21-Janeiro-2014.
- FEOFILOFF, P.; KOHAYAKAWA, Y.; WAKABAYASHI. *Uma Introdução Sucinta à Teoria dos Grafos*. São Paulo: USP, 2011.
- FRADEN, J. *Handbook of Modern Sensors - Physics, Designs, and Applications*. New York: Springer, 2010.
- GOUCHER, C.; GUIN, C.; WALTON, L. *In the balance: themes in global history*. Madison: McGraw-Hill, 1998.
- GPAT. *Definition of Assitive Technology*. 2014. URL: <http://www.gpat.org/Georgia-Project-for-Assistive-Technology/Pages/Assistive-Technology-Definition.aspx>. Acessado em 30-Janeiro-2014.
- GRIMM, V. et al. A standard protocol for describing individual-based and agent-based models. *Ecological Modelling*, v. 198, p. 115–126, 2006.
- GRUBBS, F. Procedures for detecting outlying observations in samples. *American Statistical Association*, 1969.
- GUARDIAN, T. *60 people a week dying alone at home, says MP*. 2005. URL: <http://www.guardian.co.uk/society/2005/dec/29/socialcare.uknews>. Acessado em 12-Julho-2012.
- GUISEPI, R. *Agriculture And The Origins Of Civilization; The Neolithic Revolution*. 2014. URL: <http://history-world.org/agriculture.htm>. Acessado em 16-Janeiro-2014.

- GURALNIK, V.; HAIGH, K. Z. Learning models of human behaviour with sequential patterns. In: *The Eighteenth National Conference on Artificial Intelligence (AAAI-02)*. Alberta, Canada: [s.n.], 2002. p. 24–30.
- HEALTH, W. *World Health Statistics 2013*. 2013.
[Http://www.who.int/gho/publications/world_health_statistics/EN_WHS2013_Full.pdf](http://www.who.int/gho/publications/world_health_statistics/EN_WHS2013_Full.pdf).
Acessado em 20-Janeiro-2014.
- HODGE, V.; J., A. A survey of outlier detection methodologies. In: *Artificial Intelligence Review*. York, UK: Kluwer Academic Publishers, 2004. v. 22, p. 85–126.
- IBGE. *Síntese de Indicadores Sociais - Uma Análise das Condições da Vida da População Brasileira 2012*. 2012.
[Ftp://ftp.ibge.gov.br/Indicadores_Sociais/Sintese_de_Indicadores_Sociais_2012/SIS_2012.pdf](ftp://ftp.ibge.gov.br/Indicadores_Sociais/Sintese_de_Indicadores_Sociais_2012/SIS_2012.pdf).
Acessado em 20-Janeiro-2014.
- IBGE. *Em 2012, esperança de vida ao nascer era de 74,6 anos*. 2013. URL
<http://saladeimprensa.ibge.gov.br/noticias?view=noticia&id=1&busca=1&idnoticia=2528>.
Acessado em 20-Janeiro-2014.
- INMEDICA. *Global Telehealth Market Set to Exceed \$1 Billion by 2016*. 2011. URL:
http://www.imsresearch.com/news-events/press-template.php?pr_id=2299. Acessado em 29-Janeiro-2014.
- JAFFE, E. *The Rise of People Living Alone Has Led To More Sustainable Cities*. 2013. URL: <http://www.theatlanticcities.com/jobs-and-economy/2013/07/rise-people-living-alone-has-led-more-sustainable-cities/6212/>. Acessado em 21-Janeiro-2014.
- JAIN, A.; DUIN, R. Pattern recognition. *The Oxford Companion to the Mind. Second edition, Oxford, UK*, Oxford University Press, p. 698–703, 2004.
- JAPAN, T. *No. of people dying alone rises in no-relationship society*. 2011. URL: <http://www.japantoday.com/category/kuchikomi/view/no-of-people-dying-alone-rises-in-no-relationship-society>. Acessado em 12-Julho-2012.
- KLINENBERG, E. *I want to be alone: the rise and rise of solo living*. 2012. URL: <http://www.theguardian.com/lifeandstyle/2012/mar/30/the-rise-of-solo-living>. Acessado em 20-Janeiro-2014.
- LUCAMBIO, F. Estimador kernel da função de densidade. Agosto 2008.
- MACHADO, A. *Vida e Morte do Banceirante*. [S.l.]: Imprensa oficial do Estado S/A, 2006.
- MAIMON, O.; ROKACH, L.; BEN-GAL, I. *The Data Mining and Knowledge Discovery Handbook*. New York: Springer, 2005.

- MARKOU, M.; SINGH, S. Novelty detection: A review - part 1: Statistical approaches. *Signal Processing*, v. 83, p. 2481–2497, December 2003.
- MCLENDON, K. E-commerce and him: ready or not, here it comes. *American Health Information Management Association*, v. 1, n. 71, p. 22–23, January 2000.
- MICHIGAN, U. *Demographic Transition: An Historical Sociological Perspective*. 2000. URL: http://www.globalchange.umich.edu/globalchange2/current/lectures/pop_socio/pop_socio.html. Acessado em 20-Janeiro-2014.
- MISSOURI, u. *MU Researchers Use New Video Gaming Technology to Detect Illness, Prevent Falls in Older Adults*. 2012. URL: <http://munews.missouri.edu/news-releases/2011/0906-mu-researchers-use-new-video-gaming-technology-to-detect-illness-prevent-falls-in-older-adults/>. Acessado em 12-Julho-2012.
- NATIONS, U. *Living Arrangements of older persons around the world*. 2005. United Nations. Acessado em 02-Novembro-2011.
- NATIONS, U. *Current Status of the Social Situation, Well-Being, Participation in Development and Rights of Older Persons Worldwide*. 2010. United Nations. Acessado em 02-Novembro-2011.
- NIKUS, K.; VIRTANEN, V.; SCLAROVSKY, S.; ESKOLA, M. *The Role of Standard 12-lead ECG in a Telecardiology Consultation Service*. 2011. URL: <http://www.intechopen.com/books/telemedicine-techniques-and-applications/the-role-of-standard-12-lead-ecg-in-a-telecardiology-consultation-service>. Acessado em 29-Janeiro-2014.
- PAL, S.; PAL, A. *Pattern Recognition From Classical to Modern Approaches*. Singapore: World Scientific Publishing Co. Pte. Ltd., 2001.
- PAPADIMITRIOU, S.; KITAGAWA, H.; GIBBONS, P.; FALOUTSOS, C. Loci: Fast outlier detection using the local correlation integral. *School of Computer Science Carnegie Mellon University*, November 2002.
- PARE, G.; JAANA, M.; SICOTTE, C. Systematic review of home telemonitoring for chronic diseases: The evidence base. In: *Journal of the American Medical Informatics Association*. [S.l.: s.n.], 2007. v. 14.
- PARZEN, E. On estimation of a probability density function and mode. 1962.
- PATENT. *Monitoring and alarming for abnormal behavior of indoor personnel based on intelligent video*. 2012. URL: <http://www.google.com/patents/CN102737474A?cl=en>. Acessado em 28-Janeiro-2014.

PEI, J. et al. Prefixspan: Mining sequential patterns efficiently by prefix-projected pattern growth. *17th International Conference on Data Engineering (ICDE 01)*, April 2001.

REPAS, R. *Sensor Sense: Passive Infrared-Motion Sensors*. 2013. URL: <http://machinedesign.com/news/sensor-sense-passive-infrared-motion-sensors>. Acessado em 09-Dezembro-2013.

ROSENBLATT, M. Remarks on some nonparametric estimates of a density function. *Annals of Mathematical Statistics*, v. 27, n. 3, p. 832–837, September 1956.

Sá, J. M. *Pattern Recognition Concepts, Methods and Applications*. Portugal: Springer, 2001.

SEKI, H.; SUSUMU, T. Nondaily behavior detection monitoring system for elderly people based on bayesian network representation of omnidirectional vision sensor. *Electrical Engineering in Japan*, v. 172, n. 3, p. 42–51, August 2010.

SIGNORETTI, A. *Agentes Inteligentes com Foco de Atenção Afetivo com Simulações baseadas em Agentes*. Dissertação (Doutorado) — universidade Federal do Rio Grande do Norte, Natal, 2012.

TAPIA, E. *Activity Recognition in the Home Setting Using Simple and Ubiquitous Sensors*. Dissertação (Master of Science) — Massachusetts Institute of Technology, 2003.

TOHKA, J. *SGN-2506: Introduction to Pattern Recognition*. 2006.

TORONTO, u. *Quality of Life - Research Unit*. 2014. URL: <http://www.utoronto.ca/qol/index.htm>. Acessado em 28-Janeiro-2014.

UNFPA. *Chapter 1 : Setting the scene*. 2012. URL: <https://www.unfpa.org/webdav/site/global/shared/documents/publications/2012/UNFPA-Report-Chapter1.pdf>. Acessado em 22-Janeiro-2014.

VIEIRA, F. *Sistema de monitoração remota de recém-nascidos, crianças, idosos e convalescentes de qualquer idade e aparelhos componentes do mesmo*. 1994. URL: <https://gru.inpi.gov.br/pPI/servlet/PatenteServletController?Action=detail&CodPedido=461627&...> Acessado em 28-Janeiro-2014.

WAND, M.; JONES, M. C. *Kernel Smoothing*. United States: Chapman and Hall/CRC, 1995. URL: http://books.google.com.br/books?id=GTOOi5yE008C&printsec=frontcover&hl=pt-BR&source=gbs_ge_summary_r&cad=0#v=onepage&q&f=false.

WEBB, A. *Statistical Pattern Recognition*. England: John Wiley and Sons, Ltd, 2002.


WHO, O. *WHO technical meeting on sleep and health*. Bonn, Alemanha: [s.n.], Janeiro 2004.

ZAKI, M. Spade: An efficient algorithm for mining frequent sequences. *Machine Learning*, v. 42, p. 31–60, 2001.

ZAMBOM, A. Z.; DIAS, R. A review of kernel density estimation with applications to econometrics. Dezembro 2012.

Comitê de Ética

**Programa de Pós-Graduação em Modelagem Computacional e Tecnologia Industrial
SENAI CIMATEC**



TERMO DE CONSENTIMENTO LIVRE E ESCLARECIDO

Estamos convidando você para participar de uma pesquisa intitulada "Aquisição de Dados por Sensoriamento Remoto e Aprendizado do Padrão Comportamental de Indivíduos para Monitoramento de Domicílios Unipessoais" que será realizada na residência em que você vive. A pesquisa consiste no monitoramento remoto da sua movimentação dentro da residência, utilizando somente sensores não-intrusivos de movimentação e de temperatura do ambiente. Salientamos que não será utilizado nenhum equipamento que capture a sua imagem ou seus dados fisiológicos.

Esperamos que essa pesquisa nos auxilie na criação de um produto em forma de software que permita monitorar remotamente e de forma não-intrusiva uma pessoa que vive sozinha, principalmente pessoas idosas, aprender alguns dos seus comportamentos rotineiros e principalmente detectar com maior brevidade, situações de risco, como um desmaio ou um mal súbito. Você será, portanto um dos primeiros beneficiados por esse estudo.

Informamos que esta pesquisa não apresenta nenhum risco, seja para a sua saúde, ou para a sua integridade física e mental. Aproveitamentos para informar que os critérios para a inclusão dos participantes são: a pessoa precisa ter 60 anos ou mais e precisa morar sozinha. Entre os candidatos potenciais, iremos escolher uma amostra que represente uma ampla gama de situações possíveis, isto é, pessoas com rotinas de vida e graus de higidez diversos.

Se você aceitar participar da pesquisa, depois de ter lido ou ouvido este texto, por favor, assine este documento. O entrevistador também o fará. Isto porque, o pesquisador, deve garantir que você participou da pesquisa por sua livre vontade. Este termo de consentimento está elaborado em duas vias de igual teor e você e o pesquisador ficarão cada um, com uma cópia.

Os dados coletados serão confidenciais e somente você e o pesquisador terão acesso a elas. Seu nome não será identificado em nenhum de nossos relatórios ou publicações que resultarão deste estudo.

Sua participação na pesquisa é voluntária. Você pode se recusar a participar ou pode pedir para ser excluído a qualquer momento e não será obrigado a realizar nenhuma atividade para a qual não se sinta disposto ou capaz. Se você precisar de esclarecimentos adicionais sobre a pesquisa (metodologia, procedimentos), estes serão fornecidos em qualquer tempo do curso da pesquisa. Você não será responsabilizado por nenhum custo relacionado a esta pesquisa.

Se você vier a ter outras perguntas sobre sua participação neste estudo, por favor, entre em contato com o pesquisador, Valter de Senna, através do telefone (71) 8788-2741 e do endereço: Av. Orlando Gomes, 1845 – Piatã, Salvador – Bahia. CEP: 41650-010

Este estudo foi avaliado pelo Comitê de ética da Escola Bahiana de Medicina e Saúde Pública / Fundação Bahiana Desenvolvimento das Ciências, situada à Av. Dom João VI, 275, Brotas, Salvador – Bahia. CEP: 40.290-000. E-mail: cep@bahiana.edu.br. Telefone: (71) 3276-8225.

Consentimento: Eu, _____ li ou ouvi a leitura do consentimento informado. Tive a oportunidade de perguntar questões sobre o projeto e elas foram respondidas para minha completa satisfação. Sou voluntário em participar do projeto.

Assinatura do participante ou digital Data

Assinatura do pesquisador Data

Figura A.1: Termo de Consentimento Livre e Esclarecido. Fonte: Autor



 <div style="display: inline-block; text-align: center;"> <p>ESCOLA BAHIANA DE MEDICINA E SAÚDE PÚBLICA / FUNDAÇÃO BAHIANA</p> </div> 								
PARECER CONSUBSTANCIADO DO CEP								
DADOS DO PROJETO DE PESQUISA								
Título da Pesquisa: SISTEMA DE AQUISIÇÃO DE DADOS POR SENSORIAMENTO E APRENDIZADO DO PADRÃO COMPORTAMENTAL DE INDIVÍDUOS PARA MONITORAMENTO DE DOMICÍLIOS UNIPESSOAIS								
Pesquisador: Valler de Senna								
Área Temática:								
Versão: 2								
CAAE: 35247214.5.0000.5544								
Instituição Proponente: SERVIÇO NACIONAL DE APRENDIZAGEM INDUSTRIAL								
Patrocinador Principal: SERVIÇO NACIONAL DE APRENDIZAGEM INDUSTRIAL								
DADOS DO PARECER								
Número do Parecer: 917.017								
Data da Relatoria: 28/10/2014								
Apresentação do Projeto:								
<p>O indivíduo será posicionado numa cadeira confortável, com os pés apoiados, orientado para realizar uma manobra de expiração lenta em seguida uma inspiração rápida e forçada com nariz ocluído por um clip nasal. A manobra será repetida até o voluntário não for mais</p> <p>O treinamento muscular inspiratório (TMI), nos últimos anos, tem sido largamente investigado como opção terapêutica em pacientes com Insuficiência Cardíaca (IC), Doença Pulmonar Obstrutiva Crônica (DPOC), em doentes críticos para auxílio do desmame da ventilação mecânica, entre as mais diversas afecções crônicas que tenham como impacto redução da capacidade funcional e fraqueza muscular respiratória^{1,2,3,4,5}.</p> <p>Além dos indivíduos que apresentam patologias cardiorrespiratórias e metabólicas, este tipo de treinamento tem sido utilizados em atletas de alto rendimento que buscam melhora da performance em seus desportos⁶. Em pacientes com Insuficiência Cardíaca (IC) está bem estabelecido que o treinamento muscular respiratório, com 30% da Pressão Inspiratória Máxima (Pimax), quinze minutos por dia, 7 dias por semana, foi eficaz em</p>								
<table style="width: 100%; border: none;"> <tr> <td style="border: none;">Endereço: AVENIDA DOM JOÃO VI, 275</td> <td style="border: none;">CEP: 40.290-000</td> </tr> <tr> <td style="border: none;">Bairro: BROTAS</td> <td style="border: none;"></td> </tr> <tr> <td style="border: none;">UF: BA</td> <td style="border: none;">Município: SALVADOR</td> </tr> <tr> <td style="border: none;">Telefone: (71)3276-8225</td> <td style="border: none;">E-mail: cep@bahiana.edu.br</td> </tr> </table>	Endereço: AVENIDA DOM JOÃO VI, 275	CEP: 40.290-000	Bairro: BROTAS		UF: BA	Município: SALVADOR	Telefone: (71)3276-8225	E-mail: cep@bahiana.edu.br
Endereço: AVENIDA DOM JOÃO VI, 275	CEP: 40.290-000							
Bairro: BROTAS								
UF: BA	Município: SALVADOR							
Telefone: (71)3276-8225	E-mail: cep@bahiana.edu.br							
Página 01 de 07								

Figura A.2: Documento de Aprovação do Projeto pelo Comitê de Ética (Página 01/05). Fonte: Autor



	ESCOLA BAHIANA DE MEDICINA E SAÚDE PÚBLICA / FUNDAÇÃO BAHIANA	
Continuação do Parecer: 917.017		
<p>Oxigênio (SpO₂), Frequência cardíaca através do oxímetro de pulso da marca X, a Pressão Arterial (PA) mensurado a cada nível pelo aparelho Y e os dados foram anotados num banco de dados para posterior análise. Como critério de segurança o teste será interrompido caso haja sensação de dispnéia ou fadiga, queda da Spo₂ 94% PAS > 160mmHg, FC > 140 ou glicemia 60 mg/dL. O teste será interrompido caso haja sensação de dispnéia ou fadiga, queda da Spo₂ 94% PAS >= 160mmHg, FC >= 140bpm ou glicemia 60 mg/dL. Durante todo o estudo serão observadas as diretrizes sobre a pesquisa com seres humanos da Declaração de Helsinque e da Resolução 466/12 do Conselho Nacional de Saúde. Este estudo será submetido ao Comitê de Ética em Pesquisa da Escola Bahiana de Medicina e Saúde Pública. Todos os sujeitos receberão detalhadamente as informações sobre os objetivos do estudo, riscos e benefícios envolvidos nos procedimentos e assinarão consentimento livre e esclarecido (em anexo). Serão preenchidas duas vias, uma ficando em posse do voluntário e outra em posse do pesquisador.</p>		
Objetivo da Pesquisa:		
Utilizar equipamento com sensores para detectar movimentos e de temperatura, obtendo-se uma maneira logística de comunicação para prever riscos de acidentes e melhoria da qualidade de vida. Identificar os algoritmos (sequencia de resolução de problemas) mais adequados para o aprendizado do comportamento de pessoas em moradias unipessoais.		
Avaliação dos Riscos e Benefícios:		
O risco percebido nesse estudo poderia vir a ser de constrangimento já que vai ser transmitido a rotina através de movimentação do participante, apesar do autor garantir que não se observa nenhum tipo de risco pois o sensor só irá detectar a movimentação de uma pessoa no seu raio de alcance. O benefício será direto será o participante ter durante o tempo de coleta a segurança de monitoramento para eventos adversos agravados pelo status de morara sozinho. O indireto será o da contribuição com um modelo computacional que		
Endereço: AVENIDA DOM JOÃO VI, 275		
Bairro: BROTAS		
UF: BA		
Município: SALVADOR		
CEP: 40.290-000		
Telefone: (71)3276-8225		
E-mail: cep@bahiana.edu.br		

Figura A.3: Documento de Aprovação do Projeto pelo Comitê de Ética (Página 02/05). Fonte: Autor

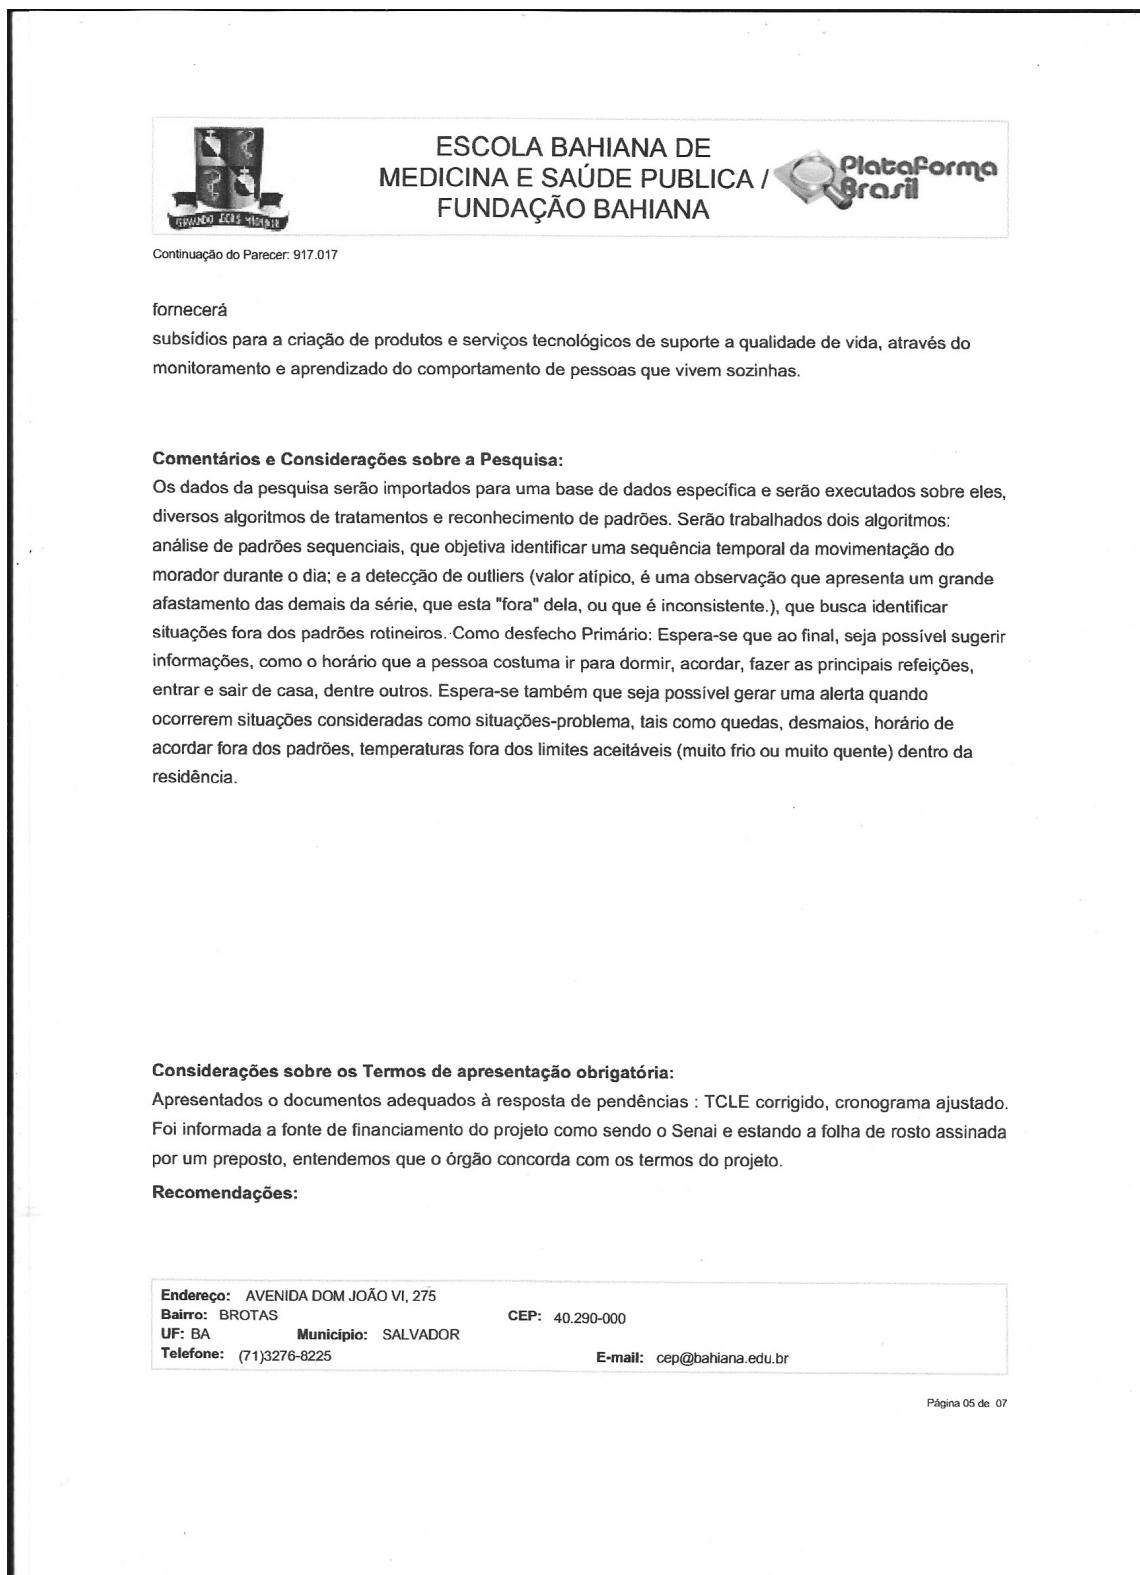


Figura A.4: Documento de Aprovação do Projeto pelo Comitê de Ética (Página 03/05). Fonte: Autor



	ESCOLA BAHIANA DE MEDICINA E SAÚDE PÚBLICA / FUNDAÇÃO BAHIANA	
Continuação do Parecer: 917.017		
Conclusões ou Pendências e Lista de Inadequações:		
Sanadas as pendências do parecer consubstanciado datado de 09.10.2014 referentes ao TCLE, cronograma e orçamento, sugerimos aprovação.		
Situação do Parecer:		
Aprovado		
Necessita Apreciação da CONEP:		
Não		
Considerações Finais a critério do CEP:		
Atenção : o não cumprimento à Res. 466/12 do CNS abaixo transcrita implicará na impossibilidade de avaliação de novos projetos deste pesquisador. Tendo sido sanadas as pendências anteriormente assinaladas e, estando de acordo com a Res. 466/12 do CNS o projeto encontra-se exequível.		
XI ¿ DO PESQUISADOR RESPONSÁVEL		
XI.1 - A responsabilidade do pesquisador é indelegável e indeclinável e compreende os aspectos éticos e legais.		
XI.2 - Cabe ao pesquisador: a) e b) (...)		
c) desenvolver o projeto conforme delineado;		
d) elaborar e apresentar os relatórios parciais e final;		
e) apresentar dados solicitados pelo CEP ou pela CONEP a qualquer momento;		
f) manter os dados da pesquisa em arquivo, físico ou digital, sob sua guarda e responsabilidade, por um período de 5 anos após o término da pesquisa;		
g) encaminhar os resultados da pesquisa para publicação, com os devidos créditos aos pesquisadores associados e ao pessoal técnico integrante do projeto; e		
h) justificar fundamentadamente, perante o CEP ou a CONEP, interrupção do projeto ou a não publicação dos resultados		
Endereço: AVENIDA DOM JOÃO VI, 275		
Bairro: BROTAS CEP: 40.290-000		
UF: BA Município: SALVADOR		
Telefone: (71)3276-8225 E-mail: cep@bahiana.edu.br		

Figura A.5: Documento de Aprovação do Projeto pelo Comitê de Ética (Página 04/05). Fonte: Autor

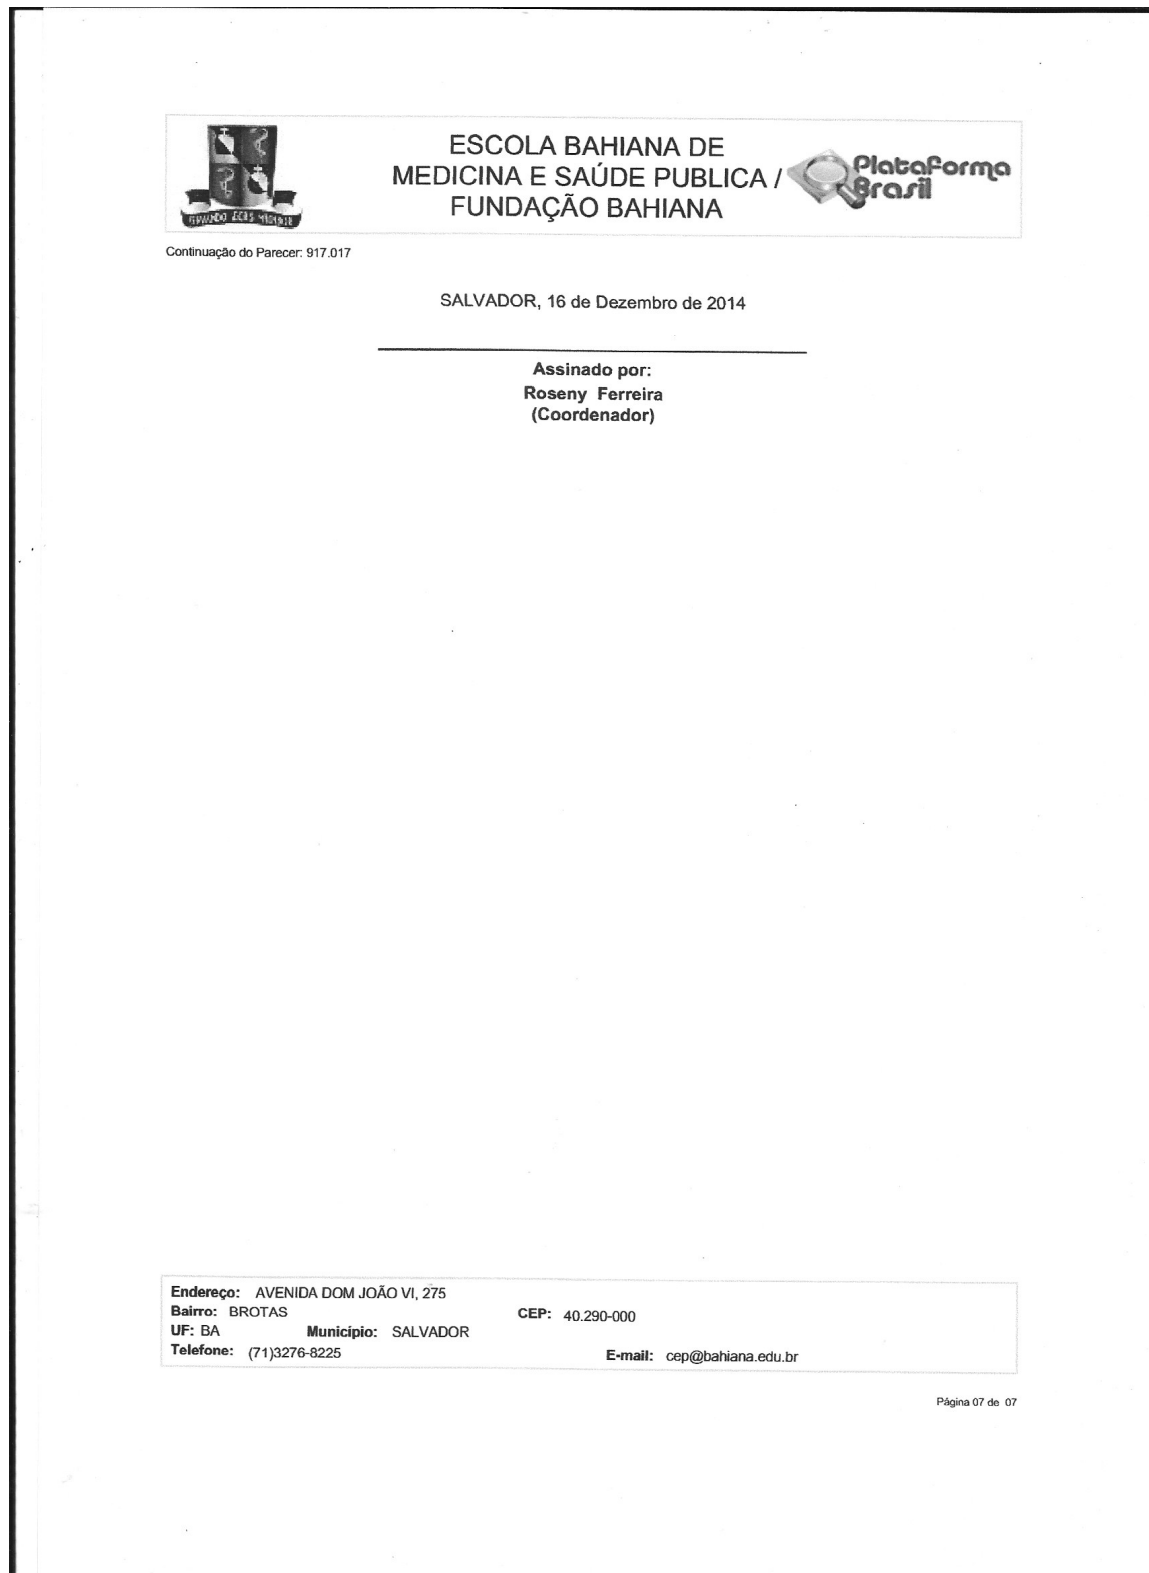


Figura A.6: Documento de Aprovação do Projeto pelo Comitê de Ética (Página 05/05). Fonte: Autor

Modelagem de Padrões Comportamentais de Pessoas em Domicílios Unipessoais

Márcio Renê Brandão Soussa

Salvador, 15 de Maio de 2015.