



Bruno Silva Pontes

**Reconhecimento de Posturas Humanas Preservando a
Privacidade:
Um estudo de caso usando um sensor térmico de baixa resolução**

Dissertação de Mestrado

Dissertação apresentada como requisito parcial para
obtenção do grau de Mestre em Informática pelo
Programa de Pós-Graduação em Informática da
PUC-Rio.

Orientador: Prof. Hugo Fuks

Rio de Janeiro
Setembro 2016



Bruno Silva Pontes

Reconhecimento de Posturas Humanas Preservando a Privacidade:

Um estudo de caso usando um sensor térmico de baixa resolução

Dissertação apresentada como requisito parcial para a obtenção do grau de Mestre pelo Programa de Pós-Graduação em Informática do Departamento de Informática do Centro Técnico Científico da PUC-Rio. Aprovada pela Comissão Examinadora abaixo assinada.

Prof. Hugo Fuks

Orientador

Departamento de Informática - PUC-Rio

Prof. Alberto Barbosa Raposo

Departamento de Informática - PUC-Rio

Prof. Simone Diniz Junqueira Barbosa

Departamento de Informática - PUC-Rio

Prof. Márcio da Silveira Carvalho

Coordenador Setorial do Centro Técnico Científico - PUC-Rio

Rio de Janeiro, 30 de setembro de 2016

Todos os direitos reservados. É proibida a reprodução total ou parcial do trabalho sem autorização da universidade, do autor e do orientador.

Bruno Silva Pontes

Iniciou o mestrado no segundo semestre de 2014 no Departamento de Informática da Pontifícia Universidade Católica do Rio de Janeiro (PUC-Rio). Bruno obteve o título de Bacharel em Sistemas de Informação também pela PUC-Rio em 2014. Atua em pesquisas de Computação Ubíqua, Software dos Lugares e Interação Humano-Computador no SecondLab (PUC-Rio). Desenvolvimento de software que processa dados de sensores e utiliza algoritmos de aprendizagem de máquina são exemplos de tecnologias que foram desenvolvidas durante o mestrado.

Ficha Catalográfica

Pontes, Bruno Silva

Reconhecimento de posturas humanas preservando a privacidade : um estudo de caso usando um sensor térmico de baixa resolução / Bruno Silva Pontes ; orientador: Hugo Fuks. – 2016.

82 f. : il. color. ; 30 cm

Dissertação (mestrado)–Pontifícia Universidade Católica do Rio de Janeiro, Departamento de Informática, 2016.

Inclui bibliografia

1. Informática – Teses. 2. Reconhecimento de posturas humanas. 3. Privacidade. 4. Ambientes de moradia assistidos. 5. Sensor térmico. 6. Árvores de decisão. I. Fuks, Hugo. II. Pontifícia Universidade Católica do Rio de Janeiro. Departamento de Informática. III. Título.

CDD: 004

Dedico este trabalho aos meus pais. Minha mãe, pelo carinho que tinha por mim e por me mostrar o mais puro amor ao próximo, sendo minha maior fonte de inspiração até hoje. E meu pai, por todo apoio, suporte e ensinamentos, que foram cruciais para a minha formação como pessoa e possibilitaram que eu concluísse este trabalho.

Agradecimentos

Agradeço ao meu orientador, Prof. Hugo Fuks, pelas muitas horas de trabalho comigo, acolhimento desde o início do mestrado, confiança e valiosos conselhos. Aprendi muito com sua orientação!

Obrigado aos amigos do SecondLab, em especial ao Fernando Ismério, Bruno Chagas, Rafael Pinho e Marcio Cunha. Foram ótimos momentos de pesquisa e aprendizado com vocês. Espero que possamos todos manter contato e continuarmos a amizade.

Não posso deixar de agradecer aos companheiros do dia a dia Bernardo Dias e Fellipe Moura, assim como minha namorada Izabela. A convivência com vocês torna minha estadia no Rio de Janeiro muito mais agradável e isso influenciou muito para que fosse possível completar esta jornada.

Por fim, agradeço à PUC-Rio pela oportunidade de estudar nesta maravilhosa universidade e ao CNPq pela bolsa de estudo.

Resumo

Silva Pontes, Bruno; Fuks, Hugo. **Reconhecimento de Posturas Humanas Preservando a Privacidade: Um estudo de caso usando um sensor térmico de baixa resolução.** Rio de Janeiro, 2016. 82p. Dissertação de Mestrado – Departamento de Informática, Pontifícia Universidade Católica do Rio de Janeiro.

O reconhecimento de posturas é um dos desafios para o sensoramento humano, que auxilia no acompanhamento de pessoas em ambientes de moradia assistidos. Estes ambientes, por sua vez, auxiliam médicos no diagnóstico de saúde de seus pacientes, principalmente através do reconhecimento de atividades do dia a dia em tempo real, que é visto na área médica como uma das melhores formas de antecipar situações críticas de saúde. Além disso, o envelhecimento da população mundial, escassez de recursos em hospitais para atender todas as pessoas e aumento dos custos de assistência médica impulsionam o desenvolvimento de sistemas para apoiar os ambientes de moradia assistidos. Preservar a privacidade nestes ambientes monitorados por sensores é um fator crítico para a aceitação do usuário, por isso há uma demanda em soluções que não requerem imagens. Este trabalho evidencia o uso de um sensor térmico de baixa resolução no sensoramento humano, mostrando que é viável detectar a presença e reconhecer posturas humanas, usando somente os dados deste sensor.

Palavras-chave

Reconhecimento de Posturas Humanas; Privacidade; Ambientes de Moradia Assistidos; Sensor Térmico; Árvores de Decisão.

Abstract

Silva Pontes, Bruno; Fuks, Hugo (Advisor). **Human Posture Recognition Preserving Privacy: A case study using a low resolution array thermal sensor**. Rio de Janeiro, 2016. 82p. MSc. Dissertation – Departamento de Informática, Pontifícia Universidade Católica do Rio de Janeiro.

Postures recognition is one of the human sensing challenges, that helps ambient assisted livings in people accompanying. On the other hand, these ambients assist doctors in the diagnosis of their patients' health, mainly through activities of daily livings real time recognition, which is seen in the medical field as one of the best ways to anticipate critical health situations. In addition, the world's population aging, lack of hospital resources to meet all people and increased health care costs drive the development of systems to support ambient assisted livings. Preserving privacy in these ambients monitored by sensors is a critical factor for user acceptance, so there is a demand for solutions that does not requires images. This work demonstrates the use of a low resolution thermal array sensor in human sensing, showing that it is feasible to detect the presence and to recognize human postures, using only the data of this sensor.

Keywords

Human Posture Recognition; Privacy; Ambient Assisted Livings; Thermal Array Sensor; Decision Tree.

Sumário

| | |
|--|----|
| 1 Introdução | 14 |
| 2 Contexto | 16 |
| 2.1. Ambientes de moradia assistidos | 16 |
| 2.2. Reconhecimento de posturas humanas | 21 |
| 2.3. Privacidade | 23 |
| 3 Trabalhos relacionados | 26 |
| 4 Visão geral da pesquisa | 30 |
| 4.1. Objetivos | 30 |
| 4.2. Protótipo | 33 |
| 4.2.1. Hardware | 33 |
| 4.2.2. Software | 38 |
| 5 Método de pesquisa | 41 |
| 6 Estudo de caso | 44 |
| 6.1. Estudo exploratório | 44 |
| 6.2. Projeto do estudo de caso | 48 |
| 6.2.1. Quarto | 50 |
| 6.2.2. Banheiro | 52 |
| 6.3. Voluntários | 54 |
| 7 Resultados | 56 |
| 7.1. Explorando os dados | 57 |
| 7.2. Engenharia de atributos | 62 |
| 7.3. Modelos de árvores de decisão e respectivas acurácias | 69 |
| 7.3.1. Reconhecendo os voluntários | 69 |
| 7.3.2. Reconhecendo as posturas | 71 |

| | |
|-------------------------------------|----|
| 7.3.3. Detectando a presença humana | 73 |
| 8 Conclusão e trabalhos futuros | 75 |
| 9 Referências bibliográficas | 79 |

Lista de figuras

| | |
|---|----|
| Figura 1 - Taxonomia de propriedades humanas envolvidas no sensoriamento humano (Teixeira; Dublon; Savvides, 2010)..... | 17 |
| Figura 2 - Exemplos de uso de tecnologias de sensoriamento humano (Teixeira; Dublon; Savvides, 2010) em <i>smart spaces</i> (Surie; Partonia; Lindgren, 2013). | 18 |
| Figura 3 - Diagrama de sistema colaborativo para acompanhamento de pacientes. Fonte: http://icity.smu.edu.sg/research/research (acessado em: 24 de julho de 2016). | 19 |
| Figura 4 - Wearable para reconhecimento de atividades humanas proposto por (Ugulino et al., 2012)..... | 20 |
| Figura 5 - Exemplo de imagem de pontos de pressão gerada (b) por usuário deitado na cama (a) no trabalho de (Liu, 2013). | 22 |
| Figura 6 - Exemplo de imagem gerada por câmera térmica de resolução 320 x 240 pixels..... | 24 |
| Figura 7 - Instalação de um microfone em um cano de água para monitorar o uso de dispositivos que utilizam água em uma casa (Fogarty; Au; Hudson, 2006). | 25 |
| Figura 8 - Exemplo dos dados gerados por dois sensores térmicos de resolução 16 x 16 pixels cada um (um no teto (a) e outro na parede (b)) e a respectiva imagem de uma câmera instalada no teto (c), em um quarto de enfermagem (Taniguchi et al., 2014). | 26 |
| Figura 9 - Diagrama de transição de posturas e suas respectivas explicações (Taniguchi et al., 2014). | 27 |
| Figura 10 - Contribuições da presente pesquisa em cada assunto. | 31 |
| Figura 11 - Motivações, tarefa e assuntos importantes, de acordo com a literatura pesquisada. | 32 |
| Figura 12 - Funcionamento do sensor. Fonte: datasheet.octopart.com/D6T8L06-Omron-datasheet-12469928.pdf (acessado em: 25 de julho de 2016). | 34 |

| | |
|--|----|
| Figura 13 - Campo de visão e distribuição de pixels do sensor. Fonte: https://www.omron.com/ecb/products/pdf/en-d6t.pdf (acessado em: 25 de julho de 2016)..... | 34 |
| Figura 14 - Relação da temperatura ambiente com o alcance da temperatura medida pelo sensor. Fonte: datasheet.octopart.com/D6T8L06-Omron-datasheet-12469928.pdf (acessado em: 25 de julho de 2016)..... | 35 |
| Figura 15 - Instalação do protótipo no quarto..... | 36 |
| Figura 16 - Componentes de hardware do protótipo. | 37 |
| Figura 17 - <i>Print</i> do visualizador de temperaturas desenvolvido em Processing. | 39 |
| Figura 18 - Exemplo de como a distância afeta a leitura de temperatura pelo sensor. Fonte: datasheet.octopart.com/D6T8L06-Omron-datasheet-12469928.pdf (acessado em: 25 de julho de 2016)..... | 42 |
| Figura 19 - Fluxograma do método estudo de caso. Fonte: Livro de (Pimentel & Fuks, 2011)..... | 43 |
| Figura 20 - Análise da frequência dos dados do sensor..... | 45 |
| Figura 21 - Análise do uso de vestimentas (deitado na cama)..... | 46 |
| Figura 22 - Análise da distância (deitado na cama e no chão)..... | 47 |
| Figura 23 - Análise da distância (sentado na cama e no chão). | 48 |
| Figura 24 - Imagem com o objetivo de simular o campo de visão do sensor no quarto. | 51 |
| Figura 25 - Quarto onde a presente pesquisa foi feita e suas características. | 52 |
| Figura 26 - Imagem com o objetivo de simular o campo de visão do sensor no banheiro. | 53 |
| Figura 27 - Banheiro onde a presente pesquisa foi feita..... | 54 |
| Figura 28 - Exemplo de arquivo com extensão arff gerado para reconhecimento de posturas. | 56 |
| Figura 29 - Temperaturas medidas enquanto voluntário dorme na cama com cobertor. | 60 |
| Figura 30 - Temperaturas medidas após voluntário sair da cama onde estava dormindo..... | 61 |

| | |
|--|----|
| Figura 31 - Exemplo da matriz de temperaturas de um voluntário em pé no quarto, em temperatura ambiente de 23,4°C..... | 63 |
| Figura 32 - Matriz de correlação entre os atributos, do método <i>PrincipalComponents</i> | 67 |
| Figura 33 - Matriz de confusão do reconhecimento de voluntários no dataset da prova de conceito 1. | 70 |
| Figura 34 - Matriz de confusão do reconhecimento de posturas no banheiro, usando somente o dataset do estudo de caso. | 71 |
| Figura 35 - Matriz de confusão do reconhecimento de posturas no quarto, usando somente o dataset do estudo de caso. | 72 |
| Figura 36 - Matriz de confusão do reconhecimento de posturas no quarto, avaliado no dataset da prova de conceito 1. | 73 |
| Figura 37 - Matriz de confusão do reconhecimento de posturas no quarto, avaliado no dataset da prova de conceito 2. | 73 |
| Figura 38 - Matriz de confusão da detecção de presença no quarto, no dataset prova de conceito 2..... | 74 |

Lista de tabelas

| | |
|---|----|
| Tabela 1 - Preço dos principais componentes de hardware. | 38 |
| Tabela 2 - Perfil dos voluntários. | 55 |
| Tabela 3 - Médias dos pixels de maior temperatura em cada medição, nas posturas em pé em frente ao vaso sanitário (4) e em pé em frente ao vaso sanitário usando muita vestimenta (5), no banheiro. | 58 |
| Tabela 4 - Médias dos pixels de maior temperatura em cada medição, nas posturas em pé (6) e em pé usando muita vestimenta (7), no quarto. | 58 |
| Tabela 5 - Análise da influência da temperatura ambiente nas temperaturas medidas no campo de visão do sensor. As temperaturas são do mesmo voluntário (C) e são as médias dos pixels de maior temperatura em cada medição. | 59 |
| Tabela 6 - Resultado do método de seleção de atributos <i>CfsSubsetEval</i> | 64 |
| Tabela 7 - Resultado do método de seleção de atributos <i>CorrelationAttributeEval</i> | 66 |
| Tabela 8 - Resultado do método de seleção de atributos <i>WrapperSubsetEval</i> | 67 |
| Tabela 9 - Acurácias do reconhecimento de voluntários no banheiro. | 70 |
| Tabela 10 - Acurácias do reconhecimento de voluntários no quarto. | 70 |
| Tabela 11 - Acurácias do reconhecimento de posturas no quarto. | 72 |
| Tabela 12 - Acurácias da tarefa de detecção de presença humana no quarto. | 73 |

1

Introdução

Esta dissertação está inserida no contexto dos ambientes de moradia assistidos, que têm o objetivo de auxiliar pessoas, principalmente idosos, convalescentes e pessoas que necessitam de alguma assistência. Este auxílio pode ser facilitando tarefas do dia a dia destas pessoas em suas moradias, ou as acompanhando e, avisando pessoas queridas e profissionais de saúde caso ocorra alguma situação anormal. Isto faz com que médicos tenham um melhor diagnóstico de saúde de seus pacientes, pois estes ambientes realizam o acompanhamento de pessoas em tempo real. Os ambientes de moradia assistidos são capazes de transmitir informações para diversos interessados, aumentando as chances de intervenção rápida, caso seja necessário. Estas funcionalidades fazem com que pessoas fiquem mais seguras em suas moradias.

A investigação da viabilidade de se usar um sensor térmico de baixa resolução no acompanhamento de pessoas é uma das contribuições da presente pesquisa, que investigou o reconhecimento de posturas humanas em cômodos de uma moradia que requerem privacidade, i.e., banheiro e quarto. A presente pesquisa evidenciou que é viável detectar a presença e reconhecer posturas humanas com o sensor usado.

O Capítulo 2 faz a contextualização, inspirada em artigos da literatura, dos principais assuntos da presente pesquisa, i.e., ambientes de moradia assistidos, reconhecimento de posturas humanas e privacidade. Também no Capítulo 2 são apresentados dados que motivaram e mostram a relevância deste trabalho. No Capítulo 3 são apresentados os trabalhos encontrados na literatura que mais se assemelham com este. O Capítulo 4 lista os objetivos e apresenta as especificações técnicas do protótipo desenvolvido. O método de pesquisa é apresentado no Capítulo 5 e é detalhado no Capítulo 6. Os resultados e as análises dos dados que foram gerados no estudo de caso fazem parte do Capítulo 7. Por fim, o Capítulo 8 faz a conclusão da presente pesquisa e sugere trabalhos futuros,

e o Capítulo 9 contém toda a bibliografia que me auxiliou ao longo desta dissertação.

Diversos termos conhecidos e que fazem parte do contexto da presente pesquisa foram mantidos em inglês. Também foram mantidos em inglês os textos de imagens que foram retiradas de artigos encontrados na literatura.

2 Contexto

Apresento neste capítulo as motivações da presente pesquisa. As principais áreas em que a presente pesquisa se insere são contextualizadas. Também são apresentados os trabalhos encontrados na literatura que dizem respeito a cada área.

2.1. Ambientes de moradia assistidos

O desenvolvimento de sistemas para apoiar os ambientes de moradia assistidos (*Ambient Assisted Living* - AAL) é impulsionado pelo envelhecimento da população mundial, escassez de recursos em hospitais para atender todas as pessoas e aumento dos custos de assistência médica. A elevação da expectativa de vida, principalmente em países desenvolvidos, já torna o envelhecimento da população uma realidade. Em 2012 no Japão já eram 24,1% de idosos (idade maior ou igual 65 anos) (Taniguchi et al., 2014c) e é a maior proporção no mundo, sendo que a previsão para 2050 é de 36,5%. No Brasil, a previsão é que a proporção de idosos aumente mais de três vezes em 40 anos (de 6,9% em 2010 para 22,5% em 2050) (United Nations, 2013). Além de idosos, doentes, convalescentes e outros que necessitam de auxílio em suas casas são beneficiados com a tecnologia. O objetivo de AAL é tornar a casa destas pessoas mais seguras, pois possui sensores que as acompanham diuturnamente, e através da internet se comunicam com familiares, médicos ou vizinhos, caso o sistema reconheça alguma situação de emergência. AAL também reconhece atividades do dia a dia (*Activities of Daily Living* - ADLs), que segundo profissionais da saúde, saber de mudanças nas ADLs é a melhor forma de diagnosticar as condições física e mental de pessoas, possibilitando que médicos consigam antecipar situações críticas de saúde (Lawton; Brody, 1970). Comer, usar o banheiro, lavar roupas, tomar banho e entrar e sair da cama são exemplos de ADLs.

O acompanhamento de pessoas é uma tarefa essencial para AAL, que é feito através de sensores que estão em locais previamente definidos. Os sensores instalados nos locais têm o objetivo de sensoriar as pessoas ou elementos do ambiente que sejam acionados pelas pessoas, como por exemplo o chuveiro, que se for detectado que foi ligado isto certamente indica uma ação da pessoa (tomando banho). Os métodos de sensoriamento humano foram estudados por (Teixeira; Dublon; Savvides, 2010), que definiram cinco propriedades espaço-temporais: detectar presença, contar, localizar, rastrear e identificar. Neste mesmo estudo foram definidas cinco propriedades comportamentais: postura, ação, atividade, comportamento e comportamento em grupo, além de diversas propriedades fisiológicas como pressão sanguínea, temperatura, peso, batimento cardíaco, cor da pele, etc. A Figura 1 mostra estes três grupos de propriedades, sendo que as setas indicam relação de hierarquia entre propriedades do mesmo grupo. Por exemplo, para contar o número de pessoas é necessário detectar a presença delas antes. Com tantas propriedades para se detectar, os autores (Teixeira; Dublon; Savvides, 2010) afirmam que a fusão das informações de diversos tipos de sensores é aconselhável, e que dificilmente um único sensor será capaz de fazer este sensoriamento humano completo.

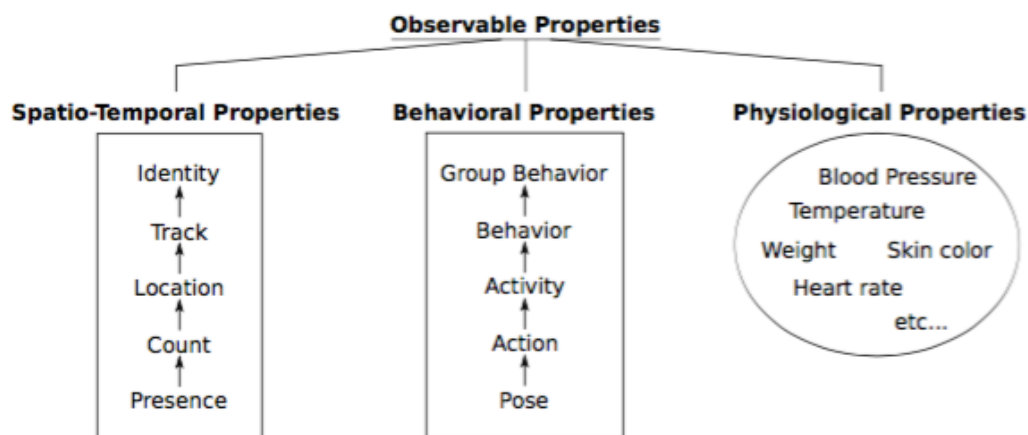


Figura 1 - Taxonomia de propriedades humanas envolvidas no sensoriamento humano (Teixeira; Dublon; Savvides, 2010)

O trabalho de (Surie; Partonia; Lindgren, 2013) se inspirou no trabalho de (Teixeira; Dublon; Savvides, 2010) e desenvolveu um sistema baseado em visão

computacional para resolver as tarefas das propriedades espaço-temporais. A Figura 2 mostra exemplos de uso em *smart spaces* uma vez que o sistema reconheça estas propriedades. Por exemplo, se a presença de uma pessoa for detectada, as luzes do ambiente ligam automaticamente, e se essa pessoa também for identificada, sua música favorita é tocada.

| Human-Sensing Properties | Human-related questions in a space | Usage examples for smart spaces | Recognition technology |
|--------------------------|------------------------------------|--|---|
| Presence | Is there someone present? | Turn on the light automatically when a person enters the room | Fusion of face recognition and skeletal tracking using Microsoft Kinect |
| Count | How many are present? | Count the number of passengers who have boarded a flight to detect missing checked-in passengers | |
| Location | Where are they? | Present TV news in the living room or kitchen depending on a person's location | |
| Track | How are they moving? | Present in-depth information when moving towards and abstract information when moving away from a digital public display | |
| Identity | Who are they? | Play favorite music depending on who is there in the room | |

Figura 2 - Exemplos de uso de tecnologias de sensoriamento humano (Teixeira; Dublon; Savvides, 2010) em *smart spaces* (Surie; Partonia; Lindgren, 2013).

Artigos da literatura sugerem acompanhamento colaborativo em AAL. Isto significa que não só médicos devem ter acesso aos dados das ADLs dos usuários (pacientes em algumas ocasiões), mas também vizinhos, familiares, amigos ou cuidadores de forma geral, podendo depender do estado de saúde e do interesse do usuário em dividir suas informações com outras pessoas (Ugulino et al., 2012) (Cunha & Fuks, 2014). O acompanhamento colaborativo aumenta a probabilidade de antecipar situações médicas urgentes. O artigo de (Triantafyllidis et al., 2016) propõe um arcabouço para monitoramento de pacientes baseado em dados de sensores. A Figura 3 mostra um diagrama para acompanhamento colaborativo de pacientes em AAL e sugere a disseminação da informação para “pessoas

queridas”, mas também a participação de médicos, voluntários e sistemas externos.



Figura 3 - Diagrama de sistema colaborativo para acompanhamento de pacientes. Fonte: <http://icity.smu.edu.sg/research/research> (acessado em: 24 de julho de 2016).

Para a tarefa de contar pessoas encontrei pesquisas com soluções usando sensor térmico (Taniguchi et al., 2014c) e câmera (Teixeira; Savvides, 2008). Os *wearable*, com acelerômetro e giroscópio embutidos, são bastante usados para a tarefa de reconhecer atividades humanas (Silva; Silva, 2015) (Teixeira et al., 2009) (Ugulino et al., 2012) mas possuem limitações relacionadas com consumo de bateria e necessidade do usuário estar usando o dispositivo constantemente. O uso de câmeras auxilia no reconhecimento de atividades humanas. Quando o reconhecimento é feito através do uso de *wearable* somente, mais pontos de medição no corpo da pessoa são necessários. A Figura 4 mostra o esquema de posicionamento e orientação dos sensores e um usuário vestindo uma parte do dispositivo, no trabalho de (Ugulino et al., 2012). Uma das vantagens dos *wearable* é que quando o dispositivo está sendo usado e com bateria, o acompanhamento do usuário é realizado independentemente do local de onde ele estiver. O trabalho de (Cunha & Fuks, 2014) propôs as luzes de AAL como forma de reconhecer ADLs. A presença de fonte de energia, que possibilita o uso de

diversos sensores, e a ubiquidade dentro de moradias são alguns dos benefícios das luzes. A tarefa de identificar humanos é a mais alta da hierarquia de propriedades espaço-temporais (Teixeira; Dublon; Savvides, 2010). Variação nas condições de iluminação e planos de fundo em imagens de ambientes são desafios para o problema de identificação, assim como as diversas posturas em que o usuário pode estar, como por exemplo de costas para a câmera, que dificulta o reconhecimento facial. O trabalho de (Correa et al., 2011) propôs um sistema para robôs detectarem e identificarem humanos em ambientes domésticos usando dados de um sensor térmico e uma câmera.



Figura 4 - Wearable para reconhecimento de atividades humanas proposto por (Ugulino et al., 2012).

Deteção de desmaio e queda são tarefas de AAL relevantes, principalmente devido ao envelhecimento da população, e são considerados alguns dos principais problemas relacionados a idosos. Segundo o Centro de Controle e Prevenção de Doenças, do governo dos Estados Unidos da América, em 2008 aproximadamente 21,8 milhões de pessoas com 15 anos ou mais sofreram lesões não intencionais e não fatais (CDC, 2011), resultando em aproximadamente 67,3 bilhões de dólares em custos médicos (Finkelstein; Corso; Miller, 2006), sendo que 81% dessas lesões são por quedas e o local de maior ocorrência é no banheiro (Span, 2009). Há soluções na literatura para este problema baseados em câmeras térmicas de baixa resolução (16 x 16 pixels)

(Sixsmith; Johnson, 2004) e com maior resolução (320 x 240 pixels) (Wong et al., 2010). Soluções baseadas em câmeras térmicas têm a vantagem de sensoriar o ambiente independente da iluminação, diferente das câmeras RGB convencionais, o que pode ser fundamental para a detecção de uma queda no escuro.

A realidade econômica de países de terceiro mundo como o Brasil, onde a presente pesquisa foi realizada, motivou a escolha das tecnologias usadas para contribuir com a área de AAL. Soluções para sensoriar ambientes baseados em câmeras, como a de (Surie; Partonia; Lindgren, 2013), necessitam de computadores para fazer o processamento das imagens, por isso optei por usar um sensor de baixo custo cujos dados são processados por um microcontrolador também de baixo custo (descritos na seção 4.2.1). O uso de técnicas de aprendizado de máquina, junto com a criação de diversos datasets, foram as estratégias usadas para contornar a simplicidade dos dispositivos de hardware usados. A baixa oferta de sensores no Brasil e o alto custo para importa-los fazem com que seja necessário o desenvolvimento de softwares inteligentes para conseguirmos contribuir com o sensoriamento humano. Os *wearable* não foram considerados para o sensoriamento proposto pois o objetivo da presente pesquisa é tornar o ambiente assistivo, independente dos usuários estarem portando sensores ou não.

2.2.

Reconhecimento de posturas humanas

Postura é a primeira propriedade comportamental na taxonomia de (Teixeira; Dublon; Savvides, 2010), seguida de ação, atividade, comportamento, e por fim, comportamento em grupo. A fronteira entre essas propriedades não é bem definida na literatura, o trabalho de (Shang; Liu; Wang, 2014) diz que reconhece posturas no título (*Posture recognition for the elderly based on wireless sensor networks*) e tem *walking* e *falling down* dentre as classes para reconhecimento, que são verbos e indicam ações. Já no trabalho de (Silva; Silva, 2015), sentado e em pé estão entre as classes do problema de reconhecimento, e o título do artigo diz em reconhecimento de atividades humanas. Reconhecer a postura deitado na cama por muito tempo, no período da madrugada por exemplo, pode indicar que a pessoa está dormindo, que é uma atividade, ou com insônia. A mesma postura no

banheiro (sentado no vaso sanitário) indica duas atividades diferentes para homens e mulheres, i.e., urinando para mulheres e defecando para homens, mas isso dependerá também da cultura do local. Estes dois exemplos mostram que o sensoriamento humano depende do contexto dos dados coletados, que no exemplo da postura deitado na cama foi caracterizado pelas variáveis duração da postura, tempo e local, e no caso do banheiro pela variável gênero do usuário.

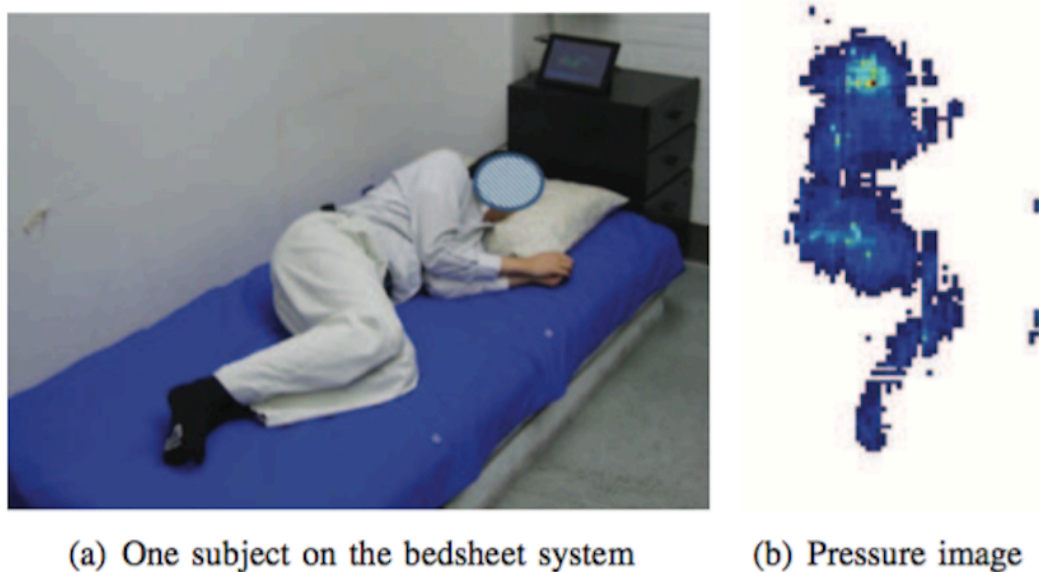


Figura 5 - Exemplo de imagem de pontos de pressão gerada (b) por usuário deitado na cama (a) no trabalho de (Liu, 2013).

A cama é um local importante para sensoriamento humano devido à importância do sono para a saúde. A qualidade do sono tem sido usada como indicador de diagnóstico de saúde em diversas aplicações médicas (Liu, 2013). A privacidade é um fator crítico para a escolha do tipo de sensoriamento de pessoas em camas, visto que o uso de câmeras não é aceito por alguns usuários. O trabalho de (Gaddam; Mukhopadhyay; Gupta, 2008) utilizou sensores de pressão para detectar a presença de pessoas em uma cama. O reconhecimento de posturas durante o sono foi pesquisado por (Liu, 2013), que desenvolveu um lençol com pontos sensíveis à pressão, gerando uma imagem que ilustra a distribuição de peso que o usuário faz no lençol (ver Figura 5).

2.3. Privacidade

Como visto acima, a privacidade é um assunto importante quando se trata de informações da vida de uma pessoa, e por isso, é preciso que o usuário de AAL tenha conhecimento da forma como ele é acompanhado, de que maneira e com quem seus dados são compartilhados. Em 24 de abril de 2014 foi instituído no Brasil o Marco Civil da Internet (Lei 12.965), que tem a privacidade como um de seus três pilares (Palácio do Planalto, 2015). O Marco Civil da Internet dá o direito à inviolabilidade e ao sigilo das comunicações pela internet para o usuário, salvo por ordem judicial. Uma das consequências deste direito é que as provedoras de serviço de internet não podem acessar os dados de seus clientes, isso vale para conteúdo de e-mails, redes sociais, lista de sites visitados, etc.

Câmeras de vigilância estão por todas as partes nos dias de hoje, porém seu uso é proibido em banheiros por causa da violação da intimidade de pessoas. O acompanhamento de pessoas, por câmeras, no quarto e no banheiro de suas casas requer uma preocupação extra com privacidade, pois no caso de vazamentos de dados ocorre uma exposição da intimidade dos usuários. Em AAL espera-se que o usuário autorize o compartilhamento dos dados sensorizados com as partes interessadas, estas partes definidas também por ele. O usuário de AAL também deve definir quais dos seus dados sensorizados são compartilhados com quais partes interessadas, como por exemplo autorizar somente médicos e familiares a terem acesso às imagens de uma câmera instalada no quarto, enquanto negar este acesso a vizinhos. Outro exemplo de configuração de compartilhamento de dados é restringir a notificação de ADLs somente para médicos, mas notificar todas as partes interessadas caso seja detectado uma situação de emergência, por exemplo uma queda.

O trabalho de (Teixeira; Dublon; Savvides, 2010) afirma que à medida que o sensoriamento humano se tornar ubíquo, a privacidade será um assunto inevitável, haverá um aumento da demanda de sensores que preservem a privacidade e que surpreendentemente poucas pesquisas têm tido foco nessas direções. Em uma pesquisa feita por (Doyle et al., 2011), com 9 pessoas (6 do sexo masculino, 3 do feminino e idades na faixa 60-79 anos), que investiga os requisitos para a entrega dos dados de assistência médica para as partes

interessadas, a privacidade foi a maior preocupação em relação ao processo de envio e armazenamento dos sensoriados. Nesta mesma pesquisa, o entrevistado com mais idade (79 anos) se mostrou preocupado com o que os pesquisadores seriam capazes de ver com os dados de sensores, além de querer ter certeza que os sensores não eram câmeras. Sensores que não têm a aparência de câmeras de vídeo convencionais diminuem a resistência dos usuários em serem acompanhados (Nakashima et al., 2010). Na pesquisa de (Sixsmith; Johnson, 2004), que acompanhou 28 pessoas com idades entre 65 e 82 anos, a maioria dos participantes preferiu imagens térmicas do que imagens de câmeras RGB com relação à preservação da privacidade. A Figura 6 é uma imagem gerada por uma câmera térmica de resolução 320 x 240 pixels, de uma pessoa em uma postura que antecede o desmaio.



Figura 6 - Exemplo de imagem gerada por câmera térmica de resolução 320 x 240 pixels.

Gravação de voz também pode levantar sérias preocupações relacionadas à invasão de privacidade (Liu, 2013), porém microfones simples, com baixa qualidade na captação de áudio, preservam a privacidade de conversa entre usuários e auxiliam no reconhecimento de atividades humanas. No trabalho de (Fogarty; Au; Hudson, 2006) foram utilizados microfones em canos de água de uma casa, com o objetivo de monitorar o acionamento de dispositivos que

utilizam água em seu funcionamento, como lavadora de roupas, lavadora de pratos, chuveiro, vaso sanitário e torneiras. Utilizando aprendizado de máquina os autores conseguiram diferenciar o uso dos diversos dispositivos, através dos dados dos microfones, que foram instalados sendo pressionados com fita adesiva em contato direto com os canos de água para a captação do áudio (ver Figura 7).




Figura 7 - Instalação de um microfone em um cano de água para monitorar o uso de dispositivos que utilizam água em uma casa (Fogarty; Au; Hudson, 2006).

A definição de privacidade em AAL ainda é subjetiva, podendo ter relação com o Marco Civil da Internet, onde preservar a privacidade de usuários significa não compartilhar seus dados digitais com quem não seja parte interessada destes, ou, uma vez que o usuário autoriza o compartilhamento de seus dados sensorizados, privacidade pode se relacionar com intimidade, e a preocupação do usuário passa a ser com o tipo de dados que as partes interessadas têm acesso. Por isso é importante que o usuário saiba o tipo de informação que está compartilhando, por exemplo, se é uma imagem sua no banheiro tomando banho ou apenas a informação que o chuveiro está ligado.

3 Trabalhos relacionados

Apresento neste capítulo os trabalhos encontrados na literatura que mais se assemelham com a presente pesquisa. As acurácias de nenhum trabalho foram usadas para comparar resultados diretamente com as acurácias deste, pois o conjunto de dados que usei é único (gerado nesta pesquisa). A comparação com os trabalhos apresentados neste capítulo é feita de forma qualitativa na Conclusão e nos Trabalhos Futuros (Capítulo 8).

Dois trabalhos (Taniguchi et al., 2014b) (Taniguchi et al., 2014a) de Taniguchi et al. usaram sensores térmicos para reconhecer posturas humanas em um quarto de enfermagem, sendo que a tarefa de um deles é pré-requisito para a tarefa do outro. A primeira tarefa investigada reconhece posturas humanas, previamente definidas, através de um diagrama de transição das posturas (ver Figura 9), e a segunda relaciona estas transições de posturas para conseguir detectar quedas.




Figura 8 - Exemplo dos dados gerados por dois sensores térmicos de resolução 16 x 16 pixels cada um (um no teto (a) e outro na parede (b)) e a respectiva imagem de uma câmera instalada no teto (c), em um quarto de enfermagem (Taniguchi et al., 2014).

Os dois trabalhos usaram a mesma configuração de hardware em seus protótipos e conduziram as pesquisas no mesmo local, um quarto de enfermagem com pé-direito medindo 250 cm. Dois sensores térmicos, de resolução 16 x 16 pixels cada um, foram os componentes de hardware utilizados para o sensoriamento humano, um instalado no teto e o outro na parede. A Figura 8 ilustra uma pessoa sentada na cama, sendo que (a) e (b) representam as temperaturas medidas pelos sensores instalados no teto e na parede respectivamente, e (c) é a imagem de uma câmera instalada no teto, capturada no mesmo momento em que as medições dos sensores foram registradas.




Fig. 6. Time-series posture transition diagram

TABLE I. EXPLANATION OF POSTURE TRANSITION DIAGRAM

| No. | explanation of each posture |
|-----|--------------------------------|
| 0 | None in the measurement area |
| 1 | Walking |
| 2 | Lying on the bed |
| 3 | Sitting on the bed |
| 4 | Sitting on the edge of the bed |
| 5 | Standing beside the bed |
| 6 | Falling from the bed |
| 7 | Falling |

Figura 9 - Diagrama de transição de posturas e suas respectivas explicações (Taniguchi et al., 2014).

O trabalho de (Kuki et al., 2012) propõe um método para registro de trajetória de movimento humano utilizando o mesmo sensor térmico de baixa resolução que a presente pesquisa utiliza, com 4 x 4 pixels de resolução e também instalado no teto (pé-direito medindo 273 cm). O método proposto consegue rastrear uma pessoa utilizando lógica *fuzzy* e a remoção do plano de fundo, sendo

que este último também foi implementado nesta dissertação. Uma das regras da lógica *fuzzy* utilizada considera que a temperatura do corpo de uma pessoa sempre é maior que a temperatura ambiente, por isso esta solução não é válida para ambientes onde a temperatura é maior ou igual 37 °C. Nesta remoção do plano de fundo, para identificar onde a pessoa se encontra, são descartados os pixels onde as temperaturas são menores que um determinado valor, que é definido em tempo de execução e é relativo à temperatura ambiente. O resultado do trabalho de (Kuki et al., 2012) é baseado no dataset gerado por eles, caracterizado por temperatura ambiente aproximada de 19°C, enquanto que a presente pesquisa gerou um dataset próprio para avaliação, com temperaturas ambientes variando de 21°C à 29°C. O reconhecimento da propriedade espaço-temporal localização é um objetivo em comum do meu trabalho e do (Kuki et al., 2012), mas as avaliações das soluções propostas foram feitas de formas distintas. Kuki et al. avaliaram a localização de uma pessoa em centímetros, enquanto que avaliei esta propriedade em um estudo de caso feito em um quarto mapeando dois locais: cama e ao lado da cama. Apesar deste trabalho relacionado também ter gerado dados do sensor térmico enquanto um participante estava em pé, deitado e sentado, o método proposto por eles não foi avaliado no reconhecimento destas posturas.

De acordo com a pesquisa feita por (Teixeira; Dublon; Savvides, 2010), sensores do tipo *wearable*, térmicos e câmeras apresentam bom desempenho no reconhecimento de propriedades espaço-temporais. O problema das câmeras é a questão de privacidade dos usuários, mas possuem alta resolução espacial e diversos tipos de informações sobre objetos e pessoas em uma cena, como tamanho, forma, cor e textura. Talvez por estas características, visão computacional tem sido uma importante área de pesquisa no sensoriamento humano. Dispositivos *wearable* não são usados em algumas situações devido ao estado de saúde ou deficiência de pessoas. Poucos trabalhos usando sensores térmicos foram encontrados na literatura. Um possível motivo é o recente lançamento destes com baixo custo, sendo que o sensor que a presente pesquisa utiliza foi lançado em 30 de junho de 2012 (fonte: www.omron.com, acessado em: 5 de janeiro de 2016). Este lançamento teve dois sensores térmicos com as resoluções 4 x 4 e 1 x 8 pixels. O sensor com resolução 16 x 16 usado por (Taniguchi et al., 2014) não foi encontrado para venda. A empresa FLIR (www.flir.com.br), que comercializa produtos de imagens térmicas, tem

disponível sensores térmicos com resolução de 80 x 60 pixels por 175 dólares (fonte: www.digikey.com, acessado em: 17 de novembro de 2016), que é aproximadamente o triplo do preço do sensor que a presente pesquisa utilizou. Sensores de movimento, bastante utilizados em escadas de edifícios para ligar luzes automaticamente quando o movimento de pessoas é detectado, não possuem bom desempenho no sensoramento humano, pois falham na detecção da primeira propriedade espaço-temporal (presença) caso as pessoas fiquem imóveis.

A presente pesquisa foi beneficiada pelo algoritmo C4.5 da área de aprendizado de máquina, publicado em um livro com autoria de Ross Quinlan em 1993, sendo que a implementação utilizada foi a do programa Weka (Hall et al., 2009) e se chama J48. O algoritmo de aprendizado supervisionado (AS) J48 constrói modelos preditivos de árvores de decisão baseado em dados rotulados, que no caso desta pesquisa foram previamente gravados com os nomes das posturas. Este processo é chamado de treinamento e é necessário em algoritmos de AS, i.e., aprendizado que utiliza dados previamente rotulados para criação de modelos preditivos. A técnica estatística validação cruzada foi usada para avaliar a capacidade de generalização dos modelos criados. Esta técnica consiste em dividir parte dos dados para treinar e outra para avaliar a acurácia de um modelo mais de uma vez, sendo que na presente pesquisa foi feita esta divisão 10 vezes para cada modelo criado. Desta forma, diferentes dados são selecionados a cada iteração da divisão, tanto para treinamento quanto para avaliação, então a acurácia do modelo é definida pela média das acurácias de cada divisão. Assim, a avaliação feita com validação cruzada garante que todos os dados do dataset sejam usados no treino e na avaliação do modelo. Depois do modelo treinado ele é usado para rotular novos dados, e.g., reconhecer posturas.

4

Visão geral da pesquisa

Após contextualizar os assuntos dos quais surgiram as motivações desta pesquisa, apresentados no capítulo 2, e pesquisar as contribuições já dadas pela literatura no capítulo 3, apresento neste capítulo uma visão geral da pesquisa que fiz. Na seção 4.1 discuto a contribuição que quero deixar com o presente trabalho, assim como as questões de pesquisa que guiaram todo o estudo. A seção 4.2 diz respeito à parte específica de Informática desta dissertação, que é dividida em hardware e software, e aborda as tecnologias que me auxiliaram a conduzir a pesquisa.

4.1. Objetivos

O desenvolvimento de uma solução para apoiar AAL foi a principal motivação da presente pesquisa. O reconhecimento de posturas humanas foi a tarefa que escolhi investigar, sendo que para resolvê-la, optei por usar um sensor térmico de baixa resolução, a fim de preservar a privacidade da pessoa que é acompanhada. A Figura 10 cita as contribuições que a presente pesquisa busca dar em cada assunto. A Figura 11 ilustra a ordem das motivações e escolhas que são a base da presente pesquisa, assim como apresentado no início deste parágrafo, e também cita dentro do círculo de cada motivação e escolha, assuntos importantes de acordo com a literatura, mas que não investiguei.

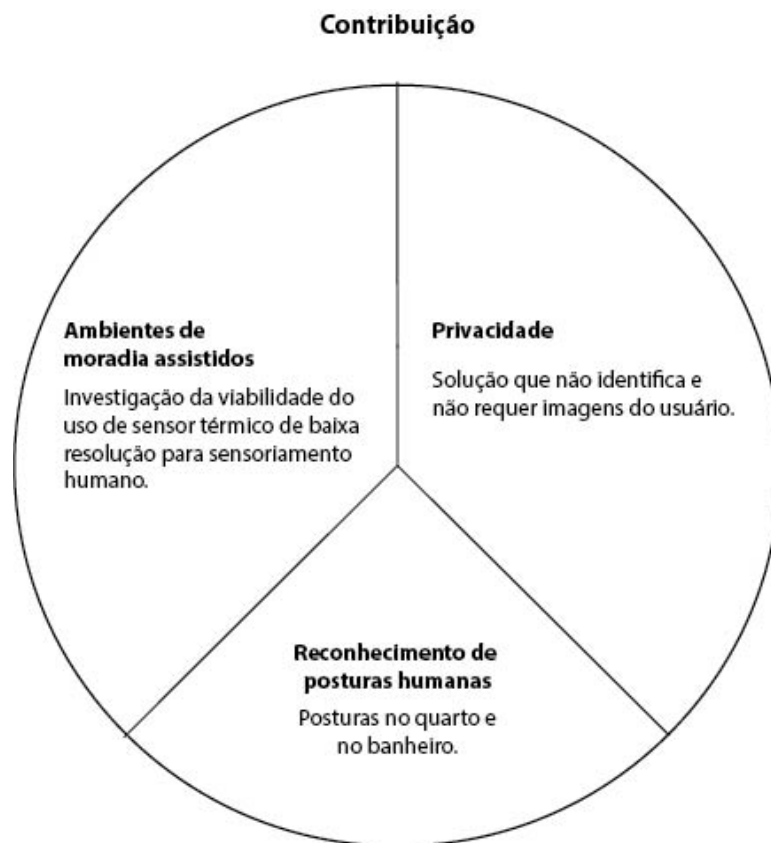


Figura 10 - Contribuições da presente pesquisa em cada assunto.

Meu objetivo é contribuir com uma pesquisa que se aproxime mais de situações reais de um ambiente de moradia, que seja investigado a influência de vestimentas, pois não encontrei nenhum trabalho na literatura fazendo esta investigação. Para os autores do trabalho (Teixeira; Dublon; Savvides, 2010) a variável vestimenta é um desafio para sistemas de visão computacional no sensoriamento humano, principalmente na tarefa de identificação, e também afirma que faltam estudos na literatura que tratem da vestimenta. Apesar da presente pesquisa não usar visão computacional, a vestimenta também afeta a leitura de temperaturas do sensor usado (ver seção 7.1).



Figura 11 - Motivações, tarefa e assuntos importantes, de acordo com a literatura pesquisada.

Todas as questões de pesquisa têm o objetivo de investigar a viabilidade de se usar um sensor térmico de baixa resolução (4 x 4 pixels) no sensoriamento humano, sendo que a principal investigação diz respeito ao reconhecimento de posturas, mas também investigo a viabilidade de usar o sensor para as tarefas de identificação e detecção de presença de pessoas. O trabalho de (Taniguchi et al., 2014b) evidenciou que é viável reconhecer posturas humanas usando dois sensores térmicos com resolução de 16 x 16 pixels de resolução cada, que resultam em 512 pixels de informações de temperatura, 32 vezes mais temperaturas que a presente pesquisa. Mesmo com esta quantidade maior de pixels, o trabalho de Taniguchi et al. também preserva a privacidade da pessoa sensoriada, pois não é possível construir uma imagem a partir dos dados de temperatura dos sensores. A investigação da viabilidade de se usar um sensor térmico com menor resolução tem o objetivo de diminuir o custo da solução, tornando possível usar componentes de hardware (sensor e microcontrolador)

mais simples, i.e., sensor com baixa resolução e microcontrolador com baixo poder de processamento, que possibilita o reconhecimento de posturas em tempo real por um programa rodando no próprio microcontrolador, não sendo necessário transmitir todas as temperaturas para um computador processá-las na nuvem por exemplo, que também auxilia na redução de custos, neste caso economizando com máquina e banda de internet. A principal questão da presente pesquisa é:

- É viável usar um sensor térmico de resolução 4 x 4 pixels, instalado no teto de um ambiente de moradia, com o objetivo de reconhecer posturas humanas?

Também são consideradas as seguintes questões:

- É viável usar um sensor térmico de resolução 4 x 4 pixels, instalado no teto de um ambiente de moradia, com o objetivo de detectar a presença de pessoas?
- É viável usar um sensor térmico de resolução 4 x 4 pixels, instalado no teto de um ambiente de moradia, com o objetivo de identificar pessoas?

4.2. Protótipo

O protótipo usado nesta pesquisa contou com componentes de hardware que possibilitaram a implementação de uma solução para acompanhar os voluntários executando as posturas. Para integrar alguns destes componentes de hardware, coletar dados e fazer as análises necessárias para atingir os objetivos desta pesquisa, foi necessário desenvolver componentes de software específicos em diferentes linguagens de programação. O hardware e o software serão detalhados a seguir, dentro desta seção.

4.2.1. Hardware

Esta seção descreve os componentes de hardware que usei para o desenvolvimento do protótipo e para as análises quantitativas dos dados gerados. Os componentes de hardware usados nesta pesquisa não foram desenvolvidos ou modificados por mim.

D6T Operation principle




Figura 12 - Funcionamento do sensor. Fonte: datasheet.octopart.com/D6T8L06-Omron-datasheet-12469928.pdf (acessado em: 25 de julho de 2016).

A persistência e o processamento dos dados foram executados por um laptop (MacBook Air) com as seguintes especificações: processador 1,3 GHz Intel Core i5, memória de 4GB 1600 MHz DDR3 e rodando o sistema operacional OS X El Capitan versão 10.11.6.





Figura 13 - Campo de visão e distribuição de pixels do sensor. Fonte: <https://www.omron.com/ecb/products/pdf/en-d6t.pdf> (acessado em: 25 de julho de 2016).

O hardware utilizado para medir as temperaturas na pesquisa foi o sensor térmico D6T-44L da Omron (OMRON Corporation, 2012). Seu funcionamento é parecido com o de uma câmera infravermelho, porém tem baixíssima resolução (4 x 4 pixels) e cada pixel representa uma temperatura. O Omron D6T-44L também tem um sensor de temperatura ambiente acoplado, que possibilita entender a relação da temperatura que o sensor mede, em comparação com a temperatura onde ele está instalado. As figuras 12, 13 e 14 foram retiradas de manuais técnicos do sensor, fornecidos pelo fabricante. A Figura 12 ilustra, de forma simples, como o sensor funciona, a Figura 13 mostra como o sensor lê e distribui os pixels com as informações de temperatura, e a Figura 14 mostra o alcance de detecção de temperaturas, baseado na temperatura ambiente em que o sensor está.

Temperature detecting range of the object



10

Figura 14 - Relação da temperatura ambiente com o alcance da temperatura medida pelo sensor. Fonte: datasheet.octopart.com/D6T8L06-Omron-datasheet-12469928.pdf (acessado em: 25 de julho de 2016).

O Arduino UNO (Arduino, 2016) foi escolhido para a implementação da funcionalidade de se comunicar com o sensor e repassar os dados para o laptop. Optei por este microcontrolador pelo fato dele ter um baixo custo, e além disso, segundo o próprio site oficial do produto, o mesmo é o microcontrolador mais usado e documentado da família Arduino & Genuino. Também de acordo com o

site oficial do produto, o Arduino UNO foi o primeiro a ser usado junto com o Arduino Software (IDE) 1.0 e é referência para as versões mais novas do Arduino, o que faz entender que essa é uma boa escolha para o usar na pesquisa, devido ao grande número de usuários deste hardware. Esses fatos vão ao encontro de um dos objetivos dentro da pesquisa, que é contribuir com uma solução que tenha um baixo custo para implementação, quando comparado com soluções baseadas em processamento de imagens.




Figura 15 - Instalação do protótipo no quarto.

Estes foram alguns desafios para usar o Arduino UNO na pesquisa: ausência de hardware para comunicação sem fio com o laptop, ausência de memória interna para persistência dos dados e falta de bateria para que ele possa pegar energia para funcionar sem a necessidade de fio. Há soluções para todos estes desafios levantados. Diversos fabricantes de hardware desenvolvem *shields* que se conectam no Arduino UNO e os mesmos possuem funcionalidades para contornar o problema da ausência de fonte de energia, comunicação sem fio e persistência de dados. O BLE Shield da Red Bear Lab (<http://redbearlab.com/bleshield/>,

acessado em: 25 de julho de 2016) é um exemplo de hardware projetado para integração com o Arduino UNO e possibilitar que ele se comunique usando o protocolo Bluetooth Low Energy com outros dispositivos. Porém, para uma rápida implementação do protótipo para a pesquisa, a opção escolhida foi utilizar um cabo de comunicação via porta serial de 5 metros. Este cabo conecta o Arduino com a porta USB do laptop e soluciona os problemas de fonte de energia e comunicação.




Figura 16 - Componentes de hardware do protótipo.

O preço dos componentes de hardware usados nesta pesquisa, sem contar com o laptop, fios, resistores e a *protoboard* do circuito montado, estão listados em Dólar Americano na Tabela 1. O componente mais caro é o sensor térmico da OMRON (\$52). O valor total dos componentes é de \$87. A Figura 16 ilustra os componentes de hardware utilizados no protótipo e como foi sua configuração física. A Figura 15 ilustra como foi sua instalação no quarto.

Tabela 1 - Preço dos principais componentes de hardware.

| Nome | Preço (US\$) |
|--------------------------------|--------------|
| Sensor OMRON D6T-44L | 52 |
| Arduino UNO | 25 |
| Cabo serial de 5 metros | 10 |
| TOTAL | 87 |

Antes de usar o Arduino UNO, montei um protótipo usando o *single computer* SeeedStudio BeagleBone Green (<https://beagleboard.org/green>, acessado em: 20 de abril de 2016), porém não tive sucesso na comunicação dele com o sensor. Também tive problema com o BeagleBone em conectá-lo ao laptop. Após procurar na Internet, encontrei usuários comentando no fórum do fabricante (<http://beagleboard.org/Community/Forums>, acessado em: 20 de abril de 2016) que o *driver* indicado para a comunicação do mesmo com o sistema operacional que usei (OS X El Capitan Versão 10.11.6) não estava funcionando. Segundo usuários do fórum, este *driver* funciona em uma versão anterior deste sistema operacional, mas tornou-se incompatível com a atualização para o OS X El Capitan, que tinha sido lançado há poucas semanas quando fiz esta tentativa (início de 2016).

4.2.2. Software

A parte de software é composta por programas desenvolvidos em três diferentes linguagens de programação: Arduino, Processing (Fry; Reas, 2011) e R (R Development Core Team, 2008). O arcabouço de aprendizado de máquina usado foi o Weka.

O programa em Arduino é responsável por receber os dados do sensor, i.e., temperatura ambiente e mais 16 valores de temperatura referentes ao campo de visão, sendo que esta comunicação é feita através do protocolo *Inter-integrated Circuit* (I2C). Uma vez que os dados do sensor são lidos, o programa os transmite via porta serial.

A recepção dos dados é feita por um programa em Processing, que tem as funcionalidades de visualização e persistência das temperaturas. A interface de

visualização consiste em uma matriz 4 x 4, onde cada elemento da matriz contém impresso o valor da temperatura medido naquele instante, sendo que os valores se atualizam à medida que novas temperaturas são recebidas. Cada elemento também tem a cor de seu plano de fundo alterada conforme as temperaturas são atualizadas. A cor de plano de fundo de cada elemento é definida dinamicamente e é baseada no sistema RGB de cores, sendo que quanto maior a temperatura mais vermelho e menos azul, e quanto menor a temperatura mais azul e menos vermelho tem na cor, a quantidade de verde não se altera e é mantida com o valor zero. Esta escolha de cores levou em conta o fator cultural, pois somos acostumados a relacionar o vermelho com quente e azul com frio (Rheingans, 2000). A Figura 17 ilustra a interface deste programa desenvolvido em Processing.




Figura 17 - *Print* do visualizador de temperaturas desenvolvido em Processing.

As análises e gráficos dos dados presentes neste documento foram realizadas em *scripts* desenvolvidos em R, exceto as análises de aprendizado de máquina (acurácias de reconhecimento, matrizes de confusão e os modelos de árvore de decisão). O dataset, incluindo a parte de engenharia de atributos, foi gerado no R.

O arcabouço de aprendizado de máquina Weka teve um papel importante na presente pesquisa, pois é baseado nas suas acurácias das árvores de decisão e matrizes de confusão geradas que respondo as questões de pesquisa.

5

Método de pesquisa

Depois das questões de pesquisa definidas, a escolha de um método de pesquisa foi o meu próximo passo. Diferentes questões necessitam de diferentes abordagens para respondê-las. De acordo com (Pimentel & Fuks, 2011), as questões de pesquisa e o nível de conhecimento prévio do pesquisador a respeito do fenômeno a ser estudado influenciam na escolha do método de pesquisa.

O resultado desta pesquisa é contribuir com um estudo que tenha enfoque no realismo, em vez de generalização ou precisão (Dennis & Valacich, 2001). Mais especificamente, o objetivo é entender como algumas variáveis influenciam no objetivo desta pesquisa.

A Figura 18, extraída de um documento do fabricante do sensor, mostra como a distância até uma pessoa afeta a leitura de temperatura. Uma variável é identificada então: a distância. Desta forma, duas pessoas com alturas diferentes são diferenciáveis com os dados deste sensor. Mas qual será a diferença mínima de altura para que se possa fazer essa diferenciação? Não respondo essa pergunta específica, mas tento reconhecer os diferentes voluntários (com alturas diversas) utilizando um algoritmo de aprendizado de máquina. Outra forma de alterar essa variável é considerar ambientes diferentes, com pés-direitos diferentes, pois o sensor foi instalado no teto. Da mesma forma que a distância altera os dados, o peso altera também, se for considerado que uma pessoa mais pesada ocupa uma área maior do campo de visão do sensor do que uma mais leve. Esta diferença da “área” de uma pessoa para outra provavelmente é pequena, mas somada com a diferença de altura, facilitará para um modelo de aprendizado de máquina conseguir diferenciar duas pessoas, previamente conhecidas pelo modelo. Investiguei também a influência da temperatura ambiente, já que a temperatura corporal é aproximadamente 37 graus centígrados, como será a temperatura de uma pessoa, medida pelo sensor, quando o mesmo está instalado em um ambiente que está em uma temperatura acima dos 37 graus centígrados? Esta pergunta específica não foi respondida, pois, apesar da pesquisa ter sido feita no Rio de

Janeiro, que no verão tem temperaturas acima de 40 graus centígrados, no inverno (período da pesquisa) não tivemos temperaturas tão altas. A temperatura máxima (medida pelo sensor) durante a pesquisa foi de 29 graus centígrados. Por fim, investiguei a influência das vestimentas. Por exemplo, uma pessoa com menor estatura e menos peso que outra, representa menos calor para o sensor, mas se a pessoa que tem maior estatura e mais peso estiver usando mais vestimenta, i.e., com menos partes do corpo (fontes de calor) expostas ao sensor, a temperatura de ambos tende a ser a mesma.

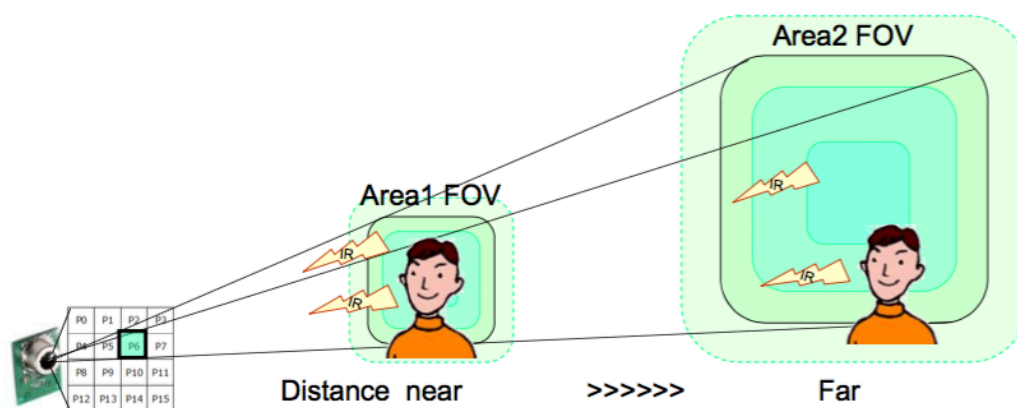


Fig.5 Changing factor of measurement by distance

Note: The occupied area in FOV becomes smaller with increasing distance and the background temperature prevails.

Figura 18 - Exemplo de como a distância afeta a leitura de temperatura pelo sensor. Fonte: datasheet.octopart.com/D6T8L06-Omron-datasheet-12469928.pdf (acessado em: 25 de julho de 2016).

Todas estas variáveis identificadas também adicionam limitações na pesquisa. Não é possível generalizar as análises para outros ambientes, outros usuários e nem para situações em que são usadas vestimentas diferentes das que conduzi a pesquisa. Também é limitação da pesquisa não investigar a influência de outras fontes de calor, que em uma situação real certamente ocorrem, como por exemplo, a presença de equipamentos eletrônicos, animais domésticos, cigarros, incensos, outras pessoas, comida ou bebida quente, etc.

Estudo de caso foi o método de pesquisa escolhido. Segundo (Pimentel & Fuks, 2011), este método é sugerido quando não se conhece todas as variáveis que influenciam um fenômeno, e também quando se busca realizar a investigação em

um contexto real, sem a necessidade ou possibilidade de ter total controle das variáveis (precisão). Estes são objetivos do estudo empírico realizado, entender as variáveis envolvidas nos contextos investigados, assim como evidenciar a viabilidade de se usar um tipo específico de sensor para responder as questões de pesquisa descritas na seção 4.1. A temperatura ambiente é um exemplo de variável que é investigada, mas não teve controle de sua variação durante a observação do fenômeno. A Figura 19, retirada do livro de (Pimentel & Fuks, 2011), mostra as fases do método estudo de caso, que guiaram esta pesquisa e estão detalhadas nos capítulos 6 e 7.



Figura 25.1. Fases do método estudo de caso

Figura 19 - Fluxograma do método estudo de caso. Fonte: Livro de (Pimentel & Fuks, 2011).

O método de pesquisa experimento também auxilia o pesquisador quando a questão de pesquisa necessita de respostas que expliquem o por que e como o fenômeno acontece. O experimento também é indicado em situações onde se deseja entender melhor o fenômeno estudado, mas ele requer que se tenha controle das variáveis (Yin, 2003). Por exemplo, a temperatura ambiente, uma variável que não teve controle no estudo de caso, necessitaria ser controlada durante um experimento.

6

Estudo de caso

Neste capítulo detalho como a pesquisa foi executada. Com exceção das fases “Analisar dados” e “Comunicar resultados”, mostradas na Figura 19, todas as outras fases estão descritas. Antes de executar o estudo de caso, fiz um estudo exploratório (Ugulino, 2014) com a intenção de verificar se as variáveis descritas no capítulo 5 realmente influenciam na leitura das temperaturas pelo sensor, e também para testar o funcionamento do protótipo desenvolvido. Este estudo é descrito na seção 6.1 e contém as análises dos dados gerados, que serviram de base para o projeto do estudo de caso, que é descrito na seção 6.2. As seções 6.2.1 e 6.2.2 descrevem os dois ambientes em que conduzi o estudo de caso. Apesar da pesquisa ter sido feita em dois ambientes diferentes, o estudo de caso é o mesmo, pois o fenômeno e as variáveis investigadas são as mesmas. Por fim, o perfil dos quatro voluntários que participaram na pesquisa é descrito na seção 6.3.

6.1.

Estudo exploratório

O estudo exploratório teve o objetivo de verificar o funcionamento do protótipo e fazer uma primeira análise dos dados. O tempo total de duração da leitura de dados deste estudo foi de 2 horas 36 minutos e 17 segundos, que gerou 25.319 medições (dataset do estudo exploratório).

A frequência com que o Arduino recebeu os dados do sensor e se comunicou com o laptop, via porta serial, para a persistência dos dados, foi de 2,7 hertz. O histograma dos tempos de intervalo entre as medições é ilustrado na Figura 20. Este histograma mostra somente os intervalos de tempo de até 1 segundo, que representam 96,31% do dataset do estudo exploratório. A porcentagem de pacotes com erro lidos do sensor foi outra informação para avaliar o funcionamento do protótipo. O manual técnico do sensor diz como fazer a verificação de erro em um pacote lido, e após este algoritmo implementado, verifiquei que 1,86% do dataset gerado no estudo exploratório contém erro. O

manual diz que este erro significa que a medição não é confiável, mas a análise feita com estas medições não apresentou evidências de anormalidade. Cada medição indicada com erro, com índice i , foi comparada com as medições de índice $i + 1$ e $i - 1$, i.e., medições coletadas logo antes e após à medição com erro indicado, sendo que as medições com índice $i + 1$ e $i - 1$ não foram indicadas com erro pelo sensor. O resultado da análise foi que, apenas 0,02% do dataset gerado no estudo exploratório foi indicado com erro pelo sensor e algum pixel do campo de visão com diferença maior que 0,2 grau centígrado em relação às medições $i + 1$ e $i - 1$. Esta análise indica que as medições com erro são praticamente iguais às que não contém erro e, desta forma, as medições indicadas com erro pelo sensor não foram excluídas dos datasets gerados e estão incluídas nas análises da presente pesquisa.




Figura 20 - Análise da frequência dos dados do sensor.

Um lençol e um cobertor foram usados para evidenciar o efeito que a quantidade de vestimenta tem na leitura de calor pelo sensor. Um voluntário permaneceu deitado em uma cama enquanto a medição das temperaturas estava sendo feita. Primeiro, o voluntário permaneceu deitado na cama usando somente sua vestimenta, depois ele se cobriu com o lençol, e por fim se cobriu com o cobertor. O gráfico ilustrado na Figura 21 mostra estas medições na ordem

mencionada e mostra que, apesar da temperatura ambiente aumentar, a média das temperaturas medidas diminui, confirmando que vestimentas diminuem a quantidade de calor medida pelo sensor.




Figura 21 - Análise do uso de vestimentas (deitado na cama)

Posturas iguais executadas na cama e no chão, pelo mesmo voluntário, foram medidas pelo sensor com o objetivo de analisar a variável distância. Os dados das posturas “deitado” e “sentado” foram utilizados nesta análise. Nestas duas posturas o voluntário usou somente a vestimenta que já estava usando, que foi a mesma para ambas as posturas. Os gráficos ilustrados na Figura 22 e na Figura 23 mostram as medições das temperaturas nas posturas “deitado” e “sentado” respectivamente. Os primeiros valores (menor índice de medição) dos dois gráficos são relativos à postura executada na cama, e depois são os valores da postura executada no chão. Estes dois gráficos mostram que as médias das temperaturas medidas diminuem quando as posturas são executadas no chão, i.e., a uma distância maior do sensor até o voluntário.




Figura 22 - Análise da distância (deitado na cama e no chão).

As temperaturas mostradas com círculos nos gráficos da Figura 21, da Figura 22 e da Figura 23 são as médias das matrizes de temperaturas (média das 16 temperaturas) medidas dentro do campo de visão do sensor. Assim, as variações destas médias de temperaturas, nestes três gráficos, foram bem pequenas, pois o voluntário ocupava no máximo metade dos pixels do campo de visão do sensor e a outra metade permanecia aproximadamente a mesma.




Figura 23 - Análise da distância (sentado na cama e no chão).

Os valores destes três gráficos mostram que a temperatura ambiente medida pelo sensor é maior que a média das temperaturas medidas dentro do seu campo de visão, mesmo com a presença de um voluntário e esta temperatura ambiente sendo menor que 26 graus centígrados (9 graus centígrados menos que a temperatura corporal do voluntário). Além da distância, o fato do sensor de temperatura ambiente estar acoplado no sensor térmico, que está bem próximo do Arduino, e tanto o sensor térmico quanto o Arduino estavam processando dados sem parar e sem um dispositivo para resfriamento, provavelmente influenciou nas altas temperaturas ambiente medidas.

6.2.

Projeto do estudo de caso

O estudo de caso realizado na presente pesquisa (Yin, 2003) (Pimentel & Fuks, 2011) tem as seguintes características:

- **Tipo de pesquisa:** quantitativa e qualitativa.
- **Técnica de coleta de dados:** medição.

- **Fontes de dados:** dataset gerado, *prints* de tela do programa de visualização das temperaturas, modelos de aprendizado de máquina criados e informações do manual técnico do sensor.
- **Avaliação:** matrizes de confusão e acurácias dos modelos de aprendizado de máquina criados.

Os voluntários usaram vestimentas e executaram posturas definidas previamente. Cada postura com uma determinada vestimenta foi executada durante aproximadamente 1 minuto. Os voluntários foram orientados a executarem as posturas simulando situações reais próprias de cada um (Dennis & Valacich, 2001). Por exemplo, sugeri para que os voluntários ficassem com posturas parecidas com as que costumam e se sentem confortáveis na hora de dormir na postura definida “deitado na cama”, ficando livres para deitar de lado, se encolher, permanecer de barriga para cima ou de bruços, por exemplo.

A avaliação da viabilidade de usar o Omron D6T-44L para reconhecer pessoas/posturas e detectar presença humana se deu através do dataset criado no estudo de caso, projetado nesta seção. Com base no dataset foram criados modelos de aprendizado de máquina, que tiveram suas acurácias e matrizes de confusão analisadas.

O estudo de caso é caracterizado pela coleta de dados em quatro dias diferentes no quarto e um dia no banheiro, com temperaturas ambientes que variaram entre 21 e 25,1°C, sendo que o dia da coleta de dados no banheiro foi em temperatura ambiente de 21°C. Em dois dias da coleta de dados no quarto, só o voluntário C participou das medições, já nos outros dois dias todos os quatro voluntários participaram.

A métrica de avaliação acurácia, usada na presente pesquisa, diz qual a porcentagem de acerto de reconhecimento das medições e é adequada para avaliar o reconhecedor do meu estudo, pois sabendo a proporção de acerto consigo dizer se um modelo criado é aceitável ou não, e também comparar com outros trabalhos. Não usei precisão e *recall* (duas métricas de avaliação comuns em aprendizado de máquina) pois os modelos criados tem o objetivo de acertar todas as classes, e estas métricas servem para avaliar a proporção de falsos negativos e falsos positivos de uma classe específica. Vamos supor que o objetivo da presente pesquisa fosse reconhecer a classe deitado no chão, porque esta postura provavelmente indica que o usuário caiu, então as métricas precisão e *recall*

seriam boas, pois iriam dizer a proporção de acerto que a classe fosse deitado no chão, e eu iria saber se o modelo criado é aceitável em reconhecer esta classe específica. Também podemos imaginar as métricas precisão e *recall* boas para avaliar o reconhecimento de fraudes em transações bancárias, pois dentre os diversos tipos de transação, a classe associada à fraude certamente tem uma importância muito grande em ser reconhecida e, portanto, necessita de uma métrica de avaliação própria.

As matrizes de confusão são ideais para avaliar as medições reconhecidas erroneamente pelo modelo. Vamos supor que o objetivo de um modelo é diferenciar os voluntários e que a altura da pessoa é a variável mais relevante para esta tarefa. Agora vamos supor que o voluntário A é o mais alto, C o mais baixo e B o do meio. Se a classe de uma dada medição é A e o modelo diz que é B, esse erro é “menor” que se o modelo tivesse dito C.

Como o Arduino UNO só tem 2KB de memória RAM, árvore de decisão foi o único algoritmo para gerar os modelos de aprendizado de máquina usados, pois este modelo gera a classe de saída (resposta da tarefa) a partir de *ifs* e *elses* aninhados, que são definidos previamente no treinamento da árvore e requerem pouca memória para serem processados. Contudo, devido ao tempo para conclusão desta dissertação, não foi possível implementar os modelos de árvore de decisão no Arduino.

6.2.1. Quarto

O dataset gerado dentro de um quarto de um apartamento com cama de solteiro e chão com revestimento cerâmico contém as seguintes classes:

- 1) Deitado na cama.
- 2) Deitado na cama usando cobertor.
- 3) Sentado na cama.
- 4) Sentado no chão.
- 5) Deitado no chão.
- 6) Em pé.
- 7) Em pé usando muita vestimenta.
- 8) Ninguém.




Figura 24 - Imagem com o objetivo de simular o campo de visão do sensor no quarto.

Além das posturas deitado, sentado e em pé, gravei dados com o quarto vazio a fim de criar uma árvore de decisão que também reconheça quando não há ninguém no campo de visão do sensor. As classes 4, 5, 6 e 7 foram executadas pelos voluntários ao lado da cama. Quando a classe não menciona o uso de cobertor ou muita vestimenta (classes 1, 3, 4, 5 e 6), significa que o voluntário executou a postura usando vestimentas típicas de um dia quente, i.e., descalço, vestindo camiseta de manga curta e bermuda, com exceção do autor desta dissertação, que vestiu apenas sunga, a fim de gerar dados que dificultem a árvore de decisão na tarefa de diferenciar pessoas. Na classe 7 o voluntário ficou em pé ao lado da cama usando vestimentas típicas de um dia frio, i.e., vestindo tênis, calça e casaco.




Figura 25 - Quarto onde a presente pesquisa foi feita e suas características.

As figuras 24 e 25 ilustram o quarto onde a presente pesquisa foi feita. As áreas sombreadas nas figuras têm o objetivo de ilustrar o campo de visão do sensor.

6.2.2. Banheiro

O dataset gerado dentro de um banheiro de um apartamento com chão com revestimento cerâmico contém as seguintes classes:

- 1) Deitado dentro do box.
- 2) Em pé dentro do box.
- 3) Em pé em frente à pia.
- 4) Em pé em frente ao vaso sanitário.
- 5) Em pé em frente ao vaso sanitário usando muita vestimenta.
- 6) Sentado no vaso sanitário.
- 7) Sentado no vaso sanitário usando muita vestimenta.
- 8) Ninguém.




Figura 26 - Imagem com o objetivo de simular o campo de visão do sensor no banheiro.

Começando pela classe 8, assim como no estudo de caso executado no quarto, o dataset gerado no banheiro também tem temperaturas medidas enquanto não havia ninguém no campo de visão do sensor. O voluntário usou vestimentas típicas de frio nas medições das classes 5 e 7 e vestimentas típicas de verão nas outras seis classes. O autor desta dissertação vestiu apenas sunga como vestimenta típica de verão, e os demais voluntários se vestiram da mesma forma que no estudo de caso executado no quarto (seção 6.2.1). As posturas são as mesmas das executadas no quarto: deitado, sentado e em pé. Os voluntários executaram posturas em quatro locais dentro do banheiro: dentro do box, em frente à pia, sobre o vaso sanitário e em frente ao vaso sanitário.




Figura 27 - Banheiro onde a presente pesquisa foi feita.

As figuras 26 e 27 ilustram o banheiro onde a presente pesquisa foi feita. As áreas sombreadas nas figuras têm o objetivo de ilustrar o campo de visão do sensor. Como o banheiro tem pé-direito menor que o quarto, não foi possível fazer um posicionamento no teto que sensoriasse toda a área do box e os voluntários por completo quando estivessem em frente ao vaso sanitário.

6.3. Voluntários

Depois de identificar variáveis que influenciam nos dados de temperatura e projetar o estudo de caso, fui à procura de voluntários que auxiliem a evidenciar a relação dessas variáveis com os dados gerados pelo sensor, i.e., pessoas com o máximo de diferença de altura e peso entre elas. Somente conhecidos foram selecionados devido à inconveniência de se executar as posturas, sendo requisitados para executá-las com muita e pouca vestimenta, e pelo fato do local de instalação do protótipo para a pesquisa ser íntimo (banheiro e quarto da casa do autor desta dissertação). A Tabela 2 mostra o perfil de cada voluntário, ordenados pela altura. O campo ID representa a forma como escolhi chamá-los daqui em diante nesta dissertação, sendo que A é o voluntário com maior estatura e D o com menor. O C é o autor desta dissertação. Entendo que o fato do autor ter

participado do estudo não cria um viés na pesquisa, pois sou incapaz de manipular meu peso, altura, ou temperatura corporal durante a execução das posturas.

Tabela 2 - Perfil dos voluntários.

| ID | Altura (m) | Peso (kg) | Sexo | Idade (anos) |
|-----------|-------------------|------------------|-------------|---------------------|
| A | 1,80 | 75 | Masculino | 27 |
| B | 1,79 | 79 | Masculino | 30 |
| C | 1,73 | 66 | Masculino | 29 |
| D | 1,60 | 64 | Feminino | 27 |

O estudo contou com quatro voluntários no total. A maior diferença de altura entre os voluntários é de 20 cm e de peso é 15 kg. Todos os voluntários foram questionados, antes do início da execução das posturas, se achavam que estavam em algum estágio de febre, por menor que seja, e todos responderam não. Outra variável, que não foi estudada nesta pesquisa, mas que pode influenciar nos dados de temperatura, é o tamanho/volume do cabelo.

7 Resultados

Este capítulo inicia apresentando as seguintes análises de dados feitas: investigações da influência da altura dos voluntários, uso de vestimentas e temperatura ambiente. Após estas análises, são apresentados dados que foram medidos enquanto o voluntário D dormia na cama do quarto e logo após se levantar. Por fim, a parte de aprendizado de máquina feita na presente pesquisa é apresentada e discutida, assim como as acurácias dos reconhecimentos de voluntários, posturas e detecção de presença.

```
% 1. Title: Thermal data for Master's Thesis
%
% 2. Sources:
%   (a) Creator: Bruno Silva Pontes
%   (b) Date: October, 2016
%
@RELATION thermal
|
@ATTRIBUTE HottestDiff NUMERIC
@ATTRIBUTE HottestPixels NUMERIC
@ATTRIBUTE HeatDiscontinuity NUMERIC
@ATTRIBUTE HeatSD NUMERIC
@ATTRIBUTE HeatSum NUMERIC
@ATTRIBUTE HeatMean NUMERIC
@ATTRIBUTE FirstHeatBed NUMERIC
@ATTRIBUTE FirstHeatFloor NUMERIC
@ATTRIBUTE SecondHeatBed NUMERIC
@ATTRIBUTE SecondHeatFloor NUMERIC
@ATTRIBUTE class {DeitCama,SentCama,EmPe,SentChao,DeitChao}
@DATA
33.7,11,0,13.4,198.5,18.0,1,0,1,0,DeitCama
33.7,11,0,13.3,199.5,18.1,1,0,1,0,DeitCama
33.7,11,0,13.1,200.0,18.2,1,0,1,0,DeitCama
33.7,11,0,13.2,202.5,18.4,1,0,1,0,DeitCama
32.7,10,0,12.6,190.8,19.1,1,0,1,0,DeitCama
33.7,10,0,12.6,194.2,19.4,1,0,1,0,DeitCama
32.7,10,0,12.4,186.2,18.6,1,0,1,0,DeitCama
```

Figura 28 - Exemplo de arquivo com extensão arff gerado para reconhecimento de posturas.

Para alcançar os resultados apresentados neste capítulo, foram desenvolvidos programas em três linguagens de programação: Arduino, Processing e R. Após o programa em Arduino ler os dados do sensor, ele os envia através da porta serial para o programa em Processing, que faz a persistência dos seguintes dados para cada medição: temperatura ambiente, dezesseis valores de temperatura referentes ao campo de visão do sensor, dígito para verificar se houve erro na medição, diferença de tempo da medição anterior em milissegundos e data e hora da medição corrente. Para cada medição de postura, de cada voluntário e em cada cômodo, foi gerado e persistido um arquivo texto. O programa em R fez o pré-processamento dos arquivos texto persistidos pelo Processing, gerando arquivos com extensão arff, que são usados pelo Weka para criação e avaliação dos modelos de aprendizado de máquina, assim como as avaliações dos atributos. Para cada tarefa de reconhecimento e dataset avaliado, foi gerado um arquivo arff com os atributos e respectivas classes de cada tarefa.

A Figura 28 ilustra um exemplo de arquivo arff usado para o reconhecimento de posturas. A imagem é um *print* das primeiras linhas do arquivo, que começa com um cabeçalho para livre preenchimento, seguido da definição dos nomes e tipos dos atributos, que são iniciados pela *string* @ATTRIBUTE. Também iniciado pela mesma string, mas chamado de class, são definidas as classes para reconhecimento, que o respectivo arquivo arff contém os dados. Por fim, após a *string* @DATA, os dados com os valores dos atributos e suas respectivas classes rotuladas são inseridos. Neste exemplo, estão ilustradas sete instâncias referentes à classe da postura deitado na cama.

7.1.

Explorando os dados

A influência da vestimenta nas temperaturas medidas no campo de visão do sensor foi a primeira análise feita. As tabelas 3 e 4 contêm os resultados da análise.

Tabela 3 - Médias dos pixels de maior temperatura em cada medição, nas posturas em pé em frente ao vaso sanitário (4) e em pé em frente ao vaso sanitário usando muita vestimenta (5), no banheiro.

| Voluntário | Postura 4 (°C) | Postura 5 (°C) |
|-------------------|-----------------------|-----------------------|
| A | 23,7 | 22,8 |
| B | 23 | 22 |
| C | 22,9 | 22,3 |
| D | 22,7 | 22,5 |

Para a análise do uso de vestimentas foram consideradas posturas iguais, porém com a diferença da quantidade de vestimenta que os voluntários vestiram. As colunas da postura 4 da Tabela 3 e da postura 6 da Tabela 4 representam as posturas sendo executadas com vestimentas típicas de verão, enquanto as colunas da postura 5 da Tabela 3 e da postura 7 da Tabela 4 representam as posturas sendo executadas com vestimentas típicas de inverno. As temperaturas destas tabelas foram calculadas da seguinte forma: para cada medição do sensor, foram selecionados os pixels com maior temperatura, i.e., o pixel onde o calor do voluntário está mais concentrado, em seguida foi calculado a média destes valores. Em todos os voluntários destas tabelas as médias das temperaturas diminuíram quando as posturas foram executadas com mais vestimenta.

Tabela 4 - Médias dos pixels de maior temperatura em cada medição, nas posturas em pé (6) e em pé usando muita vestimenta (7), no quarto.

| Voluntário | Postura 6 (°C) | Postura 7 (°C) |
|-------------------|-----------------------|-----------------------|
| A | 26 | 24,1 |
| B | 26,6 | 23,8 |
| C | 27,5 | 24,9 |
| D | 24,7 | 24,1 |

Também pelas tabelas 3 e 4, podemos ver que as médias das temperaturas não diminuem com voluntários de menores alturas. Na Tabela 3 a coluna da postura 4, até que as médias das temperaturas diminuíram conforme a altura dos voluntários diminui, mas isso não aconteceu nos valores da Tabela 4, coluna da

postura 6, como por exemplo, o voluntário B é mais alto que o C mas sua média da temperatura é menor.

Tabela 5 - Análise da influência da temperatura ambiente nas temperaturas medidas no campo de visão do sensor. As temperaturas são do mesmo voluntário (C) e são as médias dos pixels de maior temperatura em cada medição.

| Post. no quarto | Ambiente 23,4°C | Ambiente 25,1°C | Ambiente 28°C |
|-----------------|-----------------|-----------------|---------------|
| 4 | 26,5 | 26,6 | 29,3 |
| 6 | 27,5 | 28,6 | 30,3 |
| 5 | 26,6 | 27,6 | 30,5 |
| 7 | 24,9 | 26 | 28,5 |

Os resultados de uma primeira análise da influência da temperatura ambiente nas temperaturas medidas pelo campo de visão do sensor são apresentados na Tabela 5. Nesta tabela, são apresentadas as médias dos pixels de maior temperatura do mesmo voluntário (C) em quatro diferentes posturas, em três dias diferentes, que caracterizam três temperaturas ambientes diferentes. Estes resultados mostram que conforme a temperatura ambiente aumenta, as médias das temperaturas medidas também aumentam, mas não de forma proporcional.




Figura 29 - Temperaturas medidas enquanto voluntário dorme na cama com cobertor.

Com o objetivo de contribuir com dados para trabalhos futuros, gerei dois datasets para analisar a quantidade de calor de uma pessoa que é transferido para a cama e o cobertor com o passar do tempo, enquanto o voluntário dorme. O gráfico da Figura 29 mostra as temperaturas medidas enquanto o voluntário (D), vestindo cobertor e casaco, dormiu na cama. Os aumentos repentinos das temperaturas medidas são devidos ao voluntário, que em alguns momentos durante o sono, deixou mais partes do corpo descobertas pelo cobertor, i.e., expostas ao sensor. A duração do acompanhamento do voluntário durante seu sono foi de 1 hora 55 minutos e 21 segundos.




Figura 30 - Temperaturas medidas após voluntário sair da cama onde estava dormindo.

O gráfico da Figura 30 mostra as temperaturas medidas, após as medições das temperaturas do gráfico da Figura 29, e mostra como a cama perdeu calor após o voluntário se levantar após dormir e deixar o campo de visão do sensor. Apesar do calor transferido do voluntário para a cama ser ocultado pelo cobertor, este calor é claramente notado após o voluntário sair da cama e deixar a área que estava deitado exposta ao sensor, pois a última medição do gráfico da Figura 29 é menor que a primeira medição do gráfico da Figura 30, i.e., a média da matriz de temperaturas aumentou mesmo o voluntário não estando mais no campo de visão do sensor. A duração do acompanhamento da perda de calor da cama foi de 35 minutos e 37 segundos. A geração dos dados dos gráficos da Figura 29 e da Figura 30 teve um intervalo de tempo de 2 minutos e 28 segundos e por isso estes dados não estão ilustrados no mesmo gráfico, visto que a perda de calor é mais rápida logo após o voluntário se levantar da cama. Este intervalo de tempo em que não medi a perda de calor da cama fez com que eu perdesse dados importantes para a correta continuidade das medições de temperatura no gráfico, então optei por separar os gráficos para não confundir a análise.

7.2. Engenharia de atributos

Logo após gerar o dataset dos voluntários executando as posturas, usei o Weka para construir uma árvore de decisão para ter uma primeira acurácia. Neste dataset tinha somente os atributos que o sensor fornece, i.e., temperatura ambiente e as 16 temperaturas do campo de visão. Analisando a árvore de decisão gerada, percebi que estes atributos fazem com que a árvore decore o dataset e que dificilmente a árvore vá conseguir aprender a reconhecer posturas e identificar usuários. Na tarefa de identificação por exemplo, a árvore usou a temperatura ambiente para diferenciar os voluntários, isto significa que se um voluntário executou as posturas em uma temperatura ambiente de 23 graus e outro em 24, a árvore gerada não irá diferenciar estes usuários com sucesso caso o que executou as posturas em temperatura ambiente de 23 execute as posturas em 24 em um segundo momento. As 16 temperaturas do campo de visão do sensor (T1, T2, T3, ..., T15, T16) também não são bons atributos para o aprendizado da árvore, pois fazem com que a árvore decore o local onde cada voluntário permaneceu mais durante a criação do dataset. Por exemplo, se um voluntário permaneceu em pé sempre onde é o T1 no campo de visão e outro voluntário no T9, em um segundo momento quando o usuário permanecer em pé no local onde o outro estava, a árvore não irá diferenciar os usuários corretamente.




Figura 31 - Exemplo da matriz de temperaturas de um voluntário em pé no quarto, em temperatura ambiente de 23,4°C.

Foi necessário então criar atributos que representem as características da distribuição de calor de cada classe do dataset. Apesar da temperatura ambiente não ser um atributo relevante, sua informação foi levada em consideração na engenharia dos atributos, pois todas as temperaturas medidas pelo sensor dependem dela. A informação da temperatura ambiente é usada no cálculo do valor que separa os pixels do plano de fundo, dos pixels em que o usuário está. Esta técnica de separar os pixels identificados como plano de fundo dos pixels que interessam para a tarefa é usado na literatura, tanto em trabalhos que utilizam câmera (Teixeira; Savvides, 2008) como em trabalhos que utilizam sensor térmico de baixa resolução (Kuki et al., 2012). Depois de identificados os pixels do plano de fundo, a ideia é excluí-los do processamento a fim de diminuir a complexidade do problema (*background subtraction*). Na presente pesquisa, é feita uma regra de três com os valores de temperatura ambiente e o pixel de maior temperatura, no dataset onde não havia ninguém no campo de visão do sensor, com o objetivo de encontrar uma temperatura máxima que separa os pixels de plano de fundo, dos pixels onde há fonte de calor, em uma dada temperatura ambiente. Este cálculo é feito dinamicamente para cada medição (matriz de temperaturas e a temperatura

ambiente) e em seguida são calculados os atributos desta medição. Por exemplo, no dataset gerado no banheiro, quando não havia ninguém, a média das temperaturas ambiente foi 23,1 e a média dos pixels de maior temperatura foi 20,9 graus, então 23,1 está para 20,9 assim como a temperatura ambiente da medição onde os atributos precisam ser calculados (atual) está para o valor usado para remover o plano de fundo. Neste exemplo temos que o valor para retirar os pixels de plano de fundo é igual 20,9 vezes a temperatura ambiente atual dividido por 23,1, que resulta em 0,9 vezes temperatura ambiente atual. Feito este cálculo e depois dos pixels com temperatura menor que o valor encontrado serem excluídos, sobram apenas os pixels onde supostamente há fonte de calor, e a partir destes, os atributos são calculados.

Tabela 6 - Resultado do método de seleção de atributos *CfsSubsetEval*.

**Núm. de subconjuntos da
validação cruzada em
que foi selecionado**

Atributo

| | |
|------------------|--|
| 6 (60%) | 1 – Maior dif. de <i>back. sub.</i> |
| 10 (100%) | 2 – Núm. de pixels após <i>back. sub.</i> |
| 10 (100%) | 3 – Descontinuidade de calor |
| 4 (40%) | 4 – Desvio padrão de calor |
| 10 (100%) | 5 – Somatório de calor |
| 0 (0%) | 6 – Média de calor |
| 10 (100%) | 7 – Pixel mais quente na cama |
| 10 (100%) | 8 – Pixel mais quente ao lado da cama |
| 0 (0%) | 9 – Segundo pixel mais quente na cama |
| 10 (100%) | 10 – Segundo pixel mais quente ao lado da cama |

Os seguintes atributos foram criados para serem usados no aprendizado de máquina da presente pesquisa:

- 1) Diferença do pixel de maior temperatura para o valor de *background subtraction*.
- 2) Número de pixels após *background subtraction*.

- 3) Descontinuidade da fonte de calor. Este atributo tem seu valor definido como 0 ou 1. Após *background subtraction*, se sobrares menos de 2 pixels o valor é 0, senão é verificado se os 2 pixels de maior temperatura não são vizinhos na matriz 4 x 4 de temperaturas, se não forem vizinhos (descontínuos) o valor é 1, se forem vizinhos o valor é 0. Este atributo tem o objetivo de diferenciar principalmente as posturas deitado, onde a cabeça e as pernas possam ser as maiores fontes de calor.
- 4) Desvio padrão dos pixels após *background subtraction*. Este tem seu valor definido como 0 caso o número de pixels após *background subtraction* for menor que 2.
- 5) Somatório dos pixels após *background subtraction*. Seu valor é 0 caso o número de pixels após *background subtraction* for menor que 1.
- 6) Média dos pixels após *background subtraction*. Seu valor é 0 caso o número de pixels após *background subtraction* for menor que 1.
- 7) O sétimo atributo diz respeito ao local onde o pixel de maior temperatura está na matriz e é representado de forma binária, i.e., só assume 2 possíveis valores, 0 ou 1. No caso do banheiro são gerados 3 atributos binários, onde somente um destes tem o valor 1 e o resto 0. Estes são referentes ao box, pia e vaso sanitário. Desta forma, se o pixel de maior temperatura está dentro dos pixels mapeados do box, o atributo referente ao box tem seu valor 1 e os demais 0. No caso do quarto são gerados 2 atributos binários, referentes à cama e à área ao lado da cama. Este mapeamento foi feito manualmente pixel a pixel, observando quais pixels do campo de visão do sensor estavam medindo as áreas de interesse de cada cômodo investigado. Esta definição de contexto no software para auxiliar na tarefa foi usada por (Teixeira et al., 2009), que mapeou onde estavam as câmeras e os móveis de uma moradia. Mudanças na posição de objetos que compõem o plano de fundo dificultam o sensoriamento humano em imagens (Teixeira; Savvides, 2008).
- 8) O oitavo atributo é criado da mesma forma que o sétimo, porém diz respeito ao segundo pixel de maior temperatura.

Tabela 7 - Resultado do método de seleção de atributos *CorrelationAttributeEval*.

| Média de correlação (Pearson) entre atributo e a classe | Atributo |
|--|--|
| 0,3 | 1 – Maior dif. de <i>back. sub.</i> |
| 0,308 | 2 – Núm. de pixels após <i>back. sub.</i> |
| 0,143 | 3 – Descontinuidade de calor |
| 0,274 | 4 – Desvio padrão de calor |
| 0,289 | 5 – Somatório de calor |
| 0,281 | 6 – Média de calor |
| 0,368 | 7 – Pixel mais quente na cama |
| 0,463 | 8 – Pixel mais quente ao lado da cama |
| 0,323 | 9 – Segundo pixel mais quente na cama |
| 0,407 | 10 – Segundo pixel mais quente ao lado da cama |

A Figura 31 mostra um exemplo de medição de um voluntário executando a postura em pé no quarto em temperatura ambiente de 23,4°C. Neste exemplo, o valor de corte para *background subtraction* foi de 22,4°C. A engenharia de atributos gerou os seguintes valores: 45,3, 6, 0, 15,3, 139, 23,2, 0, 1, 0, 1. Os seis primeiros valores são os atributos listados acima, do 1 ao 6, respectivamente. Os quatro últimos são referentes aos atributos 7 e 8, e seus valores indicam que tanto o pixel mais quente quanto o segundo mais quente estão na área ao lado da cama.

| Atributo | 1 | 2 | 3 | 4 | 5 | 6 | 7 | 8 | 9 | 10 |
|----------|-------|------|-------|-------|------|------|-------|-------|-------|-------|
| 1 | 1 | 0.69 | -0.01 | 0.94 | 0.86 | 0.87 | 0.28 | 0.31 | 0.3 | 0.29 |
| 2 | 0.69 | 1 | 0.11 | 0.59 | 0.76 | 0.49 | 0.37 | 0.28 | 0.39 | 0.25 |
| 3 | -0.01 | 0.11 | 1 | -0.02 | 0.04 | 0.01 | 0.24 | -0.1 | 0.31 | -0.19 |
| 4 | 0.94 | 0.59 | -0.02 | 1 | 0.74 | 0.77 | 0.2 | 0.37 | 0.23 | 0.34 |
| 5 | 0.86 | 0.76 | 0.04 | 0.74 | 1 | 0.83 | 0.48 | 0.02 | 0.45 | 0.03 |
| 6 | 0.87 | 0.49 | 0.01 | 0.77 | 0.83 | 1 | 0.34 | 0.17 | 0.32 | 0.18 |
| 7 | 0.28 | 0.37 | 0.24 | 0.2 | 0.48 | 0.34 | 1 | -0.63 | 0.83 | -0.51 |
| 8 | 0.31 | 0.28 | -0.1 | 0.37 | 0.02 | 0.17 | -0.63 | 1 | -0.43 | 0.84 |
| 9 | 0.3 | 0.39 | 0.31 | 0.23 | 0.45 | 0.32 | 0.83 | -0.43 | 1 | -0.63 |
| 10 | 0.29 | 0.25 | -0.19 | 0.34 | 0.03 | 0.18 | -0.51 | 0.84 | -0.63 | 1 |

Figura 32 - Matriz de correlação entre os atributos, do método *PrincipalComponents*.

Para avaliar a engenharia de atributos, foram usados os dados do estudo de caso e prova de conceito gerados para reconhecimento de posturas no quarto. Este dataset contém 13.058 instâncias e é composto por 10 atributos numéricos mais a classe nominal com o nome da postura. A avaliação foi feita usando 4 métodos de seleção de atributos implementados pelo Weka, todos usando validação cruzada com 10 subconjuntos (*10-fold*).

Tabela 8 - Resultado do método de seleção de atributos *WrapperSubsetEval*.

**Núm. de subconjuntos
da validação cruzada em
que foi selecionado**

Atributo

| | |
|------------------|--|
| 10 (100%) | 1 – Maior dif. de <i>back. sub.</i> |
| 10 (100%) | 2 – Núm. de pixels após <i>back. sub.</i> |
| 10 (100%) | 3 – Descontinuidade de calor |
| 10 (100%) | 4 – Desvio padrão de calor |
| 10 (100%) | 5 – Somatório de calor |
| 7 (70%) | 6 – Média de calor |
| 9 (90%) | 7 – Pixel mais quente na cama |
| 8 (80%) | 8 – Pixel mais quente ao lado da cama |
| 10 (100%) | 9 – Segundo pixel mais quente na cama |
| 6 (60%) | 10 – Segundo pixel mais quente ao lado da cama |

A Tabela 6 mostra o resultado do método de seleção de atributos *CfsSubsetEval*, que seleciona um subconjunto de atributos relevantes de acordo com a habilidade preditiva individual e a redundância entre os atributos. A Tabela 7 é resultado do método *CorrelationAttributeEval* e mostra o valor de correlação (Pearson) de cada atributo com a classe de saída. Os valores da correlação variam de -1 até 1, sendo que quanto mais perto desses dois valores significa que o atributo é relevante e quanto mais perto de 0 significa que o atributo não é relevante. O método *PrincipalComponents* foi usado para saber quais atributos têm redundância entre eles. A Figura 32 mostra a matriz de correlação entre os atributos, sendo que os valores também variam de -1 até 1 e quanto mais perto destes dois valores, significa que os atributos têm maior redundância, assim como valores próximos de 0 significa que os atributos têm menor redundância. As linhas e colunas da matriz seguem a ordem de atributos listada na coluna Atributo das Tabelas 6, 7 e 8, sendo que a diagonal principal representa a correlação de um atributo com ele mesmo, por isso todos os valores têm valor 1. Por fim, a Tabela 8 mostra o resultado do método *WrapperSubsetEval*, que seleciona um subconjunto de atributos baseado na acurácia de um algoritmo de aprendizado. Assim como nos modelos de aprendizado de máquina gerados, o algoritmo de aprendizado supervisionado J48 foi usado junto com o método de seleção de atributos *WrapperSubsetEval*.

Com base nos quatro métodos de avaliação usados, o atributo 2, que representa o número de pixels após a técnica *background subtraction*, foi o mais relevante, pois foi o único que foi selecionado em 100% dos subconjuntos da validação cruzada em três métodos. No quarto método, que foi usado para medir a correlação Pearson entre os atributos, o atributo 2 teve maior redundância com o atributo 5 (0,76), que representa o somatório de calor. Os atributos com maior redundância entre si foram o 1 e o 4, que representam a diferença do pixel de maior temperatura para o valor de *back. sub.* e o desvio padrão de calor, respectivamente, com valor Pearson de 0,94. Já o pior atributo avaliado, i.e., que menos vezes foi selecionado em subconjuntos da validação cruzada, foi o 6, que representa a média das temperaturas após *back. sub.*

7.3.

Modelos de árvores de decisão e respectivas acurácias

O J48 foi o algoritmo de árvore de decisão usado para gerar os modelos de aprendizado de máquina. Estas árvores foram geradas pelo Weka, usando sua configuração padrão para avaliação do modelo, a técnica de validação cruzada com 10 subconjuntos, também usada para avaliar os atributos criados.

O termo “prova de conceito” usado nas subseções, dentro desta seção, se refere a dois datasets gerados em momentos posteriores ao dataset do estudo de caso. Estes dados posteriores foram gerados assim como descrito na seção 6.2 (Projeto de estudo de caso), mas em dias diferentes e somente no quarto. O objetivo da geração destes novos datasets é evidenciar o aprendizado das árvores de decisão, que foram geradas a partir dos dados gerados em um primeiro momento, que chamo de estudo de caso. Os datasets das provas de conceito 1 e 2 foram gerados em dias cujas temperaturas ambientes eram superiores aos dados do estudo de caso. O valor da temperatura ambiente mais alta nos datasets do estudo de caso e das provas de conceito 1 e 2 foram, respectivamente, 25,1, 25,9 e 29,1 graus centígrados. Os voluntários C e D participaram das medições da prova de conceito 1 e os voluntários A e B da 2.

7.3.1.

Reconhecendo os voluntários

As posturas em pé foram usadas para reconhecer os voluntários, tanto no banheiro quanto no quarto. A postura em pé foi escolhida para o reconhecimento de pessoas, pois nessa postura há uma variação maior da distância dos voluntários até o sensor. Além disso, é a primeira postura que uma pessoa geralmente entra no campo de visão do sensor, ao entrar em um cômodo da moradia, ou na própria moradia. Neste caso estou sugerindo uma relação de uma postura com uma ação (caminhando). Ao entrar em um cômodo caminhando, se tirarmos um *print* dos dados do sensor, estes serão semelhantes aos dados da postura em pé, e o AAL usaria um modelo de aprendizado de máquina somente com classes da postura em pé das pessoas previamente conhecidas, e daí em diante usaria somente o modelo para reconhecimento das posturas, pois a pessoa já foi identificada assim que entrou no cômodo.

Tabela 9 - Acurácias do reconhecimento de voluntários no banheiro.

| Dataset | Acurácia (%) |
|-------------------------------|--------------|
| Estudo de caso (C + D) | 97,9 |
| Estudo de caso (A + B) | 96,33 |

No banheiro foram usadas as classes do dataset em pé em frente ao vaso sanitário e em pé em frente ao vaso sanitário usando muita vestimenta, pois neste banheiro onde ocorreu o estudo de caso o vaso sanitário é do lado da porta, então é por este local que a pessoa entraria no campo de visão do sensor. No quarto foram usadas as classes do dataset em pé e em pé usando muita vestimenta, o local onde os voluntários executaram estas posturas foi ao lado da cama, que é o local mais próximo da porta de acesso ao quarto, então também seria onde a pessoa entraria no campo de visão do sensor.

Tabela 10 - Acurácias do reconhecimento de voluntários no quarto.

| Dataset | Acurácia (%) |
|-------------------------------|--------------|
| Estudo de caso (C + D) | 95,5 |
| Estudo de caso (A + B) | 81,46 |
| Prova de conceito 1 | 71,27 |
| Prova de conceito 2 | 90,13 |

A Tabela 9 mostra as acurácias no banheiro, usando somente o dataset do estudo de caso. As letras entre parênteses representam os voluntários que foram reconhecidos em cada modelo.

```

a    b    <-- classified as
280  48 |   a = C
129 159 |   b = D

```

Figura 33 - Matriz de confusão do reconhecimento de voluntários no dataset da prova de conceito 1.

A Tabela 10 mostra as acurácias obtidas no estudo de caso e nos dois datasets para validação do modelo de reconhecimento de voluntários no quarto. Um dos datasets do estudo de caso foi separado com os dados dos voluntários C e D e o outro com os dados dos voluntários A e B. A separação foi feita desta forma para manter as mesmas comparações entre voluntários, assim como nas comparações dos datasets das provas de conceito. A Figura 33 ilustra a matriz de confusão no dataset da prova de conceito 1. Nesta matriz se observa uma alta proporção de instâncias classificadas erradas (44,79%) quando o voluntário correto era o D. O motivo é porque no modelo usado tinha mais instâncias do outro voluntário (C), sendo que essas instâncias a mais foram medidas em dias com temperaturas ambientes superiores às temperaturas ambientes de quando o voluntário D executou as posturas. Como o dataset da prova de conceito 1 também foi gerado em um dia de temperatura ambiente superior, o modelo entendeu que a maioria das instâncias eram do voluntário C.

7.3.2. Reconhecendo as posturas

Os reconhecimentos de posturas no quarto e no banheiro usaram os dados de todos voluntários em cada dataset, desta forma os modelos são criados para reconhecer as posturas, previamente definidas, independente do usuário que estiver no cômodo. Como o objetivo é reconhecer a postura independente do tipo de vestimenta, os dados das posturas em que os voluntários usaram vestimentas típicas de inverno não são diferenciadas por este motivo, e.g, a postura deitado na cama usando cobertor é rotulada nos datasets como apenas deitado na cama.

| a | b | c | d | e | <-- classified as |
|-----|-----|-----|------|------|------------------------|
| 692 | 12 | 0 | 0 | 0 | a = LayingBox |
| 12 | 634 | 0 | 0 | 0 | b = StandingBox |
| 0 | 0 | 687 | 1 | 1 | c = StandingSink |
| 0 | 0 | 1 | 1209 | 30 | d = StandingToiletSeat |
| 0 | 0 | 3 | 14 | 1162 | e = SittingToiletSeat |

Figura 34 - Matriz de confusão do reconhecimento de posturas no banheiro, usando somente o dataset do estudo de caso.

O reconhecimento de posturas no banheiro, usando somente o dataset do estudo de caso, teve acurácia de 98,34%. A Figura 34 ilustra a matriz de confusão desta tarefa.

Tabela 11 - Acurácias do reconhecimento de posturas no quarto.

| Dataset | Acurácia (%) |
|---------------------|--------------|
| Estudo de caso | 90,67 |
| Prova de conceito 1 | 75,95 |
| Prova de conceito 2 | 60,06 |

A Tabela 11 mostra as acurácias do reconhecimento de posturas no quarto em cada dataset. As Figuras 35, 36 e 37 ilustram, respectivamente, as matrizes de confusão dos reconhecimentos de posturas nos datasets do estudo de caso, prova de conceito 1 e prova de conceito 2. Nestas matrizes nota-se que o modelo praticamente só confunde as posturas executadas na cama entre si, i.e., quase não confunde posturas executadas na cama com posturas executadas ao lado da cama. Também se nota que, nos datasets das provas de conceito, o modelo erra mais no reconhecimento das posturas executadas ao lado da cama. O modelo obteve acurácias ruins no reconhecimento das posturas executadas ao lado da cama na prova de conceito 2, onde errou mais do que acertou na classificação destas, sendo que a postura deitado no chão teve apenas uma instância classificada corretamente. Na prova de conceito 1, o modelo errou mais do que acertou no reconhecimento da postura deitado no chão.

| a | b | c | d | e | <-- classified as |
|------|------|------|------|------|-------------------|
| 2815 | 62 | 2 | 3 | 0 | a = DeitCama |
| 58 | 1091 | 1 | 3 | 0 | b = SentCama |
| 27 | 0 | 2672 | 164 | 198 | c = EmPe |
| 2 | 4 | 126 | 1357 | 53 | d = SentChao |
| 0 | 0 | 169 | 53 | 1054 | e = DeitChao |

Figura 35 - Matriz de confusão do reconhecimento de posturas no quarto, usando somente o dataset do estudo de caso.

| a | b | c | d | e | <-- classified as |
|-----|-----|-----|-----|----|-------------------|
| 485 | 5 | 0 | 1 | 0 | a = DeitCama |
| 52 | 137 | 0 | 0 | 0 | b = SentCama |
| 4 | 0 | 432 | 83 | 97 | c = EmPe |
| 0 | 0 | 59 | 169 | 9 | d = SentChao |
| 0 | 0 | 93 | 9 | 78 | e = DeitChao |

Figura 36 - Matriz de confusão do reconhecimento de posturas no quarto, avaliado no dataset da prova de conceito 1.

| a | b | c | d | e | <-- classified as |
|-----|-----|-----|-----|----|-------------------|
| 526 | 33 | 0 | 0 | 0 | a = DeitCama |
| 85 | 183 | 0 | 0 | 0 | b = SentCama |
| 0 | 0 | 259 | 238 | 50 | c = EmPe |
| 0 | 0 | 89 | 79 | 0 | d = SentChao |
| 0 | 0 | 135 | 67 | 1 | e = DeitChao |

Figura 37 - Matriz de confusão do reconhecimento de posturas no quarto, avaliado no dataset da prova de conceito 2.

7.3.3.

Detectando a presença humana

A tarefa de detecção de presença usou os dados de todas as posturas e de quando não havia ninguém no campo de visão do sensor para avaliação. Os dados das posturas, de todos os voluntários, foram rotulados para representar a presença de um usuário no cômodo.

Tabela 12 - Acurácias da tarefa de detecção de presença humana no quarto.

| Dataset | Acurácia (%) |
|---------------------|--------------|
| Estudo de caso | 99,57 |
| Prova de conceito 1 | 99,94 |
| Prova de conceito 2 | 91,65 |

A acurácia de detecção de presença no banheiro, usando somente os dados do estudo de caso, foi de 99,85%.

```

      a      b  <-- classified as
1745    0 |    a = Participant
159     0 |    b = None

```

Figura 38 - Matriz de confusão da detecção de presença no quarto, no dataset prova de conceito 2.

A Tabela 12 contém as acurácias da detecção de presença no quarto em cada dataset. A Figura 38 ilustra a matriz de confusão na avaliação da tarefa, quando aplicada no dataset da prova de conceito 2. Nesta matriz, nota-se que o modelo classificou incorretamente todas as instâncias que representavam que não havia ninguém no quarto.

8 Conclusão e trabalhos futuros

Este trabalho propôs soluções para as tarefas de reconhecimento de posturas, pessoas e detecção de presença, usando dados de um sensor térmico de baixa resolução, instalado no teto de um quarto e de um banheiro. Estas tarefas fazem parte da taxonomia do sensoramento humano proposto por (Teixeira; Dublon; Savvides, 2010) e auxiliam no reconhecimento de ADLs em AAL.

Com base em datasets coletados e rotulados pela presente pesquisa, em diversos dias diferentes, contendo medições de quatro voluntários, foram feitas análises quantitativas e usando técnicas de aprendizado de máquina para avaliar as soluções propostas. Árvores de decisão foram usadas para criação dos modelos de reconhecimento. Foi desenvolvida uma engenharia de atributos a partir dos dados de saída do sensor térmico, que resultou em 10 valores, que foram usados na criação das árvores. Estes atributos são divididos em três tipos de informações: pixels após processo de remoção de plano de fundo, estatística descritiva e mapeamento físico do campo de visão do sensor.

O reconhecimento de posturas, principal questão de pesquisa deste trabalho, apresentou acurácias altas (acima de 90%) quando os modelos foram avaliados com medições em temperaturas ambiente similares às medições usadas na criação dos modelos. No entanto, quando avaliados com medições de dias com maiores temperaturas ambiente, houve uma relação inversa nas acurácias, i.e., quanto maior a diferença da temperatura ambiente entre as medições conhecidas pelo modelo e as medições com posturas a serem reconhecidas, menor a acurácia.

A tarefa de detecção de presença humana apresentou acurácias de aproximadamente 100% nos datasets do estudo de caso e prova de conceito 1. Já na prova de conceito 2, onde houve maior diferença entre temperaturas ambiente, a acurácia caiu, mas se manteve acima de 90%. Esta queda na acurácia aconteceu, pois, o modelo falhou no reconhecimento de todas as instâncias cujas classes eram ninguém.

O reconhecimento de pessoas neste trabalho foi feito de forma simplificada. Segundo o trabalho de (Teixeira; Dublon; Savvides, 2010), identificação humana é a propriedade espaço-temporal mais difícil de se reconhecer, pois necessita das tarefas presença, contar, localizar e rastrear previamente resolvidas. A tarefa contar não foi investigada; considerou-se apenas um único voluntário por vez dentro do campo de visão do sensor. Localizar e rastrear também não foram investigados; o reconhecimento de pessoas usou os dados dos voluntários apenas em uma postura com local fixo. Desta forma, os resultados obtidos no reconhecimento de pessoas só são válidos quando se tem as tarefas das propriedades espaço-temporais com hierarquia menor resolvidas.

As contribuições da presente pesquisa são: solução usando hardware de baixo custo, criação de dataset e método de engenharia de atributos que viabilizou o reconhecimento de posturas e detecção de presença. O protótipo desenvolvido tem menor custo do que o usado no trabalho de (Taniguchi et al., 2014), além disso, necessita de apenas um local de instalação (teto), ao invés de dois (teto e parede). O dataset criado será disponibilizado como domínio público com o objetivo de ajudar pesquisadores, possibilitando que sejam unidos com dados de outros sensores para que seja possível resolver tarefas do sensoramento humano com nível de hierarquia maiores, além de possibilitar que soluções propostas possam ser comparadas, uma vez que as avaliações das soluções sejam feitas com o mesmo dataset. Por fim, a presente pesquisa evidenciou que é viável usar um sensor térmico de baixa resolução no reconhecimento de posturas e detecção de presença humana, contanto que os modelos tenham sido treinados com dados coletados em temperaturas ambientes na mesma faixa de valores dos dados a serem reconhecidos. Isto implica ser necessário conhecer, previamente, os possíveis valores de temperatura ambiente que o local de instalação da solução possa estar e treinar os modelos com tais dados.

O estudo feito no banheiro teve dados coletados em apenas um dia, portanto é sugerido a criação de outros datasets para este cômodo, visto que o banheiro é o cômodo de uma moradia que requer mais privacidade e por isso sensores térmicos de baixa resolução se adequam bem. Estudos futuros também são sugeridos na parte de aprendizado de máquina, como por exemplo na engenharia de atributos e criação dos modelos. Como visto na seção 7.2, alguns atributos apresentaram alto grau de redundância entre si e, se retirados, podem tornar os modelos mais

simples de serem entendidos e mais genéricos. Com relação aos modelos de reconhecimento, é sugerido fazer testes com diferentes modelagens. Os modelos podem ser treinados com todos dados disponíveis ou, usar um modelo para cada faixa de valores de temperaturas ambiente. No caso de se usar um modelo único e, caso o modelo tenha sido treinado com medições coletadas em diversas temperaturas ambiente diferentes, é sugerido incluir a temperatura ambiente como atributo.

Uma característica fundamental para que o sensor térmico de baixa resolução seja usado no sensoriamento humano em AAL, é o pé-direito do local de instalação, visto que seu ângulo de abertura não permite um campo de visão suficiente para sensoriar um quarto inteiro como o investigado na presente pesquisa por exemplo, que tem pé-direito de 267 cm, e conforme a pessoa se dirige para alguma das extremidades do campo de visão, a parte de cima de seu corpo vai saindo do campo sensoriado.

Apesar da detecção de presença ter tido sucesso na presente pesquisa, é necessário investigar como as temperaturas de uma pessoa, medidas em ambientes acima dos 37 graus centígrados, irão ser lidas pelo sensor. As características do ambiente onde se deseja instalar um sensor térmico devem ser investigadas, como outras fontes de calor. No quarto da presente pesquisa, por exemplo, em dias de calor e sol a parede que a cama fica encostada aquece, ficando com uma temperatura maior que as outras paredes do cômodo.

Sugiro um trabalho futuro em um quarto, com o sensor térmico instalado no teto igual ao da presente pesquisa, sensoriando a cama e a área ao lado da cama, com o objetivo de identificar duas pessoas ao mesmo tempo, ninguém, ou somente uma pessoa. As classes seriam as seguintes: ninguém, uma pessoa deitada no chão, uma pessoa deitada na cama, uma pessoa em pé, e uma pessoa em pé junto com uma pessoa deitada na cama. O objetivo desta pesquisa seria simular um ambiente com um paciente e um cuidador, podendo reconhecer situações como paciente caído no chão e contar a quantidade de vezes que o cuidador visitou o paciente por exemplo.

Sensor térmico é uma opção que tem prós e contras, como todos os outros sensores. Para AAL apresentar bons resultados no sensoriamento humano, é necessário um bom estudo do local a ser sensoriado, pois todo ambiente possui suas particularidades, além de saber quais tipos de dados o usuário aceita que

sejam capturados e compartilhados, para então projetar um sistema que use diversos tipos de sensores que se complementem.

ARDUINO. **Arduino Board Uno**. Disponível em: <<https://www.arduino.cc/en/Main/ArduinoBoardUno>>. Acesso em 19 de março de 2016.

CDC. **Web-based Injury Statistics Query and Reporting System (WISQARS)**. Disponível em <<http://www.cdc.gov/injury/wisqars/index.html>>. Acesso em 20 de maio 2016.

CORREA, M. et al. Human detection and identification by robots using thermal and visual information in domestic environments. **Journal of Intelligent & Robotic Systems**, v. 66, p. 223-243, 2011.

CUNHA, M.; FUKS, H. AmbLEDs para ambientes de moradia assistidos em cidades inteligentes. In: Brazilian Symposium on Human Factors in Computing Systems, **Proceedings...** IHC: Foz do Iguaçu/PR, p.409-412, 2014.

DENNIS, A. R.; VALACICH, J. S. Conducting experimental research in information systems. **Communications of the association for information systems**, v.7, n.5, p.1-4, 2001.

DOYLE, J. et al. Requirements gathering for the delivery of healthcare data in aware homes. In: 5th International Conference on Pervasive Computing Technologies for Healthcare (Pervasive Health) and Workshops. **Anais...** IEEE ICST: Dublin/IE, p.254-257, 2011.

FINKELSTEIN, E. A.; CORSO, P. S.; MILLER, T. R. Incidence and economic burden of injuries in the United States. Nova Iorque/NY: **Oxford University Press**, 2006.

FOGARTY, J.; AU, C.; HUDSON, S. E. Sensing from the basement: a feasibility study of unobtrusive and low-cost home activity recognition. In: The nineteenth annual ACM Symposium on User Interface Software and Technology was held. **Anais...** IEEE: Montreux, Suíça, p.91-100, 2006.

FRY, B.; REAS, C. **Processing Library for Visual Arts and Design**. 2011.

- GADDAM, A.; MUKHOPADHYAY, S. C.; GUPTA, G. S. Development of a bed sensor for an integrated digital home monitoring system. In: Workshop on Medical Measurements and Applications. **Anais...** IEEE: Ottawa, Canadá, 2008.
- HALL, M. et al. The WEKA Data Mining Software: An Update. **SIGKDD Explorations**, v.11, 2009.
- KUKI, M. et al. Human movement trajectory recording for home alone by thermopile array sensor. In: International Conference on Systems, Man, and Cybernetics, **Anais...** IEEE SMC: Seul/Coreia do Sul, p.2042-2047, 2012.
- Lawton, M. P.; Brody, E. M. "Assessment of older people: self-maintaining and instrumental activities of daily living." *Nursing Research* 19.3 (1970): 278.
- LIU, J. J. A dense pressure sensitive bedsheet design for unobtrusive sleep posture monitoring. In: International Conference on Pervasive Computing and Communications. **Anais...** IEEE: San Diego/EUA, p. 207-2015, 2013.
- NAKASHIMA, S. et al. Development of privacy-preserving sensor for person detection. **Procedia Social and Behavioral Sciences**, v. 2, p.213-217, 2010.
- OMRON Corporation. **MEMS Thermal Sensors D6T**. Disponível em: <<https://www.omron.com/ecb/products/sensor/11/d6t.html>>. Acesso em 25 de julho de 2016.
- PALÁCIO DO PLANALTO. **Neutralidade, liberdade de expressão e privacidade: conheça os pilares do Marco Civil**. Disponível em <<http://www2.planalto.gov.br/noticias/2015/04/neutralidade-liberdade-de-expressao-e-privacidade-conheca-os-pilares-do-marco-civil>>. Acesso em 13 de julho de 2016.
- PIMENTEL, M.; FUKS, H. **Sistemas Colaborativos**. Rio de Janeiro: Elsevier. 2011, p.379-433.
- R Development Core Team. R: A language and environment for statistical computing. **R Foundation for Statistical Computing**, Vienna- Áustria, 2008.
- RHEINGANS, P. Task-based color scale design. In: 28th AIPR Workshop: 3D Visualization for Data Exploration and Decision Making. **Proceedings...** SPIE: Washington/DC, v.3905, p.35-43, 2000.
- SHANG, Y.; LIU, Z.; WANG, J. Posture recognition for the elderly based on wireless sensor networks. In: 26th Chinese Control and Decision Conference. **Anais...** IEEE: Changsha/China, p.2496-2499, 2014.

SILVA, G. J. B.; SILVA, L. D. Reconhecimento de atividades humanas através de um smartphone. In: XII Simpósio Brasileiro de Automação Inteligente. **Anais...** Natal/RN, p. 361-366, 2015.

SIXSMITH, A.; JOHNSON, N. A smart sensor to detect the falls of the elderly. **IEEE Pervasive Computing**, v. 3, p. 42-47, 2004.

SPAN, P. **The most dangerous room in the house?** Disponível em <<http://newoldage.blogs.nytimes.com/2009/05/28/the-most-dangerous-room-in-the-house>>. Acesso em 20 de junho de 2016.

SURIE, D.; PARTONIA, S.; LINDGREN, H. Human sensing using computer vision for personalized smart spaces. In: 10th International Conference on Ubiquitous Intelligence & Computing and 10th International Conference on Autonomic & Trusted Computing, **Proceedings...** IEEE Computer Society: Roma/Itália, p. 487-494, 2013.

TANIGUCHI, Y. N. et al. A falling detection system with plural thermal array sensors. In: Joint 7th International Conference on Soft Computing and Intelligent Systems and 15th International Symposium on Advanced Intelligent Systems, **Proceedings...** IEEE: Kitakyushu/Japão, p.673-678, 2014a.

TANIGUCHI, Y. N. et al. Estimation of human posture by multi thermal array sensors. In: International Conference on Systems, Man, and Cybernetics, **Anais...** IEEE SMC: San Diego/CA-EUA, p.3930-3935, 2014b.

TANIGUCHI, Y. N. et al. Resolution analysis for estimating human numbers by thermal array sensor system. In: World Automation Congress. **Proceedings...** IEEE SMC: Kona/EUA, p.1-6, 2014c.

TEIXEIRA, T.; DUBLON, G.; SAVVIDES, A. A Survey of Human-Sensing: Methods for Detecting Presence, Count, Location, Track, and Identity. **ENALAB Technical Report**, v.1, n.1, p.1-41, 2010.

TEIXEIRA, T. et al. Recognizing activities from context and arm pose using finite state machines. In: Third ACM/IEEE International Conference on Human Robot Interaction, **Proceedings...** IEEE ICDSC: Amsterdam, 2009.

TEIXEIRA, T.; SAVVIDES, A. Lightweight people counting and localizing for easily deployable indoors wsns. **Journal of Selected Topics in Signal Processing**, v.2, n.4, p.493-502, 2008.

TRIANAFYLLIDIS, A. K. et al. A framework of sensor-based monitoring for pervasive patient care. **Healthcare Technology Letters**, p.1-6, 2016.

UGULINO, W. C. **Wearables para apoiar a representação espacial por indivíduos cegos**. 2014. 82f. Tese (Doutorado em Informática) - Departamento de Informática, Pontifícia Universidade Católica do Rio de Janeiro. Rio de Janeiro.

UGULINO, W. C. et al. Virtual caregiver: a system for supporting collaboration in elderly monitoring. In: Brazilian Symposium on Collaborative Systems, **Anais...** São Paulo: IEEE, p. 43-48, 2012.

United Nations, Department of Economic and Social Affairs, Population Division (2013). **World Population Ageing 213**. ST/ESA/SER.A/348.

WONG, W. K. et al. Home alone faint detection surveillance system using thermal camera. In: Second International Conference on Computer Research and Development. **Proceedings...** IEEE: Washington/DC, p.747-751, 2010.

YIN, R. K. **Case study research: design and methods**. 3 ed. Thousand Oaks, CA: Sage. 2003, 181p.