

UNIVERSIDADE FEDERAL DO RIO GRANDE DO SUL
INSTITUTO DE INFORMÁTICA
PROGRAMA DE PÓS-GRADUAÇÃO EM COMPUTAÇÃO

GABRIEL MACHADO LUNARDI

**Previsão de Ações em Atividades Diárias
para Assistir Pessoas com Declínio
Cognitivo através de um Modelo Ontológico
Probabilístico**

Dissertação apresentada como requisito parcial
para a obtenção do grau de Mestre em Ciência da
Computação

Orientador: Prof. Dr. José Palazzo Moreira de
Oliveira

Porto Alegre
2017

CIP — CATALOGAÇÃO NA PUBLICAÇÃO

Lunardi, Gabriel Machado

Previsão de Ações em Atividades Diárias para Assistir Pessoas com Declínio Cognitivo através de um Modelo Ontológico Probabilístico / Gabriel Machado Lunardi. – Porto Alegre: PPGC da UFRGS, 2017.

76 f.: il.

Dissertação (mestrado) – Universidade Federal do Rio Grande do Sul. Programa de Pós-Graduação em Computação, Porto Alegre, BR-RS, 2017. Orientador: José Palazzo Moreira de Oliveira.

1. Sensibilidade ao Contexto. 2. Ontologias Probabilísticas. 3. Ambientes de Vivência Assistida. 4. Atividades Diárias. I. Palazzo Moreira de Oliveira, José. II. Título.

UNIVERSIDADE FEDERAL DO RIO GRANDE DO SUL

Reitor: Prof. Rui Vicente Oppermann

Vice-Reitor: Prof. Jane Fraga Tutikian

Pró-Reitor de Pós-Graduação: Prof. Celso Giannetti Loureiro Chaves

Diretor do Instituto de Informática: Prof. Carla Maria Dal Sasso Freitas

Coordenador do PPGC: Prof. João Luiz Dihl Comba

Bibliotecária-chefe do Instituto de Informática: Beatriz Regina Bastos Haro

“A memória é falível, claro, mas não tanto por causa de limitações de armazenamento, mas sim pelas limitações de recuperação.”

— DANIEL J. LEVITIN

AGRADECIMENTOS

Ao Prof. Dr. José Palazzo, meu orientador, interlocutor do meu desenvolvimento científico, profissional e pessoal. Obrigado pelo acolhimento, pelo estímulo, pelo profissionalismo e pelo voto de confiança na realização desta pesquisa. Foi um privilégio poder conhecê-lo e trabalhar ao seu lado, uma oportunidade singular em minha vida!

A todos os colegas do laboratório 213: Carlos, Renato, Lorayne, Diego, Alessandro, Simone e Vinícius. Obrigado por compartilharem os anseios da vida acadêmica e pelo companheirismo nas discussões que engrandeceram este trabalho. Um agradecimento especial ao Guilherme pela presteza, pelo conhecimento e pela colaboração.

Ao Prof. Dr. Alencar Machado por ter me recebido inúmeras vezes para discutir ideias que estimularam a desenvoltura inicial deste trabalho.

À cooperação estabelecida com outro lado do oceano, na Áustria... *I would like to thank the HBMS team, specially Prof. Dr. Fadi Al Machot for sharing his knowledge through inumerous Skype meetings, and Prof. Dr. Heinrich C. Mayr for buildind up the “cooperation beyond the ocean” as he was used to say.*

Aos demais docentes e técnicos administrativos do Instituto de Informática da UFRGS que se fizeram presentes, direta ou indiretamente, durante esta caminhada.

Ao Conselho Nacional de Desenvolvimento Científico e Tecnológico – CNPq, pela concessão da bolsa de estudos.

Aos meus pais, Nilson e Elisiane, pela logística familiar, eis que foram incansavelmente presentes em minha vida. Vocês me ensinaram a gerenciar a vida frente o exemplo de luta, coragem, integridade, determinação, persistência e humildade. Obrigado por acreditarem em mim e protagonizarem tudo isso!

Aos meus irmãos, Pietro e Laura, e demais familiares, pelo carinho, cuidado, compreensão e pela partilha diária de sonhos, anseios e alegrias. Obrigado por existirem e me perdoem a impaciência, o isolamento e a ausência durante a condução deste estudo.

À minha companheira, Paula, por sua cumplicidade, pelo companheirismo, pela paciência e pelo apoio em todas as minhas decisões.

RESUMO

A população idosa mundial está crescendo e, com ela, o número de diagnósticos de doenças relacionadas à velhice como, por exemplo, declínios cognitivos também. Essas doenças costumam afetar a autonomia do idoso no seu lar, especialmente no que se refere à realização de atividades diárias. Com isso em vista, é preciso empregar cuidadores e serviços de saúde que acabam por implicar em altos custos. Nesse sentido, surge a necessidade de conceber sistemas robustos, automatizados, utilizáveis e de baixo custo para a assistência pessoal. A concepção desses sistemas faz menção à área de Ambientes de Vivência Assistida. Portanto, esta dissertação propõe uma abordagem que beneficia os sistemas para Ambientes de Vivência Assistida com a capacidade de prever ações humanas para a facilitação de atividades diárias, particularmente quando declínios cognitivos relacionados à elas ocorrerem. Nesse sentido, foi concebido um meta-modelo semântico para a geração de modelos conceituais de contexto e de comportamento, compostos pelas ações humanas. A partir disso, a previsão de ações (informação de suporte) é realizada por um mecanismo de predição e inferência composto por um modelo semântico probabilístico. A abordagem é demonstrada através de um estudo de caso cujo cenário representa uma situação de declínio cognitivo, enfrentada por um usuário, que impede a condução de uma atividade diária. Então, o mecanismo de predição e inferência, utilizando o modelo semântico probabilístico, prevê qual a ação mais adequada que facilite a conclusão da atividade. Essa previsão é avaliada para aferir o quão bem um usuário seria auxiliado, isto é, se a operação prevista foi por ele realizada. Para isso, foi utilizado um *dataset* relacionado ao cenário do estudo de caso e medidas de desempenho como a precisão, a revocação e a medida-F. Os resultados dessa avaliação se mostraram promissores sendo, em média, 69,5% para a precisão, 100% para a revocação e 81% para a medida-F. As principais contribuições deste trabalho dizem respeito ao meta-modelo semântico a partir do qual pesquisas na área deste trabalho podem utilizar para gerar modelos de comportamento, e ao modelo semântico probabilístico que realiza predição através de raciocínio incerto sobre os modelos de comportamento, propiciando decisões mais precisas para auxiliar usuários com declínio cognitivo.

Palavras-chave: Sensibilidade ao Contexto. Ontologias Probabilísticas. Ambientes de Vivência Assistida. Atividades Diárias.

Prediction of Actions in Daily Activities to Assist People with Cognitive Decline through a Probabilistic Ontological Model.

ABSTRACT

The world's elderly population is growing and, with it, the number of diagnoses of diseases related to old age, such as cognitive declines as well. These diseases usually affect the autonomy of the elderly in their home, especially when it comes to performing daily activities. With this in mind, it is necessary to employ caregivers and health services that end up implying high costs. In this sense, the need arises to design robust, automated, usable and low-cost systems for personal assistance. The design of these systems makes reference to the area of Ambient Assisted Living. Therefore, this dissertation proposes an approach that benefits the Ambient Assisted Living systems with the ability to predict human actions for the facilitation of daily activities, particularly when cognitive declines related to them occur. In this sense, a semantic meta-model was conceived for the generation of conceptual models of context and behavior, composed by human actions. From this, the prediction of actions (information of support) is realized by a mechanism of prediction and inference composed by a probabilistic semantic model. The approach is demonstrated through a case study whose scenario represents a situation of cognitive decline, faced by a user, that prevents the conduct of a daily activity. Then, the prediction and inference mechanism, using the probabilistic semantic model, predicts the most appropriate action that facilitates the conclusion of the activity. This forecast is evaluated to gauge how well a user would be assisted, that is, if the intended operation was performed by him. For this, a dataset related to the case study scenario and performance measures such as precision, recall, and F-measure were used. The results of this evaluation are promising, averaging 69.5% for precision, 100% for recall and 81% for F-measure. The main contributions of this work are related to the semantic meta-model from which research in the area of this work can be used to generate behavioral models, and to the probabilistic semantic model that performs prediction through uncertain reasoning over behavior models, providing better decisions to help users with cognitive decline.

Keywords: Context-awareness. Probabilistic Ontologies. Ambient Assisted Living. Activities of Daily Living..

LISTA DE FIGURAS

Figura 1.1	Contribuição do trabalho	13
Figura 2.1	Modelo simplificado da ontologia de topo PR-OWL	26
Figura 2.2	Principais conceitos da ontologia para diagnóstico de gripe	28
Figura 2.3	MTheory para o diagnóstico médico	29
Figura 2.4	Distribuição Local de Probabilidade de cada nó residente	30
Figura 2.5	SSBN de diagnóstico do Paciente 1	30
Figura 2.6	SSBN de diagnóstico do Paciente 2	31
Figura 2.7	Ideia geral do projeto HBMS e seu conceito chave HCM	32
Figura 2.8	Arquitetura geral do sistema HBMS	33
Figura 2.9	Meta-modelo HCM-L	37
Figura 2.10	Notação HCM-L	37
Figura 2.11	<i>Behavioral Unit</i> se preparar para fazer compras	39
Figura 2.12	Modelo de contexto	40
Figura 2.13	Visão inicial da ferramenta HCM-L <i>Modeler</i>	41
Figura 2.14	ADOxx [®] <i>Notebooks</i> de comportamento	41
Figura 2.15	ADOxx [®] <i>Notebooks</i> de contexto	42
Figura 3.1	Meta-modelo semântico baseado em HCM-L	49
Figura 3.2	Etapas para a construção de uma ontologia probabilística	50
Figura 3.3	MTheory para predição de Operações	51
Figura 3.4	Arquitetura do Mecanismo de Suporte HBMS	53
Figura 3.5	Interface de suporte baseada em plataforma Android.	54
Figura 4.1	laboratório HBMS	56
Figura 4.2	Modelo de comportamento para “Assistir um DVD”	57
Figura 4.3	Distribuições Locais de Probabilidade (LPDs) de cada <i>Operation</i>	58
Figura 4.4	SSBNs com o resultado da predição	59
Figura 4.5	Algoritmo para gerar probabilidades do nó residente <i>hasHist.</i>	60
Figura 4.6	Algoritmo para gerar probabilidades do nó residente <i>hasSimilarityGain.</i> ...	61
Figura 5.1	Amostragem aleatória aplicada	63
Figura 5.2	Matriz de confusão exemplo	64
Figura 5.3	Matriz de confusão para o treino 1 e teste 1	65
Figura 5.4	Médias de desempenho da predição	66

LISTA DE TABELAS

Tabela 2.1	Análise das técnicas empregadas na modelagem de contexto.....	20
Tabela 2.2	Vantagens e desvantagens de cada técnica	21
Tabela 2.3	Comparação das linguagens probabilísticas de primeira ordem	25
Tabela 2.4	Equivalência de conceitos entre OWL e PR-OWL.....	28
Tabela 3.1	Implementação de cardinalidades UML versus OWL 2.....	48

LISTA DE ABREVIATURAS E SIGLAS

AAL	Ambient Assisted Living
ADL	Activities of Daily Living
AmI	Ambient Intelligence
AQL	ADOxx Query Language
BADL	Basic Activities of Daily Living
BPMN	Business Process Model and Notation
DSML	Domain-Specific Modeling Language
HBMS	Human Behavior Monitoring and Support
HCM	Human Cognitive Model
HCM-L	Human Cognitive Model Language
IADL	Instrumental Activities of Daily Living
MEBN	Multi-Entity Bayesian Networks
OWL	Web Ontology Language
PR-OWL	Probabilistic Web Ontology Language
SSBN	Specific Situation Bayesian Networks
SQL	Structured Query Language
TICs	Tecnologias da Informação e Comunicação
UFRGS	Universidade Federal do Rio Grande do Sul
UML	Unified Modeling Language
XML	eXtensible Markup Language

SUMÁRIO

1 INTRODUÇÃO	11
1.1 Objetivos e Contribuições	14
1.2 Organização do Texto	15
2 FUNDAMENTAÇÃO	16
2.1 Ambientes de Vivência Assistida	16
2.2 Sensibilidade ao Contexto	18
2.2.1 Modelagem de Contexto	19
2.2.2 Tratamento de Incerteza	22
2.2.3 Ontologias Probabilísticas	24
2.2.4 Redes Bayesianas Multi-Entidade	26
2.3 Monitoramento e Suporte de Comportamento Humano	31
2.3.1 Linguagem para a modelagem conceitual de comportamento humano	34
2.3.2 Ferramenta HCM-L <i>Modeler</i>	40
2.4 Trabalhos Relacionados	43
2.5 Considerações Finais	45
3 ABORDAGEM PARA A PREDIÇÃO DE AÇÕES HUMANAS	46
3.1 Meta-Modelo Semântico	46
3.1.1 Metodologia Utilizada	46
3.1.2 Implementação	48
3.2 Modelo Semântico Probabilístico	50
3.2.1 Metodologia Utilizada	50
3.2.2 Implementação	51
3.3 Arquitetura da Solução	52
3.4 Interface de Interação com o Usuário	53
3.5 Considerações Finais	54
4 ESTUDO DE CASO	55
4.1 Cenário de Utilização	55
4.2 Aplicação da Abordagem	57
4.2.1 Obtenção dos valores de probabilidade	60
4.3 Considerações Finais	61
5 AVALIAÇÃO	62
5.1 Holdout e Amostragem Aleatória	62
5.2 Medidas de desempenho	63
5.3 Resultados	66
5.4 Considerações Finais	67
6 CONCLUSÃO	68
6.1 Trabalhos Futuros	70
REFERÊNCIAS	71

1 INTRODUÇÃO

O aumento da expectativa de vida e as baixas taxas de natalidade estão no centro da mudança demográfica que ocorre no mundo. Segundo projeções da Organização das Nações Unidas, ONU (2015), o número de pessoas acima dos 65 anos triplicará, de 524 milhões em 2010, para 1,5 bilhões em 2050. Essa ascensão da população idosa será acompanhada, naturalmente, por um aumento do número de diagnósticos das doenças relacionadas ao envelhecimento, tais como: distúrbios de hiperatividade, deficiência motora, visual e auditiva, declínios cognitivos, dentre outras (BUREAU, 2009).

Em detrimento das enfermidades citadas e, de acordo com Jacobsen et al. (2011), cerca de 70% dos idosos não conseguem viver de forma independente em seus lares, especialmente no que tange às dificuldades enfrentadas no desempenhar de atividades diárias (*Activities of Daily Living* - ADLs), como: se vestir, cozinhar, utilizar aparelhos eletrônicos, tomar um medicamento, etc. Assim, surge a necessidade de prover assistência a essas pessoas, geralmente desempenhada por familiares e/ou cuidadores.

Todavia, o emprego de cuidadores e serviços de saúde implica em altos custos. Por exemplo, estima-se que o custo envolvido para assistir pessoas com Alzheimer e outras demências vá saltar de \$203 bilhões, em 2013, para \$1,2 trilhões, em 2050, nos Estados Unidos. Já no Reino Unido, é gasto um total de 23£ bilhões por ano. A nível global, em 2010, os mesmos custos estiveram na ordem de \$604 bilhões, representando por volta de 1% do PIB mundial (SUZMAN; BEARD, 2011).

Diante disso, surge a necessidade de encontrar soluções que melhorem as condições de vida das pessoas na velhice, particularmente em seus ambientes de vivência (lares). Isso torna-se um desafio que norteia o desenvolvimento, apoiado pelas Tecnologias da Informação e da Comunicação (TICs), de sistemas robustos, automatizados, utilizáveis, seguros e de baixo custo, para assistência pessoal.

A área de pesquisa que se preocupa com isso é conhecida como Ambientes de Vivência Assistida (*Ambient Assisted Living* - AAL), na qual são abordadas várias temáticas como, por exemplo, assistência à mobilidade, inclusão social, comunicação, facilitação de ADLs, dentre outras (LI; LU; MCDONALD-MAIER, 2015). Esta última, por sua vez, é alvo deste trabalho, referindo-se à recomendação das ações necessárias, através de conselhos ou lembretes, para que uma dada ADL seja completada com sucesso.

Dentro dessa temática, sistemas para AAL necessitam de informações suficientes e adequadas sobre a situação atual, sobre o usuário e sobre o contexto particular. Fontes

apropriadas dessas informações se apresentam como derivações dos dados de sensores, tipicamente montados em uma casa inteligente (*Smart Home*), provenientes do monitoramento de comportamento¹ do usuário. Outra fonte de informação diz respeito a modelos conceituais de contexto e de comportamento sobre os quais podem ser aplicados algoritmos de raciocínio para derivar o serviço/apoio que melhor se adapte à situação atual do usuário. Além disso, outros aspectos são emergentes como o tratamento de incerteza e o reconhecimento de atividades.

A partir disso, as pesquisas costumam endereçar uma ou mais das características anteriores. Por exemplo, o trabalho proposto por Machado (2015) monitora o comportamento de uma pessoa por meio de sensores, confrontando os dados coletados com um modelo de contexto (implementado em uma ontologia OWL-DL (*Web Ontology Language - Description Logic*)) para determinar a situação, isto é, o estado atual do ambiente. O sistema utiliza um modelo semântico probabilístico para prever situações indesejadas e age proativamente para evitar que tais situações surjam. As ações pró-ativas são executadas na forma de interações com o usuário (avisos visuais, de áudio, etc.) acionados quando é detectada a possibilidade de uma situação indesejada. Essa possibilidade se chama nível de incerteza, o qual não é possível representar em OWL-DL. Isso, portanto, justifica o modelo semântico possuir conotação probabilística, cuja implementação é dada sobre uma ontologia com tal aspecto denominada PR-OWL (*Probabilistic Web Ontology Language*).

Já o trabalho proposto por Michael and Mayr (2013), com o projeto HBMS², busca manter o conhecimento episódico sobre o comportamento de uma pessoa no chamado Modelo Cognitivo Humano (*Human Cognitive Model - HCM*). A partir dele, a informação de suporte é derivada por algoritmos de raciocínio quando, por exemplo, declínios cognitivos ocorrem. Cada HCM é criado utilizando a Linguagem de Modelagem Cognitiva Humana (*Human Cognitive Modeling Language - HCM-L*), desenvolvida no âmbito do projeto HBMS para descrever o conhecimento comportamental sobre ações humanas (operações), como ocorrem nas ADLs, seus objetivos e seu contexto de interesse. Ainda, uma ferramenta de modelagem (*HCM-L Modeler*) foi desenvolvida para suportar a criação, o gerenciamento e a validação dos modelos em HCM-L.

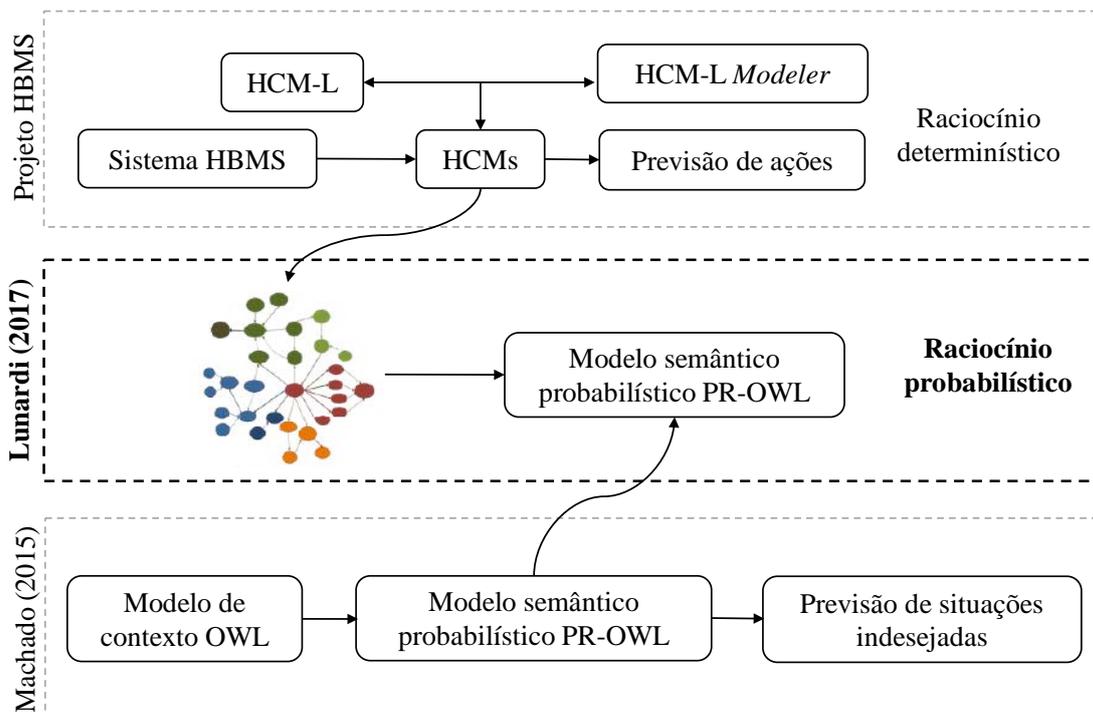
O trabalho de Machado (2015) foi adotado por ter sido desenvolvido no instituto de informática da Universidade Federal do Rio Grande do Sul (UFRGS). Em 2015, um

¹Segundo a literatura, comportamento e atividade (ADL) são conceitos indistintos para se referir à uma sequência de ações humanas, com um determinado objetivo (RODRÍGUEZ et al., 2014, p.2).

²*Human Behavior Monitoring and Support* - é um projeto na área de Ambientes de Vivência Assistida financiado pela fundação Klaus Tschira Stiftung gGmbH, Heidelberg

artigo referente a esse foi apresentado durante um *workshop* da conferência Internacional de Modelagem Conceitual (ER). Nessa ocasião, os responsáveis pelo projeto HBMS, da universidade *Alpen-Adria* de *Klagenfurt*, na Áustria, se mostraram interessados. Com isso, surgiu uma possibilidade de cooperação internacional da qual se originou esta pesquisa. Sendo assim, após o estudo aprofundado dos dois trabalhos, foi identificado que o raciocínio aplicado sobre cada modelo de comportamento não considerava aspectos de incerteza (raciocínio determinístico). Dessa forma, se não tratados, poderiam ocasionar más decisões comprometendo, sobretudo, o suporte ao usuário. A Figura 1.1 apresenta a inovação deste trabalho frente aos outros dois: o raciocínio probabilístico. Isso é atingido através de uma adaptação dos modelos HCM para uma ontologia que, por sua vez, alimenta o modelo semântico probabilístico adaptado de Machado (2015).

Figura 1.1: Contribuição do trabalho



Fonte: O autor.

Além disso, através de uma análise criteriosa de outros trabalhos relacionados, foi constatado que a maioria realiza a modelagem de comportamento por meio de técnicas puramente direcionadas a dados (*Data-Driven*). A fragilidade dessas técnicas se refere ao famoso problema de “partida a frio” (*cold-start*), ou seja, quando não existem dados suficientes para formar um padrão. Uma solução poderia ser a utilização de métodos direcionados a conhecimento (*Knowledge-Driven*), tal como os modelos conceituais de comportamento, porém estes têm sido pouco empregados.

Portanto, este trabalho se diferencia no sentido de cobrir as lacunas supracitadas, através de uma abordagem que combina técnicas baseadas em dados (probabilidade) e em conhecimento (modelos conceituais de comportamento) para a facilitação de atividades diárias. Mais especificamente, a partir de um modelo conceitual de comportamento e de uma ontologia probabilística, é predita a próxima ação humana mais provável para a condução fluída de uma ADL. Essa predição pode ajudar, por exemplo, quando o usuário hesita ou para de executar ações, caracterizando situações de declínio cognitivo ou físico.

1.1 Objetivos e Contribuições

O **objetivo geral** desta dissertação consiste em desenvolver uma abordagem que beneficie os sistemas para Ambientes de Vivência Assistida com a capacidade de prever ações humanas para a facilitação de atividades diárias, particularmente quando declínios cognitivos relacionados a elas ocorrerem. Para atingir tal objetivo, os seguintes **objetivos específicos** foram definidos:

- Desenvolver um meta-modelo semântico para a modelagem de comportamento e de contexto, baseado no meta-modelo da linguagem HCM-L;
- Adaptar o modelo semântico probabilístico para a previsão de situações indesejadas, proposto por Machado (2015), para a previsão de ações sobre os modelos de comportamento;
- Propor uma arquitetura de predição e inferência de ações utilizando, como prova de conceito, o sistema HBMS;
- Avaliar a abordagem e seu desempenho através de medidas como a precisão, a revocação e a medida-F;

As principais contribuições deste trabalho são descritas a seguir sendo exploradas com maior profundidade no capítulo de Conclusões.

- O meta-modelo semântico, com o qual é possível gerar modelos de qualquer ADL, bem como de elementos contextuais;
- O modelo semântico probabilístico que permite realizar predição e inferência sobre os modelos através da representação e do tratamento de incerteza.

1.2 Organização do Texto

Este trabalho está estruturado, a contar desta introdução, em seis capítulos:

- O Capítulo 2 apresenta os conceitos que fundamentam o trabalho, iniciando por AAL como área de pesquisa e com foco em ADLs. Em seguida é discutido o tema de sensibilidade ao contexto e as formas de modelá-lo. Ainda são expostos temas como tratamento de incerteza, ontologias probabilísticas e redes Bayesianas Multi-Entidade compondo a base para a construção de modelos semânticos probabilísticos. A seguir, apresenta-se o projeto HBMS, ferramenta e linguagem para modelagem de comportamento humano. Por fim são apresentados os trabalhos relacionados;
- O Capítulo 3 trata da abordagem, através da descrição do meta-modelo semântico, para a modelagem de comportamento e de contexto e do modelo semântico probabilístico assim como das respectivas metodologias adotadas na construção de cada um. Além disso, é apresentada uma visão arquitetural de como a abordagem poderia ser utilizada para prever ações. Finalmente é apresentado um protótipo de interface de interação com o usuário, baseado em plataforma Android.
- O Capítulo 4 apresenta um cenário para a aplicação da abordagem;
- O Capítulo 5 apresenta a avaliação da abordagem, utilizando um conjunto de dados real, através de três medidas de desempenho: precisão, revocação e medida F;
- Por fim, o Capítulo 6 explicita as conclusões, contribuições e trabalhos futuros resultantes desta pesquisa.

2 FUNDAMENTAÇÃO

Este capítulo apresenta os assuntos relacionados com este trabalho, organizando-se em cinco seções. A seção 2.1 apresenta os Ambientes de Vivência Assistida, domínio de aplicação no qual a pesquisa foi aplicada. Na seção 2.2, é discutido o tema de sensibilidade ao contexto, com foco em semântica do contexto para predição e inferência de ações em atividades diárias. Na seção 2.3, é apresentado o projeto e a aplicação em que a abordagem desenvolvida foi aplicada. A seção 2.4 apresenta os trabalhos relacionados considerados mais importantes, apontando suas lacunas. Finalmente, são tecidas algumas considerações finais sobre o capítulo.

2.1 Ambientes de Vivência Assistida

AAL é um campo de pesquisa cujo foco é buscar, através das TICs, soluções inovadoras que possam prover assistência a pessoas com algum declínio cognitivo, ou outra limitação, tornando-as aptas a viver de forma independente, segura e confortável em seus ambientes de vivência (LI; LU; MCDONALD-MAIER, 2015).

As pessoas que mais sofrem com as perdas cognitivas são as idosas, visto que o envelhecimento afeta os sentidos, a capacidade motora, a memória, dentre outros. Assim, em razão do grande crescimento dessa parcela populacional, conforme demonstrado no Capítulo 1, governos, organizações sem fins lucrativos e indústria estão promovendo o que chamam de a “era AAL”, cujo propósito é fomentar instituições de pesquisa a propor soluções que possam aumentar a qualidade de vida das pessoas na velhice. A União Europeia, por exemplo, implementou um esquema específico de financiamento, o programa AAL, o qual estimula, com largos orçamentos, projetos de pesquisa na área desde 2008 (CALVARESI et al., 2016). O programa, detalhado em Europe (2008), conceitua AAL através de uma série de objetivos, sendo:

- Estender o tempo de vivência autônoma, autoconfiante e com mobilidade das pessoas, em seus ambientes preferidos;
- Apoiar a preservação da saúde e capacidades funcionais dos idosos;
- Promover um estilo de vida melhor e mais saudável para indivíduos em risco;
- Reforçar a segurança, prevenir o isolamento social e apoiar a preservação da rede multifuncional em torno do indivíduo;

- Apoiar cuidadores, famílias e organizações de cuidado com a saúde;
- Aumentar a eficiência e a produtividade dos recursos usados nas sociedades em envelhecimento.

Para atingir tais objetivos, as pesquisas em AAL ancoram-se em áreas como a Inteligência Ambiental (*Ambient Intelligence - AmI*) que, segundo Sadri (2011), visiona ambientes discretos, interconectados, adaptáveis, dinâmicos, embarcados e inteligentes que apoiem as pessoas que neles habitam. Por inteligente, entende-se que o ambiente é dotado de sistemas sensíveis ao contexto, adaptativos e que aprendem o comportamento dos usuários, respondendo às suas necessidades. Já por embarcado entende-se que o ambiente é composto por pequenos dispositivos e sensores existentes em cada objeto com o qual um indivíduo interage. Esta visão, portanto, vai ao encontro da proposta pela computação ubíqua a qual, de acordo com Weiser (1993), estabelece que um ambiente computacional não deve impor restrições ao usuário, sendo invisível e transparente.

A partir disso, Li, Lu and McDonald-Maier (2015) afirmam que um ambiente de vivência pode não corresponder só ao lar onde reside uma pessoa, mas também a outros espaços públicos. Assim, os autores dividem as aplicações para AAL nas seguintes categorias: facilitação de atividades diárias, assistência à mobilidade, cuidados da saúde e reabilitação, inclusão social e comunicação. A primeira categoria é a mais difundida atualmente, na qual evidencia-se o conceito de casas inteligentes (*Smart Homes*).

Uma casa inteligente (*Smart Home*) é definida por Nugent et al. (2009) como sendo um ambiente doméstico montado com uma série de sensores, atuadores e dispositivos, além de sistemas baseados nas TICs. Essa estrutura, por sua vez, pode ser utilizada para monitorar o que os moradores realizam no dia-a-dia através de dois importantes tópicos de pesquisa: o reconhecimento de atividades e a compreensão de comportamento humano. Com isso, é possível reconhecer ações, atividades e situações que influam a detecção de, por exemplo, declínios cognitivos em atividades de vivência diária (*Activities of Daily Living - ADL*) (MONEKOSSO; FLOREZ-REVUELTA; REMAGNINO, 2015).

Lawton and Brody (1969) e Katz and Akpom (1976), quatro importantes pesquisadores em psicologia e geriatria, comumente citados em pesquisas em *Smart Homes*, subdividem as ADLs em atividades pessoais básicas para o auto cuidado (*Basic Activities of Daily Living - BADLs*) e em atividades domésticas ou instrumentais (*Instrumental Activities of Daily Living - IADLs*). As BADLs correspondem às atividades essenciais, tais como tomar banho, vestir-se, alimentar-se, deslocar-se, etc. Por outro lado, as IADLs podem ser entendidas como não essenciais, mas que permitem ao indivíduo viver

independentemente em uma comunidade, além de requererem níveis de habilidade, por exemplo: limpar a casa, fazer compras, gerenciar as finanças, preparar refeições, tomar medicamentos, usar dispositivos eletrônicos, etc.

As ADLs configuram-se como o elemento central na compreensão do comportamento humano e, para tal, a modelagem de atividades torna-se um tema central. Neste trabalho, os modelos são utilizados para auxiliar pessoas idosas que sofrem com qualquer tipo de declínio cognitivo. Por exemplo, através de raciocínio é possível fornecer apoio quando a pessoa não lembra os passos para completar uma determinada atividade (NI; HERNANDO; CRUZ, 2015). Cada passo diz respeito a mais simples unidade de uma atividade humana, denominada “ação”, cuja ocorrência está associada a um evento de sensor (RODRÍGUEZ et al., 2014).

As informações de contexto também são cruciais para a modelagem e monitoramento de atividades, pois circundam a ocorrência dessas. Dentro de um ambiente *Smart Home* existem vários tipos de informações contextuais como, por exemplo, localização, pessoas, objetos, tempo, etc (NI; HERNANDO; CRUZ, 2015). Tais dimensões, portanto, necessitam de uma representação computacional para que possam acurar o processo de raciocínio, sendo essa representação abordada pela área de pesquisa conhecida como sensibilidade ao contexto, apresentada a seguir.

2.2 Sensibilidade ao Contexto

A sensibilidade ao contexto (*Context-awareness*) ou, então, computação sensível ao contexto (*Context-aware Computing*) foi discutida, primeiramente, por Schilit, Adams and Want (1994) como uma nova classe de aplicações as quais eram cientes do contexto que as circundavam. Essas aplicações se adaptavam de acordo com a localização, as pessoas ao redor, os dispositivos acessíveis e ao tempo. A partir disso, era possível examinar o ambiente e reagir frente às suas mudanças. Mais tarde, Dey (2001) cunhou uma definição mais genérica: “Um sistema é sensível ao contexto se o utiliza para prover informações relevantes e/ou serviços ao usuário, cuja relevância dependa da tarefa do usuário.”. O mesmo autor, Dey (2001, p. 2), ainda propôs uma das definições de contexto mais notórias da literatura:

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

Aplicações cientes de contexto levam em consideração perguntas como “quem”, “onde”, “quando” e “o quê” para as entidades no intuito de determinar o “porquê” de uma determinada situação estar ocorrendo. Os tipos de contexto que respondem a tais perguntas são, respectivamente: a identidade, a localização, o tempo e a atividade, sendo também denominados tipos primários de contexto uma vez que podem funcionar como índices para outras fontes de informações contextuais (ABOWD et al., 1999). A partir disso, é possível pensar em como organizar o uso de contexto utilizando técnicas de modelagem, apresentadas e discutidas a seguir.

2.2.1 Modelagem de Contexto

Um sistema só conseguirá atuar sobre o ambiente se compreender minimamente como os objetos existentes neste se relacionam entre si e com o usuário. Tal compreensão se dá por meio da geração de modelos de contexto, os quais são abstrações da realidade com certa conceituação ou, ainda, a representação da realidade com um fim específico. Os modelos devem extrair uma representação genérica, abstrata e simplificada da realidade. As abstrações são definidas em termos de conceitos, por exemplo, representações de certos aspectos das entidades que existem no domínio (GUIZZARDI, 2005).

Dentre as técnicas existentes para a modelagem de contexto, destacam-se seis: **Pares Chave-Valor** (utilizam um algoritmo de correspondência simples que define uma lista de atributos e seus conteúdos/valores); **Esquemas de Marcação** (utilizam uma estrutura de dados hierárquica, principalmente em XML, que consiste em *tags* de marcação juntamente com seus atributos e conteúdo); **Gráficas** (utilizam linguagens como *Unified Modeling Language - UML* e *Object Role Modeling - ORM*, fazendo conexões entre atributos de contexto e valores baseadas em relacionamentos.); **Orientadas a Objetos** (classes de objeto encapsulam ou representam diferentes tipos de contexto, alcançando assim o contexto ou processando seus atributos são regulados com hierarquias e relacionamentos de classe orientados a objetos projetados.); **Baseadas em Lógica** (incluem formalidade baseada em fatos, expressões e regras, a fim de definir restrições, limitações, políticas ou preferências, ao mesmo tempo em que define o raciocínio de contexto.); e **Baseadas em Ontologias** (utiliza tecnologias semânticas para representar atributos e relacionamentos relacionados ao contexto.) (MOORE et al., 2007).

Moore et al. (2007) comparam cada técnica através de seis características comumente requeridas por sistemas inteligentes sensíveis ao contexto: Composição Distribuída

(remete ao fato de que as aplicações sensíveis ao contexto são geralmente implementada em sistemas distribuídos e dinâmicos); Validação Parcial (capacidade de validar parcialmente o conhecimento contextual em nível estrutural, bem como no nível de instância, dada a potencial existência de erros na definição de relações contextuais entre entidades); Qualidade das Informações (a qualidade de uma informação fornecida por um sensor varia ao longo do tempo, bem como a riqueza de informações fornecidas por diferentes tipos destes que caracterizam uma entidade); Incompletude e Ambiguidade (capacidade para lidar com informações incompletas e ambíguas); Nível de Formalidade (descrição de fatos (contextuais) e inter-relações de forma precisa e rastreável); e Aplicabilidade/Adaptabilidade (é importante que um modelo de contexto seja adaptável para permitir o uso em domínios, sistemas e infraestrutura existentes).

A Tabela 2.1, apresenta a análise comparativa das técnicas de modelagem de contexto, na qual as colunas apresentam as características e as linhas apresentam as técnicas. O sinal de (–) significa limitação da técnica em atender a característica em questão, e o sinal de (––) significa limitação ainda maior. Por outro lado, os sinais (+) e (++) significam maior atendimento.

Tabela 2.1: Análise das técnicas empregadas na modelagem de contexto.

Identificação	Técnica de Modelagem de Contexto	Composição Distribuída	Validação Parcial	Qualidade das Informações	Incompletude e Ambiguidade	Nível de Formalidade	Aplicabilidade/Adaptabilidade
1	Pares Chave-Valor	–	–	––	––	––	+
2	Esquemas de Marcação	+	++	–	–	+	++
3	Gráficas	––	–	+	–	+	+
4	Orientadas a Objetos	++	+	+	+	+	+
5	Baseadas em Lógica	++	–	–	–	++	––
6	Baseadas em Ontologias	++	++	+	+	++	+

Fonte: Adaptado de Moore et al. (2007).

Aliado ao que foi apresentado acima, os autores Ni, Hernando and Cruz (2015) e Yurur et al. (2016) discutem algumas vantagens e desvantagens de cada técnica (1 a 6), conforme a Tabela 2.2. Os autores reforçam, ainda, que tais técnicas são as mais utilizadas para a modelagem de contexto e que a escolha de uma delas depende da natureza das informações contextuais a serem modeladas e da aplicação a ser desenvolvida.

Tabela 2.2: Vantagens e desvantagens de cada técnica

Técnica	Vantagens	Desvantagens
1	<ul style="list-style-type: none"> ● fácil gerenciar com tamanho reduzido de dados; ● técnica de correspondência de texto simples; 	<ul style="list-style-type: none"> ● não escalável; ● não aplicável em estruturas hierárquicas; ● não permite uma recuperação eficiente do contexto e validação;
2	<ul style="list-style-type: none"> ● recuperação de dados eficiente; ● aplicável em estruturas hierárquicas; ● permite validação parcial; 	<ul style="list-style-type: none"> ● sem critério de <i>design</i>; ● raciocínio de contexto complexo em múltiplos esquemas; ● não permite uma recuperação eficiente do contexto e validação;
3	<ul style="list-style-type: none"> ● permite a modelagem de relacionamentos; ● melhor para gerenciar dados complexos; 	<ul style="list-style-type: none"> ● difícil de alterar modelos; ● não possui uma estrutura de <i>design</i> específica; ● falta de interoperabilidade e validação com modelos similares;
4	<ul style="list-style-type: none"> ● permite relacionamentos mais complexos e composição; ● fácil de projetar e operável em tempo de execução; 	<ul style="list-style-type: none"> ● nenhum critério de projeto específico, não trivial para atualização e otimização; ● difícil para recuperar dados; ● limitada à aplicação;
5	<ul style="list-style-type: none"> ● cooperável com outros modelos; ● alto grau de formalidade; ● fácil de projetar e operável em tempo de execução; 	<ul style="list-style-type: none"> ● falta de padronização; ● permite raciocínio sobre o contexto e validação somente até certo nível (peça em raciocínio sobre a incerteza);
6	<ul style="list-style-type: none"> ● permite compartilhar conhecimento por integração e reuso; ● provê um modelo bem definido, rico, de qualidade e relações explícitas; ● provê identificação única, tratamento de incerteza e validação parcial; 	<ul style="list-style-type: none"> ● complexa e computacionalmente dispendiosa;

Fonte: Adaptado de Ni, Hernando and Cruz (2015), Yurur et al. (2016).

De forma geral, a técnica de modelagem de contexto baseada em ontologias é a que atinge maior satisfação dentre as apresentadas. De acordo com Gruber (1993), ontologias são uma “especificação formal e explícita de uma conceituação compartilhada”. Em outras palavras, uma ontologia é conceitual, pois refere-se a um modelo abstrato do mundo real; é explícita porque os tipos de conceitos utilizados e suas restrições de uso são explicitamente definidos; é formal porque pode ser entendida por máquina; é compartilhada porque captura um conhecimento consensual, aceito por um grupo. Guarino (1998) aponta o uso de ontologias como um meio para adicionar semântica à web. Ele as define

como uma representação formal do conhecimento, processável por computador.

A linguagem mais utilizada para a implementação de ontologias é a *Web Ontology Language* - OWL, em alguma de suas variações *Lite*, *Description Logic* - DL e *Full*. A variação mais difundida é a DL devido ao seu poder de decidibilidade e possibilidade de utilização de motores de inferência (*reasoners*) capazes de checar a consistência dos modelos desenvolvidos, inferir novos relacionamentos entre classes e descobrir conhecimentos implícitos. A OWL-DL ainda permite a modelagem de um domínio específico através da definição de classes, indivíduos, características de indivíduos (propriedades de tipo de dados) e relacionamentos entre eles (propriedades objeto) (BETTINI et al., 2010).

Por isso, neste trabalho, escolheu-se ontologias e a linguagem OWL-DL para a representação e raciocínio sobre o contexto. Entretanto, os modelos baseados nesta abordagem carecem de mecanismos para raciocinar sobre a incerteza. Essa característica é tipicamente encontrada em sistemas que possuem foco em predição de situações futuras já que o próprio senso comum diz que o futuro é incerto. Dessa forma, o foco em predição e o tratamento de incerteza são discutidos a seguir com especial atenção às tecnologias da Web Semântica.

2.2.2 Tratamento de Incerteza

A incerteza está onipresente em tudo o que acontece ao nosso redor, por exemplo, a previsão do tempo é incerta; o diagnóstico de uma doença é incerto; a percepção do mundo é incerta; e assim por diante (LI; CHEN; FENG, 2013). De acordo com o Conselho Nacional de Pesquisa dos EUA (2000) “a incerteza é um conceito geral que reflete a falta de certeza sobre algo ou alguém, que vai desde a falta de segurança completa até uma quase completa falta de convicção sobre um resultado”. De forma menos formal, incerteza pode ser entendida como a falta de informação adequada para tomar uma decisão.

Exemplos disso, em ambientes inteligentes, são as informações contextuais derivadas a partir de dados coletados por sensores, os quais nem sempre são precisos. Eles são propensos a falha de *hardware*, falta de energia, problemas de comunicação, etc. Assim, um sistema ciente de contexto deve ser sensível à tal imprecisão (incerteza), a fim de tomar as decisões corretas. Além disso, os modelos de contexto, comumente utilizados nesses sistemas, também são passíveis de concepção incorreta pelo modelador uma vez que dependem da sua percepção do mundo. Portanto, a representação e o tratamento de incerteza aparecem como uma necessidade crucial para se realizar um raciocínio satisfa-

tório e lógico (ALOULOU et al., 2015).

Dentre as principais formas de raciocinar sobre a incerteza, segundo Bettini et al. (2010), destacam-se: lógica Fuzzy, lógica probabilística, Redes Bayesianas, Modelo Oculto de Markov e teoria da evidência de Dempster-Shafer. Cada uma delas possui uma adequação diferente que varia de acordo com o domínio pretendido. Maiores informações sobre elas podem ser encontradas no estudo mencionado anteriormente. De forma geral, o raciocínio probabilístico permite o processamento sobre incerteza, pois faz o tratamento de hipóteses para identificar a probabilidade de ocorrência dessas mesmo antes de ser conhecido o conjunto de informações que as evidenciam. Com isso, é possível realizar previsões através de raciocínio incerto. Neste trabalho, tal raciocínio precisa ser realizado sobre modelos de contexto baseados em ontologias OWL-DL.

Entretanto, a Lógica Descritiva (DL), variação da OWL adotada, não apresenta suporte nativo para o raciocínio sobre incerteza. Isso justifica-se pelo fato de que DL é um subconjunto da Lógica de Primeira Ordem (*First Order Logic* - FOL). Esta, por sua vez, é aplicada pela definição de um conjunto de axiomas ou sentenças que fazem afirmações sobre um domínio. As sequências lógicas de um conjunto de axiomas consistem de sentenças que são sempre verdadeiras em todas as interpretações, também chamadas de sentenças válidas (LASKEY, 2008). Por esse motivo, então, FOL acaba não sendo adequada para domínios nos quais exista incerteza nas relações entre os conceitos, como, por exemplo, sistemas que envolvam previsão, diagnóstico, etc.

Assim, redes Bayesianas são comumente utilizadas para cobrir a deficiência apresentada acima, configurando-se como o modelo ideal para o raciocínio probabilístico. Uma rede Bayesiana modela um conjunto de variáveis aleatórias $X = X_1, \dots, X_n$ no qual cada uma é o nó de um grafo direcionado acíclico (*Directed Acyclic Graph* – DAG). Os nós são ligados através de arcos direcionados representando dependência entre os mesmos. Por exemplo, um arco $X_i \rightarrow X_j$, representa que X_i é pai de X_j . Cada nó do grafo contém uma tabela de probabilidade condicional (*Conditional Probability Table* – CPT) $P(X_i | \text{pais}(X_i))$ que representa a probabilidade de X_i condicionada a seus pais (POLASTRO, 2012).

Com isso, evidencia-se a necessidade de unir o poder da expressividade disponibilizada pela FOL, existente em ontologias codificadas em OWL-DL, e o raciocínio probabilístico através de Redes Bayesianas, para tratamento de incerteza. Tal necessidade é tratada pela área de ontologias probabilísticas, apresentada a seguir (MACHADO, 2015).

2.2.3 Ontologias Probabilísticas

As ontologias probabilísticas podem ser definidas como uma representação formal e explícita que expressa conhecimento sobre um domínio de aplicação por meio de: tipos de entidades; propriedades dessas entidades; relacionamentos; processos e eventos que acontecem com essas entidades; regularidades estatísticas que caracterizam o domínio; conhecimento inconclusivo, ambíguo, incompleto, não confiável relacionado com entidades do domínio; e a incerteza sobre todas as formas anteriores. São utilizadas com o intuito de descrever o conhecimento sobre um domínio e incerteza associada a este de uma forma estruturada e compartilhável, idealmente em um formato processável por computador. Elas também expandem as possibilidades de ontologias padrão, introduzindo a exigência de uma representação adequada das regularidades estatísticas do domínio de aplicação (COSTA, 2005).

Basicamente, são duas as abordagens existentes para a obtenção de ontologias probabilísticas. A primeira consiste em representar a incerteza pela descrição de probabilidades como anotações OWL (por exemplo, marcações descrevendo detalhes relacionados com um objeto ou propriedades específicas). Entretanto, isso não é suficiente, pois informações não podem ser representadas, como a dependência entre probabilidades (COSTA; LASKEY, 2006b). A segunda consiste na utilização de alguma Linguagem Probabilística de Primeira Ordem (*First-Order Probabilistic Languages* - FOPLs), a qual combina aspectos de representação probabilística com lógica de primeira ordem (HOWARD; STUMPTNER, 2014).

Howard and Stumptner (2014) analisam três dessas linguagens: *Probabilistic Relational Models* - (PRMs), *Object-Oriented Probabilistic Relational Modelling Language* - (OPRML) e *Multi-Entity Bayesian Networks* - (MEBNs). A Tabela 2.3 mostra uma comparação das linguagens (colunas) considerando os seguintes aspectos (linhas): a manipulação de incerteza; o suporte estrutural a tipos de herança; e tipos de domínios sobre os quais a linguagem pode representar. Em relação à incerteza ainda se tem: de atributo é a incerteza sobre atributos de entidades e relacionamentos; de número é a incerteza sobre dados numéricos de entidades em um domínio; de referência é a incerteza sobre as relações entre entidades do domínio; de identidade é incerteza sobre a identidade de uma entidade; de existência é a incerteza sobre a existência de entidades e relações no domínio; e de tipos ocorre quando uma entidade de interesse é identificada, mas ela pode ser de um ou mais subtipos possíveis.

Tabela 2.3: Comparação das linguagens probabilísticas de primeira ordem

		PRMs	MEBNs	OPRML
Incerteza	Atributo	✓	✓	✓
	Número	✓	✓	✓
	Referência	✓	✓	✓
	Identidade	✓	✓	✗
	Existência	✓	✓	✓
	Tipo	✗	✓	✗
Herança	Simples	✓	✗	✓
	Múltiplo	✗	✓	✗
Domínio	Estático	✓	✓	✓
	Recursivo	✓	✓	✓
	Dinâmico	✗	✓	✓

Fonte: Adaptado de Howard and Stumptner (2014).

Dessa forma, percebe-se que a linguagem MEBN é a que melhor se adéqua às restrições impostas pela definição de uma ontologia probabilística. Sua utilização na Web Semântica se dá por uma extensão da OWL, proposta por Costa (2005), através de uma ontologia de topo denominada *Probabilistic Web Ontology Language* - PR-OWL, cuja expressividade é suficientemente poderosa para representar até mesmo os domínios mais complexos. Por esse motivo, adotou-se-a para realizar predição de ações em atividades diárias, foco deste trabalho.

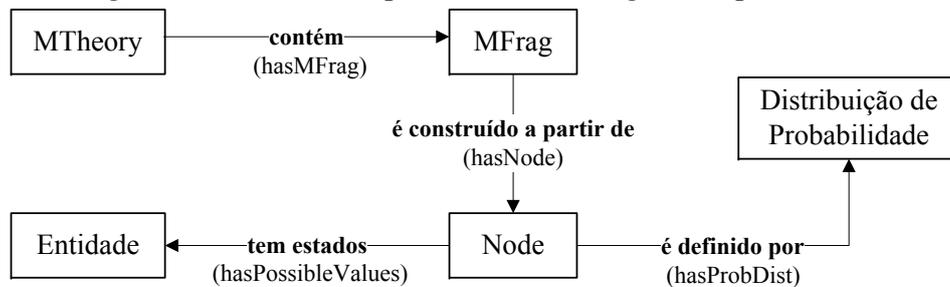
PR-OWL segue as premissas definidas pelo *World Wide Web Consortium* - (W3C) e foi construída para ser interoperável com ontologias não probabilísticas (determinísticas), ou seja, o especialista pode escolher os conceitos que deseja incluir na “parte probabilística” da ontologia, enquanto escreve os outros conceitos em OWL padrão (COSTA et al., 2008). Atualmente, PR-OWL encontra-se em sua segunda versão a qual melhorou a compatibilidade entre PR-OWL e OWL em dois aspectos importantes: formalização de associação entre variáveis aleatórias de teorias probabilísticas com os indivíduos, classes e propriedades de linguagens ontológicas como a OWL; e que os valores de variáveis aleatórias podem variar entre os tipos de dados OWL. Além disso, foi desenvolvida uma ferramenta *open-source* chamada UNBBayes¹ para apoiar a construção de ontologias PR-OWL2 (LASKEY et al., 2011).

A Figura 2.1 elucidada os principais conceitos PR-OWL, na qual os retângulos representam as classes gerais, ao passo que as setas representam os relacionamentos entre as classes. Uma ontologia probabilística codificada em PR-OWL necessita ter pelo menos

¹<http://unbbayes.sourceforge.net/>

um indivíduo da classe *MTheory*, que é basicamente um grupo de *MFrag*s as quais formam coletivamente uma *MTheory* válida (CARVALHO; LASKEY; COSTA, 2010). Tais estruturas são, na verdade, elementos MEBN os quais serão melhor detalhados a seguir. O modelo completo pode ser encontrado em (COSTA, 2005, p.150)

Figura 2.1: Modelo simplificado da ontologia de topo PR-OWL



Fonte: Adaptado de (COSTA, 2005).

2.2.4 Redes Bayesianas Multi-Entidade

Uma Rede Bayesiana Multi-Entidade (*Multi-Entity Bayesian Network* - MEBN) é uma lógica Bayesiana de primeira ordem que integra lógica clássica de primeira ordem (FOL) com teoria da probabilidade. O Teorema de Bayes fornece uma base matemática para aprendizagem e inferência, que se reduz à lógica clássica no caso de conhecimentos certos, ou seja, quando todas as probabilidades são zero ou um. Com isso, FOL é estendida no que diz respeito à representação coerente de incerteza, sem perder expressividade (COSTA; LASKEY, 2006b).

MEBN representa o mundo como um conjunto de entidades inter-relacionadas e seus respectivos atributos. O conhecimento sobre os atributos das entidades e suas relações é representado como uma coleção de fragmentos MEBN (*MFrag*s) organizados em teorias MEBN (*MTheories*). Uma teoria MEBN é definida como um conjunto de *MFrag*s que juntos satisfazem restrições de consistência, assegurando a existência de uma única distribuição de probabilidade conjunta. Já um *MFrag*, isolado, pode ser comparado a uma Rede Bayesiana em que suas variáveis aleatórias são chamadas de nós, representando os atributos e propriedades de um conjunto de entidades, e seus arcos são relações de dependência direta entre os nós. Cada nó normalmente possui como argumentos uma ou mais variáveis ordinárias, substituídas por instâncias de entidades durante o processo raciocínio e inferência (LASKEY, 2008).

O processo de raciocínio e inferência MEBN é realizado, primeiramente, pela

interposição de uma pergunta, a qual implica na geração de uma Rede Bayesiana de Específica Situação (*Specific Situation Bayesian Network* – SSBN). Esta, por sua vez, é uma rede Bayesiana comum que visa determinar as probabilidades de uma situação no domínio de conhecimento. Instâncias e evidências (fatos conhecidos do domínio) tem um papel fundamental nesta etapa, pois são elas que compõem as perguntas a serem submetidas ao algoritmo de raciocínio (CARVALHO et al., 2013). De um ponto de vista lógico, a inserção de uma evidência em uma MTheory corresponde a um novo axioma em lógica de primeira ordem. A lógica MEBN é inerentemente aberta, tendo a capacidade de incorporar novos axiomas como prova e atualizar as probabilidades de todas as variáveis aleatórias (COSTA; LASKEY, 2006a).

Segundo Matsumoto et al. (2011), um MFrag é composto por três tipos de nós: residente, entrada e contexto. Cada um deles é melhor explicado a seguir. Além disso, a Tabela 2.4 apresenta um possível mapeamento entre conceitos OWL e PR-OWL.

- Nós residentes (*Resident nodes*): são as variáveis aleatórias, o centro de uma MFrag. A distribuição de probabilidade local é definida aqui, de forma exclusiva e explícita. Caso não possa ser definida explicitamente, é assumida uma distribuição uniforme. Os valores possíveis de um nó residente podem ser uma entidade existente ou uma lista de valores mutuamente exclusivos;
- Nós entrada (*Input nodes*): são ponteiros que fazem referência ao nó residente de outra MFrag. Os nós de entrada também fornecem um mecanismo que permite a reutilização dos nós residentes entre MFrag (recursão). Os nós de entrada influenciam a distribuição de probabilidade dos nós residentes que são seus filhos em um determinado MFrag, mas suas próprias distribuições são definidas em outra MFrag;
- Nós contexto (*Context nodes*): representam condições que devem ser satisfeitas para tornar válida uma distribuição em uma MFrag. Os nós de contexto podem representar vários tipos de padrões de incerteza, como a incerteza sobre as relações entre entidades. Se for possível inferir, a partir da base de conhecimento (a ontologia), que o valor de um nó de contexto é verdadeiro, a distribuição de probabilidade da MFrag será aplicada no modelo de inferência. Se esse valor for falso, uma distribuição padrão será utilizada. Se o valor é desconhecido, o nó de contexto torna-se praticamente pai de todos os nós residentes na mesma MFrag;

Tabela 2.4: Equivalência de conceitos entre OWL e PR-OWL

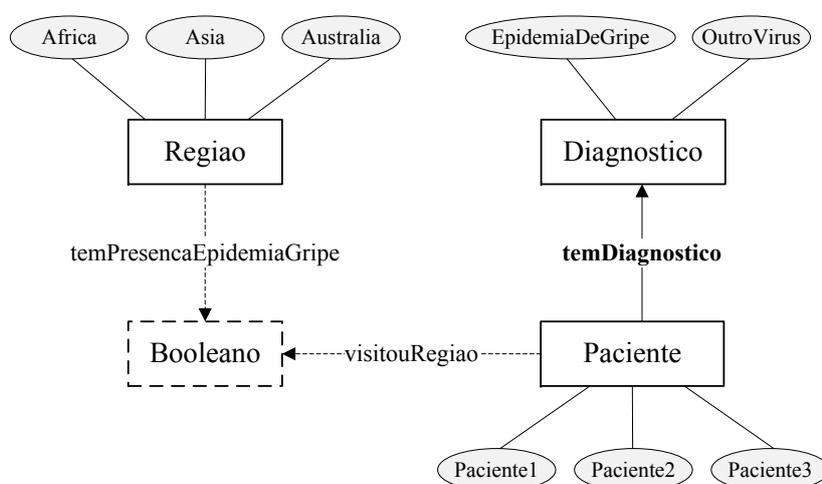
OWL	PR-OWL
Classes abaixo de Thing	Classes abaixo de Entity (abaixo de Thing)
Propriedades Objeto e de Dados	Nós Residentes
Componentes de Asserção ABox	Indivíduos (instâncias de Entity) e Evidências
Restrições em Classes e Propriedades	Nós Contexto

Fonte: Adaptado de Matsumoto et al. (2011).

A MEBN por si só não especifica um padrão para as tabelas de probabilidade condicional (CPTs), porém a ferramenta UnBBayes-MEBN fornece uma forma flexível de as declarar passando a serem denominadas distribuição de probabilidade local (*Local Probability Distribution* - LPD). Isso é realizado através de uma linguagem especial de *scripting*. Maiores detalhes seu uso e sintaxe podem ser encontrados no estudo realizado por (MATSUMOTO et al., 2011, p.17).

Para melhor compreensão da lógica que implementa PR-OWL, abaixo é desenvolvido um exemplo prático por meio de uma ontologia simples para apoiar o diagnóstico de um paciente com o sintoma de febre. Se o paciente visitou recentemente uma região com epidemia de gripe, esta pode ser a causa. Caso contrário, o paciente pode estar acometido por outro tipo de vírus. A Figura 2.2 apresenta os principais conceitos de tal ontologia, codificados em OWL-DL, através do *software* Protégé². Os retângulos representam as classes e as elipses, seus respectivos indivíduos. A seta contínua representa uma propriedade objeto e as setas tracejadas, propriedades de dados.

Figura 2.2: Principais conceitos da ontologia para diagnóstico de gripe

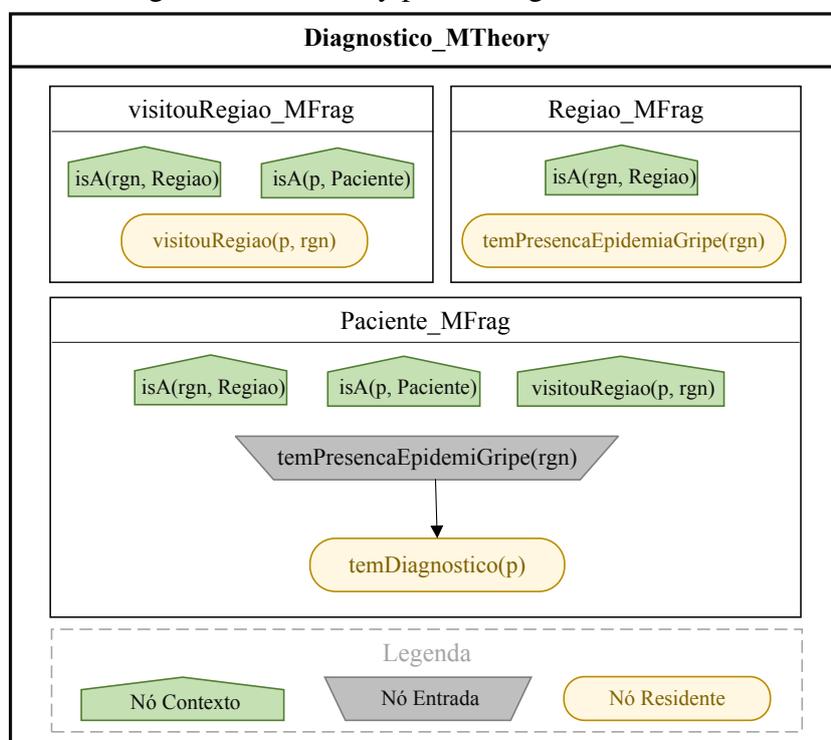


Fonte: Adaptado de Haberlin (2013).

²<http://protege.stanford.edu/>

A partir da ontologia apresentada anteriormente, é possível gerar uma MTheory para apoiar o diagnóstico médico sabendo-se que nenhum diagnóstico é 100% preciso (incerteza). Para tanto, foram gerados três MFrag, conforme mostra a Figura 2.3: Regiao_MFrag (captura o conhecimento sobre a presença de uma epidemia de gripe em uma região específica); visitouRegiao_MFrag (estabelece a relação entre um paciente e uma região específica visitada por ele); e Paciente_MFrag (descreve a relação entre o paciente e uma região que pode ou não estar com epidemia de gripe). Neste último, observa-se o nó contexto `visitouRegiao(p, rgn)` como restrição de relacionamento entre paciente e região, já tal relação não existe na ontologia original, propositalmente.

Figura 2.3: MTheory para o diagnóstico médico



Fonte: Adaptado de Haberlin (2013).

Já na Figura 2.4 está expressa, em linguagem MEBN *scripting*, a distribuição de probabilidade local para cada nó residente. Essa distribuição estabelece a probabilidade a priori de que uma região teve presença de epidemia de gripe em algum momento do tempo, sem qualquer evidência adicional. Vale mencionar que os valores de probabilidade podem ser obtidos utilizando uma combinação de pareceres de especialistas, aprendizagem a partir da observação ou, ainda, aprendizado de máquina. Observando os valores `true` e `false`, percebe-se que correspondem ao alcance das propriedades de dados `visitouRegiao` e `temPresencaEpidemiaGripe`. De outro

modo, `EpidemiaDeGripe` e `OutroVirus` (linhas 2-3; 5-6) são as instâncias da classe `Diagnostico`.

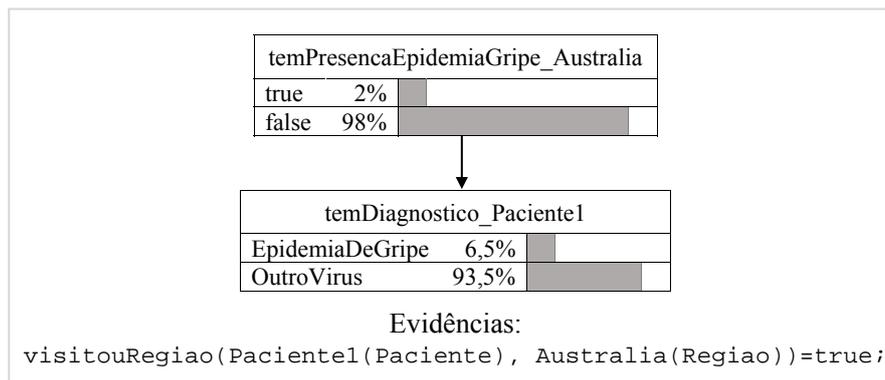
Figura 2.4: Distribuição Local de Probabilidade de cada nó residente

<code>visitouRegiao(p, rgn)</code>	<code>temPresencaEpidemiaGripe(rgn)</code>
[true = .33, false = .67]	[true = .02, false = .98]
<code>temDiagnostico(p)</code>	
<pre> 01. if any rgn have (temPresencaEpidemiaGripe = true)[02. EpidemiaDeGripe = .80, 03. OutroVirus = .20 04.] else [05. EpidemiaDeGripe = .05, 06. OutroVirus = .95 07.] </pre>	

Fonte: O autor.

Com isso, é possível realizar o processo de raciocínio e inferência, ou seja, a geração das SSBNs. A primeira etapa consiste na inserção de evidências, por exemplo, para saber o diagnóstico da instância `Paciente1`, é preciso indicar a(s) região(ões) onde ele esteve. Em seguida, indaga-se: Qual é a probabilidade do diagnóstico de `Paciente1` ser de epidemia de gripe? Esta pergunta traduz-se como o nó residente “`temDiagnostico(Paciente1)`” do MFrage `Paciente`. A Figura 2.5 mostra a SSBN resultante na qual é possível observar a probabilidade de `Paciente1` estar com gripe: 6,5%.

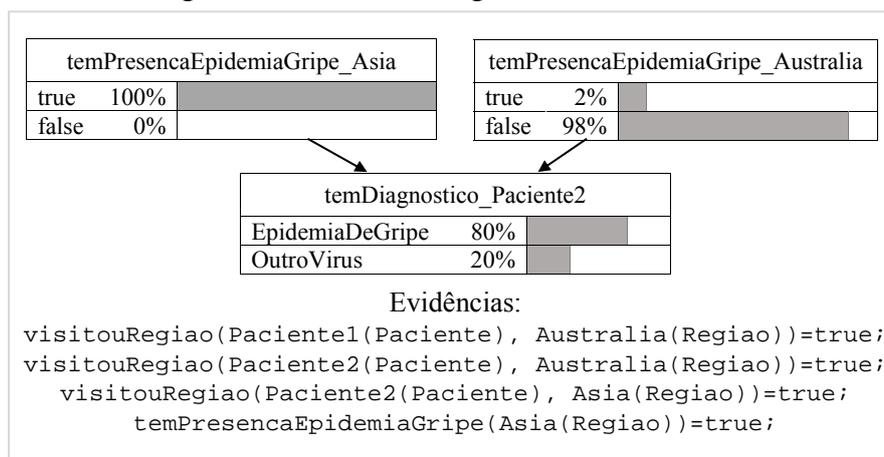
Figura 2.5: SSBN de diagnóstico do Paciente 1



Fonte: Adaptado de Haberlin (2013).

Para o diagnóstico de `Paciente2`, supõe-se que este tenha visitado Ásia e Austrália. Além disso, há presença de epidemia na Ásia, porém a Austrália segue com sua distribuição de probabilidade a priori. Como resultado, tem-se 80% de chance de `Paciente2` estar gripado, como pode ser visto na Figura 2.6.

Figura 2.6: SSBN de diagnóstico do Paciente 2



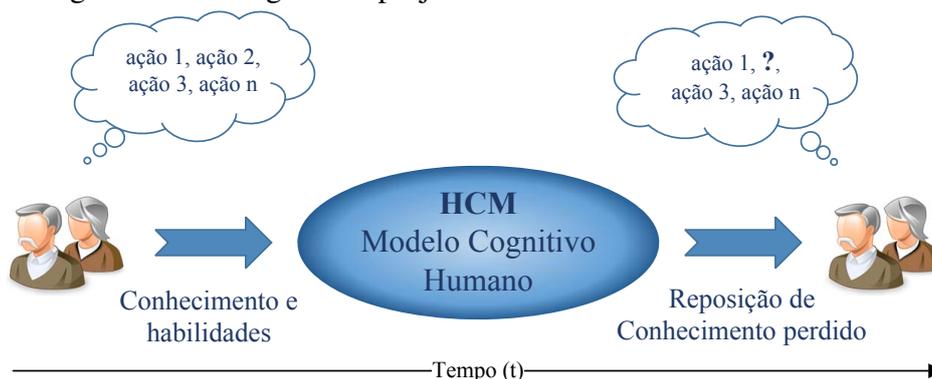
Fonte: Adaptado de Haberlin (2013).

2.3 Monitoramento e Suporte de Comportamento Humano

Monitoramento e Suporte de Comportamento Humano (*Human Behavior Monitoring and Support* - HBMS) é um projeto no domínio de AAL cujo propósito é auxiliar uma pessoa com declínio cognitivo a executar suas atividades diárias. Para tanto, é proposto o sistema HBMS o qual baseia-se em modelos conceituais de comportamento humano e em algoritmos de predição e inferência. Com isso, é inferido o apoio mais adequado ao indivíduo quando este apresentar perda de memória. O referido apoio é obtido a partir de um modelo integrado de habilidades e conhecimento autobiográfico, denominado Modelo Cognitivo Humano (*Human Cognitive Model* - HCM) (MAYR et al., 2016).

Em outras palavras, HCM é uma base de conhecimento que preserva a memória episódica de uma pessoa através da observação de seu comportamento. Isso é realizado por sistemas de reconhecimento de atividades, alimentados por sensores montados em uma casa inteligente. Quando o sistema HBMS está em modo de aprendizado, as observações são integradas ao HCM da pessoa. No modo de suporte, o sistema apoia o usuário, reavendo seu conhecimento da base HCM, de um caso base de observações concretas e de uma ontologia de domínio. A partir disso, então, o usuário é assistido de forma a executar as ações necessárias para atingir seu objetivo (MAYR et al., 2016). A Figura 2.7 ilustra o que fora explicado até aqui.

Figura 2.7: Ideia geral do projeto HBMS e seu conceito chave HCM



Fonte: Adaptado de Michael and Mayr (2013).

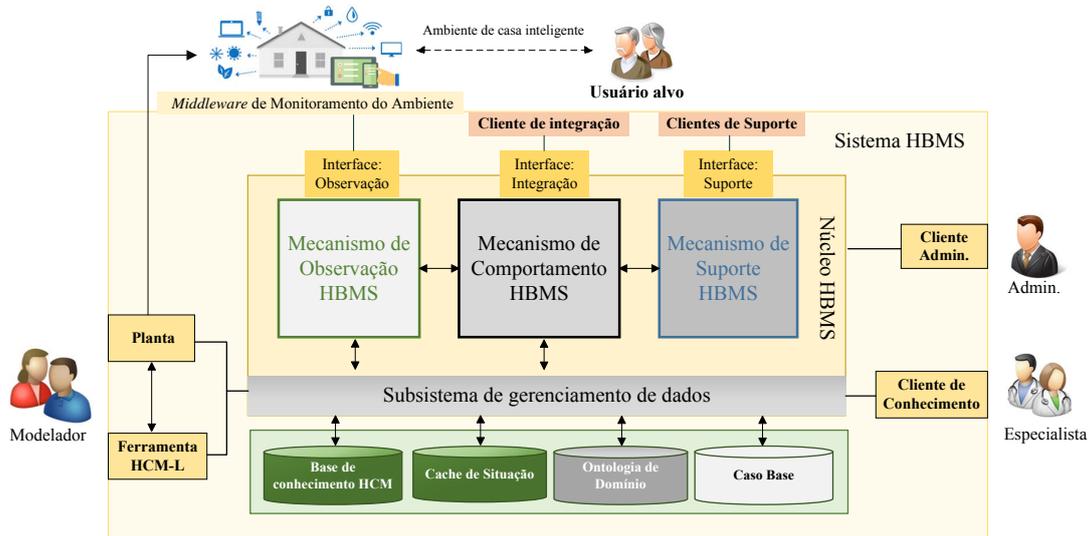
Segundo Michael and Mayr (2013), o projeto é dividido em três estágios e atualmente se encontra no segundo deles em que esta dissertação baseia-se. O primeiro estágio compreendeu: um estudo para verificar a aceitação e viabilidade do sistema HBMS com possíveis usuários finais (MICHAEL et al., 2013); o desenvolvimento de um método (linguagem e ferramenta) para a construção dos modelos conceituais de comportamento humano (MICHAEL; MAYR, 2013) (MICHAEL; MACHOT; MAYR, 2014) (MICHAEL; MAYR, 2015); testes de generalidade, controle de fluxo e aceitação do método de modelagem (MAYR; MICHAEL, 2012); e testes com usuários finais, que foram observados por um especialista enquanto executavam atividades do dia-a-dia em um ambiente de teste. A partir de anotações textuais do observador, foram construídos os modelos conceituais através da ferramenta de modelagem que foram posteriormente integrados ao HCM da pessoa observada.

O segundo estágio preocupa-se em: (i) automatizar a observação comportamental de um indivíduo por intermédio de sistemas que analisam e transformam dados de sensores em modelos conceituais que, então, são integrados ao HCM (Al Machot; MAYR, 2016); (ii) auxiliar o usuário sugerindo as próximas ações de uma atividade (MACHOT; MAYR; MICHAEL, 2014); e (iii) disponibilizar o auxílio ao usuário de forma multimodal, ou seja, na maior gama de dispositivos possíveis e adaptativa ao contexto. Já o terceiro e último estágio prevê a sensibilização total do sistema, detectando situações de esquecimento sem intervenção do usuário.

A Figura 2.8 apresenta uma visão arquitetural simplificada do sistema HBMS. De acordo com Mayr et al. (2016), um *Middleware* de Monitoramento do Ambiente monitora o comportamento do usuário utilizando sensores e metodologias para reconhecimento de atividade. Tais informações são entregues ao Mecanismo de Observação HBMS por meio

da Interface de Observação. Em seguida, o Mecanismo de Observação HBMS analisa, processa e transfere as situações de comportamento reconhecidas para o Mecanismo de Comportamento HBMS. No modo de aprendizado, esse mecanismo coleta as situações de comportamento para formar uma sequência, integrando-a ao HCM do usuário. Em caso de dúvidas no momento da integração, o usuário é envolvido no processo, através do cliente de integração. Já no modo de suporte, o Mecanismo de Comportamento HBMS recupera o conhecimento apropriado do HCM, utilizando mecanismos de raciocínio, e o transfere para o Mecanismo de Suporte HBMS, responsável pela assistência ao usuário de forma sensível ao contexto e através do cliente de suporte mais adequado (*smartphone*, *tablet*, TV, dentre outros).

Figura 2.8: Arquitetura geral do sistema HBMS



Fonte: Adaptado de Mayr et al. (2016).

Ainda, estão explícitos os quatro possíveis papéis que um usuário pode assumir:

- **Usuário alvo:** é a pessoa com potenciais problemas cognitivos residindo em uma casa inteligente;
- **Modelador:** é a pessoa responsável por descrever o comportamento de um usuário alvo, utilizando a ferramenta de modelagem HCM-L. Além disso, cria “plantas”, que correspondem a elementos de contexto com os quais o usuário alvo interage ao longo de seu comportamento. Vale mencionar que a descrição comportamental só é realizada manualmente caso o sistema não esteja no modo de aprendizado;
- **Administrador:** é a pessoa que, através do cliente *admin*, tem o poder de monitorar e visualizar o estado atual do sistema. De modo geral, todas as funções admi-

nistrativas como gerenciamento de usuários e configuração de clientes podem ser manipuladas neste papel;

- Especialista: é a pessoa que, fazendo uso do o cliente de conhecimento, obtém conhecimento de fontes externas integrando-o aos dados HBMS, por exemplo, conhecimento de domínio e conhecimento comportamental externo.

O subsistema de gerenciamento de dados controla as quatro bases de dados existentes, detalhadas conforme a seguir:

- Base de conhecimento HCM: contém o modelo cognitivo completo do usuário alvo, servindo como uma fonte para gerar elementos de cache de situação;
- Cache de situação: é a base de dados operacional do sistema, contendo fragmentos do HCM atualmente referenciados e em questão. Também armazena dados de estado coletados a partir de observações;
- Ontologia de domínio: é um modelo que representa o conhecimento específico de domínio que é referenciado às duas fontes de dados anteriores, HCM e cache de situação;
- Caso base: armazena todas as sequências de ações observadas. É explorada por algoritmos existentes no Mecanismo de Suporte HBMS para ponderar alternativas e, assim, determinar a próxima ação mais provável a ser recomendada ao usuário, de uma atividade.

2.3.1 Linguagem para a modelagem conceitual de comportamento humano

A Linguagem para a Modelagem de Comportamento Humano (*Human Behavior Modeling Language - HCM-L*³) é uma linguagem de modelagem que serve para descrever o conhecimento episódico de uma pessoa (eventos autobiográficos e informações contextuais) na forma de modelos conceituais. Tais modelos formam a principal fonte de conhecimento do sistema HBMS (MICHAEL, 2016).

A HCM-L é considerada uma linguagem de domínio específico (*Domain-Specific Modeling Language - DSML*), pois cobre requisitos que linguagens de propósito geral como BPMN e UML não cobrem, dentre os quais: (1) prover modelos que possam ser utilizados como base de conhecimento no sistema HBMS, (2) focar em comportamento

³As figuras com os conceitos da linguagem não foram traduzidas para o português afim de manter a consistência com sua proposta original.

humano e seu contexto, e (3) ser intuitivamente entendível pelas partes interessadas no domínio de AAL, por exemplo, parentes, cuidadores, ou médicos. O desenvolvimento da DSML foi guiado pela conceitualização de atividades humanas diárias da vida privada de uma pessoa: utilizar aparelhos eletrônicos, vestir-se, cozinhar, e assim por diante. Por esse motivo, a linguagem é fundada na teoria da atividade, proposta por Leontyev (1978), que descreve a natureza das atividades humanas em geral.

A Figura 2.9 apresenta todos os elementos HCM-L e suas relações semânticas por meio de um meta-modelo, desenvolvido a partir de várias iterações utilizando um diagrama de classes da UML. O principal conceito por trás da linguagem é a Unidade Comportamental (*Behavioral Unit* - BU), responsável por encapsular as sequências de ações que uma pessoa (*Person*) realiza, na intenção de atingir o objetivo (*Goal*) de uma atividade diária. Cada ação é mapeada para o conceito Operação (*Operation*) e conectadas por fluxos direcionados (*Flows*). Com isso, é possível representar a direção do processo comportamental de um indivíduo que, na maioria das vezes, não é linear dada a natureza das atividades humanas. Nesses casos, então, ramificações e junções ocorrem no processo, dando origem a sequências alternativas de operações.

Por conta disso, existem dois conceitos que controlam o fluxo de operações, implementados como atributos de *Operation*, denominados Pré-Condição (*Pre-Condition*) e Pós-Condição (*Post-Condition*). O primeiro define uma restrição a ser cumprida antes que uma operação possa ser executada. Já o segundo estabelece qual será a próxima operação a ser executada. As restrições correspondem a valores de atributos dos elementos contextuais, de tempo (*Time Space*), de operações anteriormente executadas ou da combinação destes. Tecnicamente, são estruturadas como expressões lógicas, na forma de texto e sob a notação prefixada, não sendo representadas nos modelos HCM-L para preservar a baixa complexidade visual. Somente o tipo da fórmula é exibido, como operador lógico, para explicar as possíveis ramificações e junções: AND, OR, XOR e SOR. Os três primeiros possuem o significado usual, porém, SOR (*OR* sincronizado) significa que, para a próxima operação ser executada, é necessário o aguardo de todos os fluxos predecessores.

Ainda por conta das sequências alternativas, uma BU pode possuir mais de uma operação de início (*PossibleBeginning*) e mais de uma operação de fim (*SuccessfulEnding*) cuja implementação se dá através de atributos do relacionamento de agregação entre *Operation* e BU. O atributo *GoalDistance* representa a menor sequência de operações rumo ao objetivo da BU. Ainda, uma BU pode se comportar como uma *Operation* em função do relacionamento de generalização existente entre elas. Isto, portanto, permite

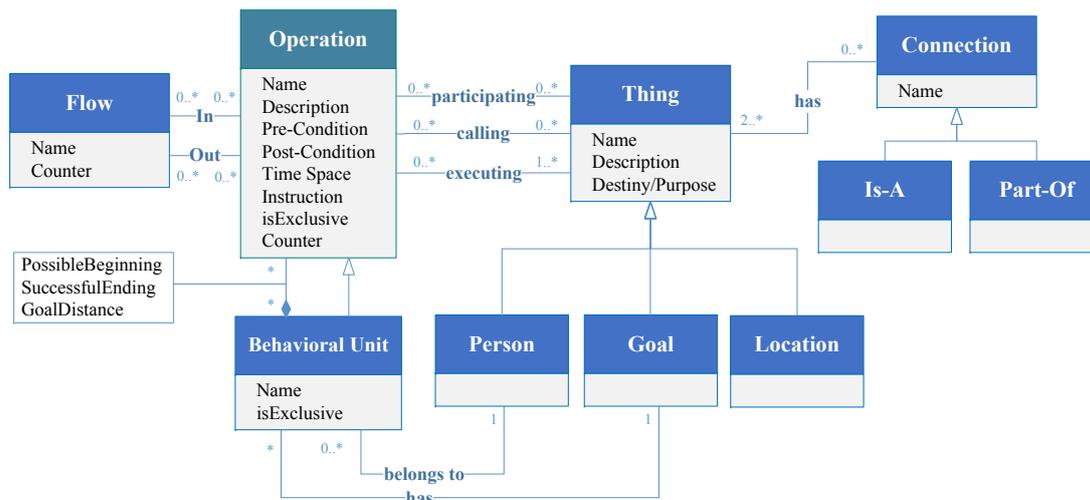
modelar atividades hierarquicamente, cobrindo um dos princípios estabelecidos nas teorias de Leontyev (1978).

Para situações em que uma *Operation* ou uma BU não deve ser interrompida por outra, há o atributo *isExclusive*; *Counter* armazena a quantidade de vezes que uma *Operation* foi executada; *Time Space* especifica o período de tempo que uma *Operation* ocorre. Ainda, uma *Operation* pode diferir em pequenos detalhes de outra, por exemplo, as operações “pegar uma xícara de chá” e “pegar uma xícara de café” diferem apenas pelo tipo de xícara envolvido. Por esse motivo, definiu-se o conceito *Instruction*, como um atributo de *Operation*, a partir do qual ocorrem adições, modificações e remoções de relacionamentos entre a operação e os elementos de contexto.

A modelagem de contexto é endereçada pelos conceitos *Connection* e *Thing*. *Thing* descreve objetos concretos ou abstratos, recursos e pessoas, os quais possuem um propósito (atributo *Desntiny/Purpose*). Uma pessoa (*Person*) é representada por várias informações sobre seu estado psicológico e físico, modeladas como atributos e/ou partes desta. *Location* serve para a descrição de salas, quartos e demais espaços, facilitando a aquisição de dados (temperatura, umidade, som, etc.). Cada *Operation* se relaciona com algum objeto de *Thing* através de três associações: *Calling*, objetos que iniciam operações; *Participating*, objetos que contribuem ou são manipulados por operações; e *Executing*, objetos que executam operações. O conceito *Connection* modela associações entre dois objetos *Thing*, especializando-se em: objeto relacionamento parte-todo *Part-Of* e objeto relacionamento especialização/especialização *Is-A*. Portanto, HCM-L é suficientemente poderosa para a representação de contexto, conforme as quatro dimensões contextuais definidas por Kofod-Petersen and Mikalsen (2005):

- pessoal: características mentais e físicas de uma pessoa;
- ambiental: objetos como mobília e aparelhos domésticos;
- social: pessoas relacionadas como parentes, cuidadores e médicos;
- espaço-temporal: localização, tempo ou frequência e duração das atividades.

Figura 2.9: Meta-modelo HCM-L



Fonte: Adaptado de Mayr et al. (2016).

Os conceitos e suas representações gráficas foram cuidadosamente escolhidos para serem intuitivamente entendidos por usuários do sistema, como já mencionado anteriormente. Tal escolha foi guiada por pesquisas como a de Moody (2009) que se preocupa com a concepção de notações visuais simplificadas e efetivas. Recentemente, a intuitividade dos modelos HCM-L foi comprovada, de acordo com Michael and Mayr (2017), através de testes com pessoas não especialistas em informática. A Figura 2.10 apresenta a notação gráfica de cada conceito HCM-L, com especial atenção ao elemento *Operation* que é bipartido para a representação de restrições (*Pre e Post-Conditions*). Ainda, é possível deduzir, facilmente, a correspondência com o meta-modelo da Figura 2.9.

Figura 2.10: Notação HCM-L

Elementos Básicos	Coisa	Conexões	Hierarquia

Fonte: Adaptado de Mayr et al. (2016).

Em relação à semântica HCM-L, uma análise foi realizada, com base em padrões de *workflow*, demonstrando que a linguagem é suficientemente poderosa para a modelagem de atividades diárias de uma pessoa em AAL, inclusive mais do que linguagens de propósito geral (MAYR; MICHAEL, 2012).

Para fins de compreensão do uso da HCM-L, um exemplo prático é apresentado a seguir. A Figura 2.11 corresponde ao modelo de comportamento usual de Maria, uma pessoa fictícia, ao se preparar para fazer compras. Sendo assim, inicialmente, Maria pega a bolsa (*PossibleBeginning*) e vai até o *hall* de entrada onde decide entre pegar a jaqueta e/ou o guarda-chuva, dependendo das condições climáticas; pega o *smartphone*, desde que as operações predecessoras tenham sido concluídas; veste os sapatos, como uma sub atividade que possui suas próprias operações (*Behavioral Unit* atuando como *Operation*); pega as chaves; abre a porta e desliga a luz caso esteja ligada; e fecha a porta (*SuccessfulEnding*) atingindo, assim, o objetivo “se preparar para fazer compras”.

Constata-se, ainda, a utilização das *Pre-Conditions* e das *Post-Conditions* para o controle de fluxo. Por exemplo, após a operação “ir até o *hall* de entrada”, o usuário pode: (1) pegar somente a jaqueta se o clima estiver frio e ensolarado; (2) pegar somente o guarda-chuva se o clima estiver chuvoso e quente/ameno; (3) pegar a jaqueta e o guarda-chuva se o clima estiver chuvoso e frio; e (4) pegar apenas o *smartphone* se o clima estiver nem chuvoso nem frio. Portanto, a *Post-Condition* que melhor implementa esta situação é implementada pela seguinte expressão:

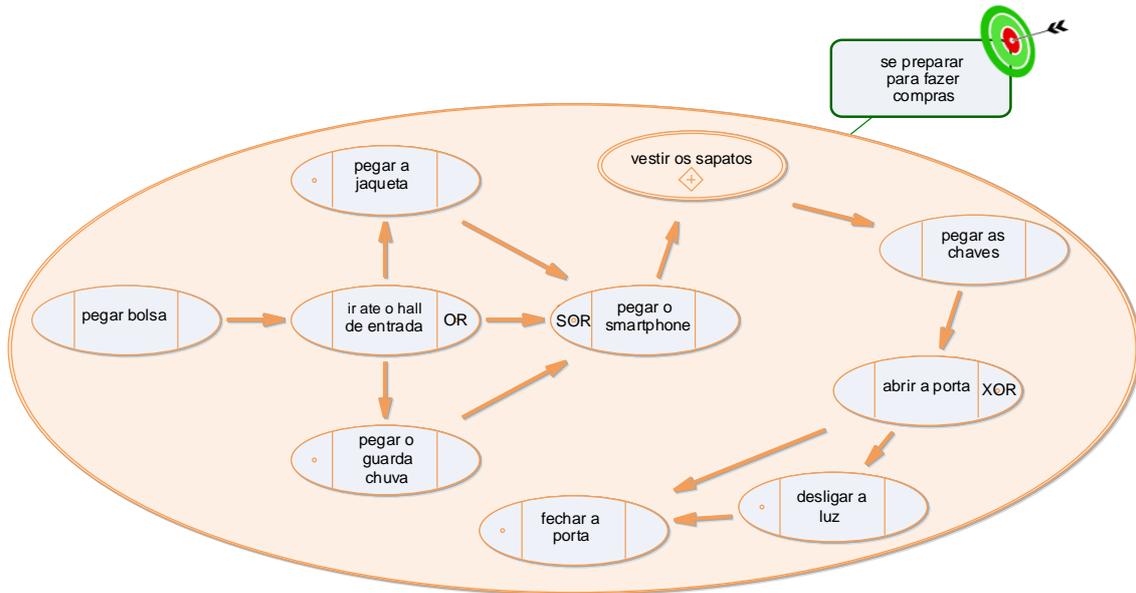
```
OR ( : pegar_o_smartphone ,
      [: Clima . temperatura < 15]: pegar_a_jaqueta ,
      [: Clima . umidade > 60]: pegar_o_guarda_chuva
    );
```

Um exemplo de *Pre-Condition* é percebido na operação “pegar o *smartphone*” que só pode ser executada se todas as suas predecessoras já ocorreram, sua expressão é:

```
SOR [ waitfor=ALL]
    ( : pegar_o_smartphone ,
      [: Clima . temperatura < 15] : pegar_a_jaqueta ,
      [: Clima . umidade > 60] : pegar_o_guarda_chuva
    );
```

Essas expressões são escritas em uma linguagem própria para a definição de restrições que ainda se encontra em desenvolvimento e, por isso, foge do escopo deste trabalho.

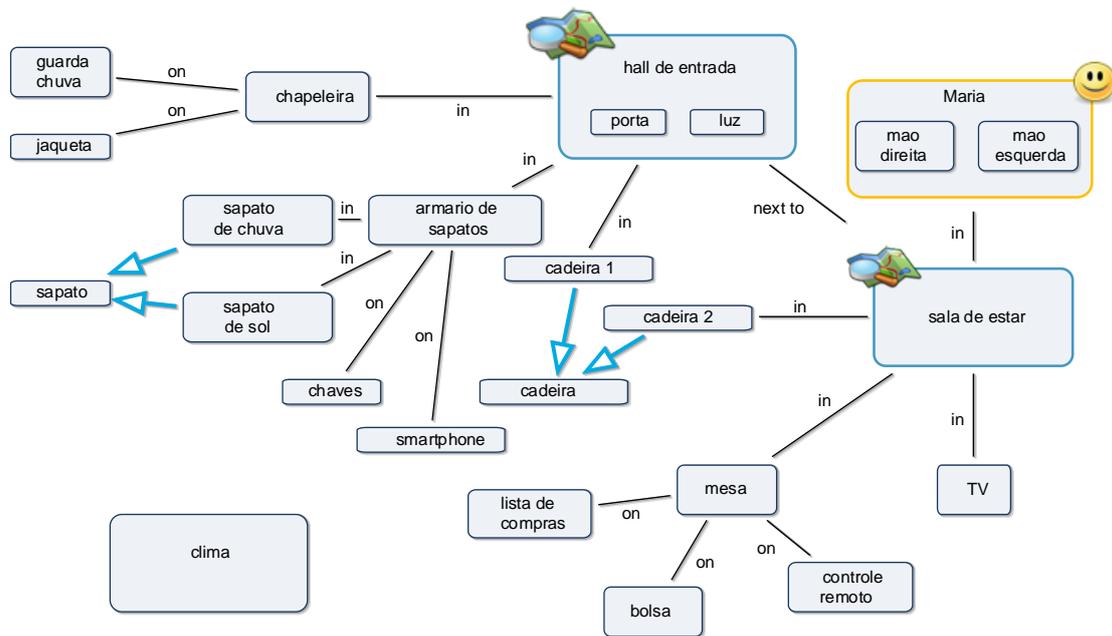
Figura 2.11: Behavioral Unit se preparar para fazer compras



Fonte: Adaptado de Mayr et al. (2016).

A Figura 2.12 ilustra o modelo do contexto que circunda a atividade “se preparar para fazer compras”. Cada elemento contextual possui algum tipo de relacionamento com os elementos da atividade, por exemplo, a operação “pegar a jaqueta” envolve: a chapeleira, a jaqueta em si, o usuário Maria e o Clima. Além disso, o contexto é manipulado conforme o andar do processo através de expressões definidas em *Instruction*, por exemplo, *add(:smartphone,with,:Maria)* faz com que o *smartphone* deixe de estar sobre o armário de sapatos e passe a estar com Maria. De outra forma, cada elemento de contexto possui uma disposição inicial em relação a outros elementos, por exemplo, a chapeleira está no *hall* de entrada, o *smartphone* está sobre o armário de sapatos, etc. Os elementos podem ser compostos por outros, é o caso do *hall* de entrada o qual possui uma porta e uma luz (*Part-Of*) ou, então, podem ser especializados como cadeira 1 e cadeira 2 que herdam as características de cadeira (*Is-A*).

Figura 2.12: Modelo de contexto



Fonte: Adaptado de Mayr et al. (2016).

2.3.2 Ferramenta HCM-L Modeler

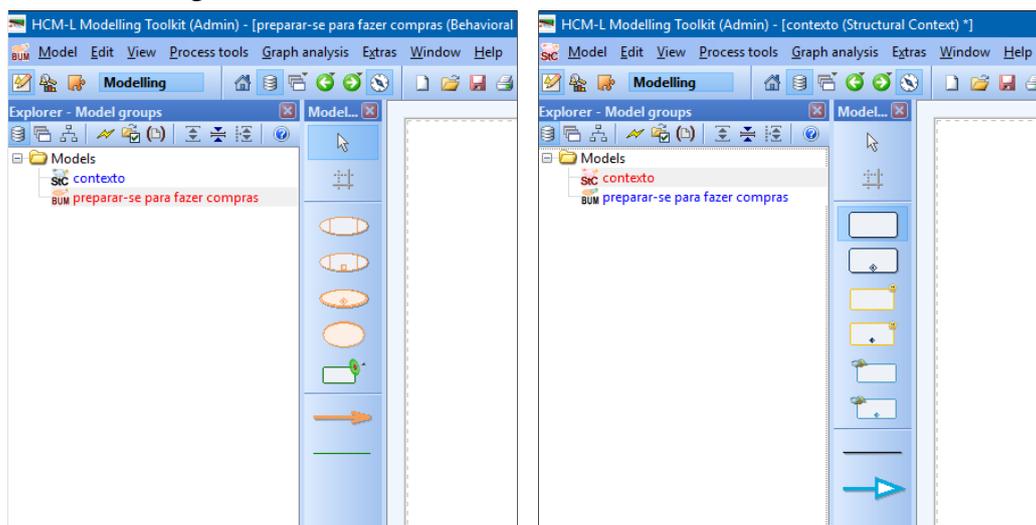
A ferramenta HCM-L Modeler⁴ é uma ferramenta de modelagem para HCM-L baseada em uma plataforma de meta modelagem denominada ADOxx^{®5}. Esta plataforma facilita a construção de ferramentas de modelagem de domínio específico, pois permite o desenvolvimento da sintaxe, da semântica e da notação gráfica com base em diferentes funcionalidades pré-definidas, por exemplo: arrastar e soltar, formas e cores, dentre várias outras comumente encontradas em ferramentas de modelagem.

A ferramenta HCM-L Modeler é também o meio pelo qual é possível visualizar e analisar os modelos HCM-L gerados automaticamente pelo reconhecimento de atividades e pelo mecanismo de observação HBMS, detalhados na seção 2.3. Além disso, a ferramenta permite a inserção de conhecimento manualmente (externo) na base de conhecimento HCM. A Figura 2.13 apresenta duas instâncias da ferramenta. À esquerda tem-se a modelagem de comportamento (*Behavioral Unit Model* - BUM) e, à direita, tem-se a modelagem de contexto (*Structural Context* - StC). Destaca-se, ainda, os elementos notacionais de cada instância além da área de desenho à direita.

⁴disponível para download em: <http://www.openmodels.at/web/hcm-l/download>

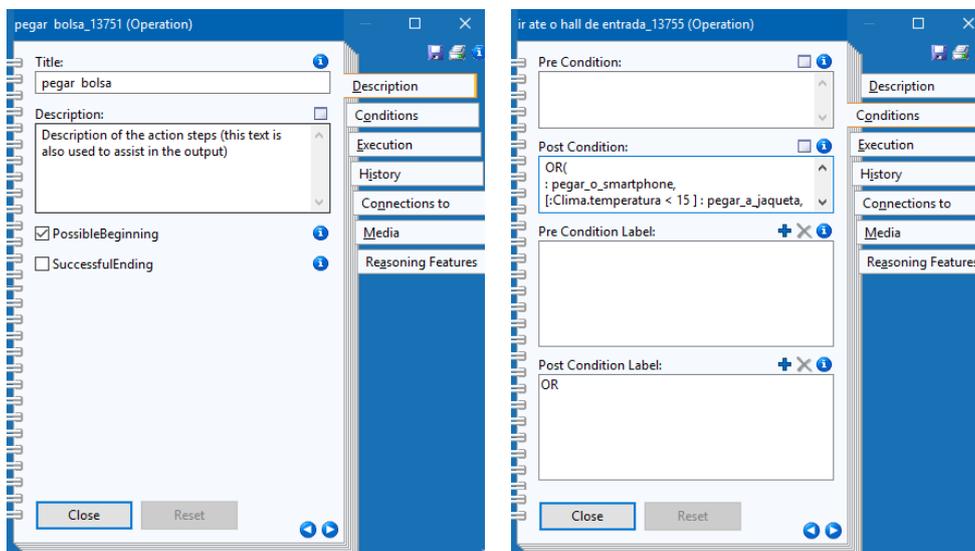
⁵disponível para download em: <http://www.adoxx.org>

Figura 2.13: Visão inicial da ferramenta HCM-L Modeler



Fonte: O autor.

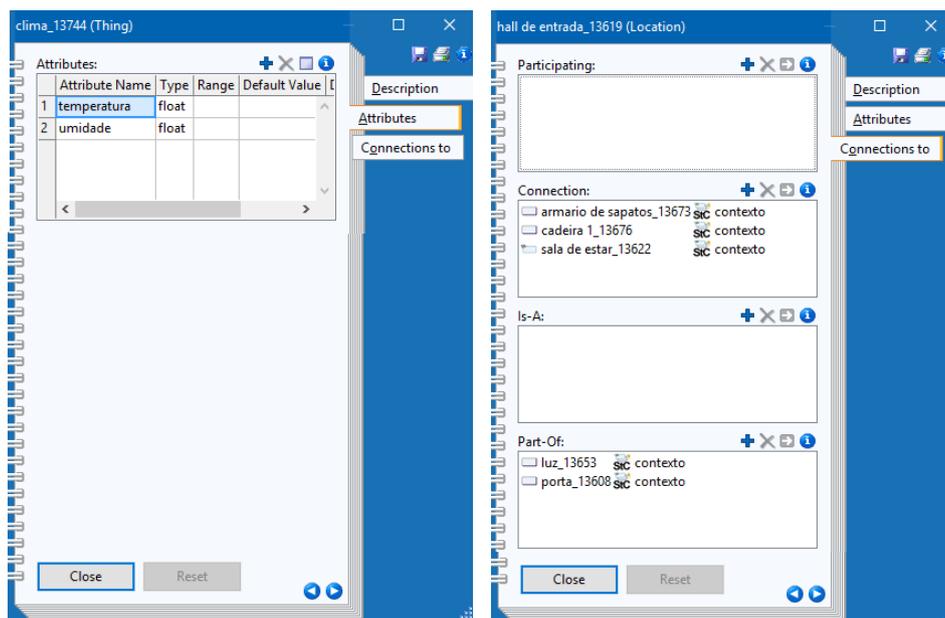
Um dos principais recursos herdados da plataforma ADOxx[®] é o *Notebook*. É através dele que os atributos de cada elemento HCM-L (*possibleBeginning*, *successfulEnding*, *Pre-Condition*, etc.) são configurados. A Figura 2.14 apresenta tal recurso, para os elementos HCM-L de comportamento, o qual organiza-se em sete abas: Descrição (*Description*), Condições (*Conditions*), Execução (*Execution*), Histórico (*History*), Conexões (*Connections*), Mídia (*Media*) e Raciocínio (*Reasoning Features*). À esquerda é possível observar as propriedades da *Operation* “pegar a bolsa” e, à direita, a implementação da *Post-Condition* da *Operation* “ir até o hall de entrada”.

Figura 2.14: ADOxx[®] Notebooks de comportamento

Fonte: O autor.

Por outro lado, a Figura 2.15 exemplifica o *Notebook* para elementos contextuais e, por este motivo, sua organização é ligeiramente diferente do anterior, estruturando-se em: Descrição (*Description*), Atributos (*Attributes*) e Conexões (*Connections*). À esquerda observa-se a definição das duas propriedades (temperatura e umidade) do elemento “clima” (*Thing*). À direita, é possível observar as conexões (relacionamentos) estabelecidas com o elemento “hall de entrada” (*Location*) e, também, suas partes (luz e porta).

Figura 2.15: ADOxx[®] *Notebooks* de contexto



Fonte: O autor.

De forma sumarizada e, de acordo com Michael, Al Machot and Mayr (2015), as principais funcionalidades e características da ferramenta HCM-L *Modeler* estão listadas a seguir. Maiores detalhes podem ser encontrados no referido trabalho.

- Verificador de modelos: anima a sucessão de operações do modelo em questão e possibilita passar por toda a BU com base nas decisões do usuário. Basicamente, esta funcionalidade destaca a operação visitada, colorindo-a. Assim, um usuário pode validar o modelo antes de colocá-lo em operação;
- Referência autônoma: auxilia os usuários, de forma implícita, a criar modelos consistentes e livres de redundância. Um exemplo disto é modelar um objeto (*Thing*) como parte de outro (*Part-Of*) cuja relação é implicitamente criada;
- Consulta: através de uma linguagem de consulta, no estilo SQL (*Structured Query Language*) e denominada AQL (*ADOxx Query Language*), é possível consultar qualquer instância HCM-L. A título de exemplo, a consulta a seguir retorna todas as

BU cujo período de ocorrência está entre seis e onze horas da manhã. (*<"Behavioral Unit»["atTime»= "00:000:06:00:00"] AND (<"Behavioral Unit»["atTime»= "00:000:11:00:00"];*

- Importar/exportar modelos: exporta os modelos para um formato XML (*eXtensible Markup Language*) genérico. A partir dele, então, é possível transformar os modelos para outros formatos como, por exemplo, OWL e usado em mecanismos de inferência e raciocínio;
- Arquivos de mídia: possibilita a inserção de arquivos de mídia (vídeo, áudio, imagens) dentro da ferramenta os quais são utilizados na fase de suporte para auxiliar a visualização de situações complexas por usuários alvo.

2.4 Trabalhos Relacionados

Não são muitos os trabalhos que consideram a predição de ações humanas e modelagem conceitual de comportamento em conjunto. Vários deles se preocupam com a primeira característica, porém baseando-se somente em abordagens direcionadas a dados, estatísticas. Por outro lado, há trabalhos que endereçam a segunda característica, através de ontologias OWL, mas apenas para apoiar sistemas de reconhecimento de atividades em *smart homes*.

Nesse sentido, Minor, Doppa and Cook (2015) abordam o problema de prever a ocorrência de atividades futuras a partir de dados de sensores. Tais dados pertencem ao projeto CASAS (*Center for Advanced Studies in Adaptive Systems*) que fornece *datasets* à comunidade científica com dados coletados de *smart homes* reais. Trata-se, portanto, de uma abordagem preditiva e que condiz com o escopo deste trabalho, todavia puramente baseada em *Data Mining*, sem considerar qualquer aspecto de modelagem conceitual.

Trabalhos como o de Hawkins et al. (2013) investigam o uso de modelos gráficos probabilísticos para a predição de ações humanas em uma tarefa. O resultado da predição é entregue à um robô que auxilia o usuário na tarefa. A predição é baseada em algoritmos que aprendem com os dados coletados de sensores (ações da pessoa na tarefa) e, embora sejam mencionados modelos gráficos, não há nenhuma relação com modelagem conceitual da tarefa discutida no trabalho.

Segue, na mesma linha, o trabalho de Del Fabro Neto et al. (2016). Os autores apresentam um modelo para predição de situações de risco, baseado em ações humanas

as quais compõem uma dada atividade diária. O modelo é capaz de inferir a probabilidade de execução da próxima ação através da análise de dados do comportamento usual do usuário. Tal análise, porém, baseia-se somente em técnicas de *Data Mining* assim como o trabalho anterior.

Chen, Nugent and Okeyo (2014), em contrapartida, consideram a modelagem conceitual de atividades diárias, baseada em ontologias OWL. Essa abordagem, todavia, apenas auxilia métodos direcionados à dados para reconhecimento de atividades diárias. Além disso, esse trabalho não considera aspectos de predição. Ainda, esse trabalho destaca o bem conhecido problema de *cold start*, ou seja, é preciso uma quantidade de dados expressiva para representar um modelo de atividade diária.

O trabalho de Helaoui, Riboni and Stuckenschmidt (2013), assim como o anterior, também utiliza modelagem conceitual baseada em ontologias OWL, mas para apoiar o reconhecimento de atividades complexas. Por exemplo, a atividade “preparar a máquina de lavar louça” pode pertencer a outra atividade mais complexa “limpar a cozinha”, além de ser composta por ações mais simples (“abrir a máquina de lavar”, “colocar pratos”, etc.). Para tanto, um *framework* probabilístico infere progressivamente atividades mais complexas a partir de níveis mais baixos (ações, subatividades, etc). Isso porque atividades são hierarquicamente incertas (podem ser executadas de diferentes maneiras; o mesmo evento de sensor pode indicar a execução de múltiplas e incompletas atividades).

Ceballos, Flores-Solorio and Garcia (2015) usa BPMN para modelar o *workflow* de atividades diárias, e redes Bayesianas para predizer e assistir usuários. Embora esta abordagem pareça muito correlata a este trabalho, é utilizada uma linguagem de propósito comum e, portanto, complicada para não especialistas em informática. Além disso, a predição é baseada na conversão direta de um modelo BPMN para uma rede Bayesiana sem a utilização de um modelo para isso, situação que pode trazer inconsistências no processo de inferência.

O trabalho de Machot, Mayr and Michael (2014) é o que mais se aproxima desta pesquisa, principalmente por fazer parte do projeto HBMS. Os autores utilizam uma abordagem para raciocínio baseada em programação declarativa - ASP (*Answer Set Programming*) afim de prover assistência ao usuário. Essa abordagem é limitada no sentido de representar incerteza, entretanto, serviu como ponto de partida deste trabalho.

Desconsiderando o domínio de AAL, há vários esforços na literatura que utilizam amplamente ontologias probabilísticas para problemas de predição. Por exemplo, Hlel, Jamoussi and Hamadou (2015) buscam prever novos interesses de autores com um

método próprio para a construção de ontologias probabilísticas, modelando uma lista de publicações da base de dados DBLP. Para tanto, foi utilizada uma rede Bayesiana para medir as dependências entre as diferentes instâncias da ontologia. Já o trabalho de Carvalho et al. (2013) utiliza uma ontologia probabilística (PR-OWL) para a detecção de fraudes em licitações federais no Brasil. Laskey et al. (2011) buscam prever, a partir de uma ontologia probabilística para o domínio militar marítimo, se um navio é suspeito de ser terrorista.

Contudo, fica evidente a não preocupação em unir abordagens direcionadas a reconhecimento e a dados no que se refere à modelagem de comportamento e à predição de ações humanas, juntas. Sendo assim, fica evidenciado o potencial deste trabalho, que busca uma solução que englobe as duas áreas em um sistema de assistência pessoal para a facilitação de atividades diárias.

2.5 Considerações Finais

Neste capítulo foi apresentado o aporte necessário para a compreensão dos próximos capítulos. Através dos trabalhos relacionados, é possível perceber grandes esforços no que se refere às ADLs, especialmente algoritmos para o reconhecimento delas. Entretanto, pouco é discutido sobre as menores unidades destas atividades, as ações (operações em HCM-L). A partir daí, pesquisas maduras como a de (MACHADO, 2015) em predição de situações com ontologias probabilísticas e a desenvolvida no projeto HBMS com modelagem de atividades, foram unidas de forma a possibilitar o raciocínio probabilístico sobre os modelos conceituais de comportamento humano.

Portanto, o próximo capítulo apresenta a definição da abordagem, metodologias utilizadas, arquitetura da solução bem como um protótipo de interface para interação com o usuário alvo.

3 ABORDAGEM PARA A PREDIÇÃO DE AÇÕES HUMANAS

Este capítulo descreve o desenvolvimento da abordagem que visa dotar os sistemas de facilitação de atividades diárias (ADLs) com a capacidade de agir antecipadamente ao surgimento de declínios cognitivos, relacionados às ações das atividades diárias de uma pessoa. Nesse sentido, é concebido um meta-modelo semântico, a partir do qual são instanciados modelos conceituais de comportamento e de contexto para formar uma base de conhecimento, utilizada para derivar informações de suporte.

Entretanto, tais modelos, por serem baseados em ontologias OWL-DL, carecem de estruturas que incorporem tratamento de incerteza, as quais possibilitariam raciocínios mais acurados. Por isso, é desenvolvido um modelo semântico probabilístico, com o qual é possível prever a próxima ação mais provável que leve à contínua condução do fluxo de uma dada ADL. Ademais, é proposta uma arquitetura que exemplifica o emprego da abordagem em um sistema utilizável.

3.1 Meta-Modelo Semântico

O meta-modelo semântico corresponde a uma ontologia genérica, implementada em OWL-DL, para a geração dos modelos conceituais de comportamento e de contexto. Como esta ontologia é baseada no diagrama de classe da UML, que descreve o meta-modelo da linguagem HCM-L, foi adotada uma metodologia, proposta por El Hajjamy et al. (2016), para a conversão de diagramas de classe UML para ontologias OWL 2. Assim, foi possível garantir a equivalência semântica entre meta-modelos. Ademais, a escolha de ontologias é justificada, principalmente, pelo poder de inferência, primordial para a derivação das informações de suporte definidas neste trabalho. A seguir é detalhada a metodologia de conversão, com especial atenção aos elementos UML presentes no meta-modelo da linguagem HCM-L.

3.1.1 Metodologia Utilizada

Existem três principais diferenças entre diagramas de classe UML e ontologias OWL: (i) nomes globais: em UML cada elemento possui um nome exclusivo dentro de seu pacote, garantindo que cada um é identificado pelo nome e posição na hierarquia do

pacote. Já em OWL, todos os nomes são globais, necessitando atribuir, a cada elemento do modelo, um nome globalmente exclusivo; (ii) suposição de nome único: em UML dois elementos com nomes distintos são tratados como diferentes, o que não ocorre em OWL, sendo necessário marcar explicitamente os elementos como sendo diferentes (axioma `differentFrom`); e (iii) suposição de mundo fechado/aberto: em UML todas as declarações que não forem mencionadas explicitamente são falsas (mundo fechado). Em contrapartida, em OWL, a mesma situação é tratada como inconclusiva (mundo aberto), necessitando de restrições para preservar a semântica original (ZEDLITZ; JÖRKE; LUTTENBERGER, 2012).

Em razão dessas diferenças, a conversão de um diagrama de classes UML para uma ontologia OWL não é trivial, ou seja, não há uma equivalência direta de conceitos. Portanto, é necessário seguir regras que sustentem tal equivalência, correspondendo à utilização de axiomas OWL 2, descritos na metodologia de El Hajjamy et al. (2016), e apresentados a seguir.

- Classes: são facilmente transformadas, pois o conceito existe em ambas linguagens, por exemplo: `Declaration(Class(:A))`;
- Generalização/especialização: a transformação é direta pelo axioma `SubClassOf`, por exemplo: `SubClassOf(:B:A)` e `SubClassOf(:C:A)`. São possíveis, ainda, as seguintes restrições:
 - disjunta incompleta: as classes específicas não possuem instâncias comuns, e não representam todos os tipos possíveis da especialização.
`DisjointClasses(:B:C)`
 - disjunta completa: as classes específicas não possuem instâncias comuns, representando todos os tipos possíveis da especialização.
`DisjointUnion(:A:B:C)`
- Associação: uma associação direcionada é transformada em uma propriedade objeto. Para uma associação bidirecional, são criadas duas propriedades objeto, uma para cada direção. Para preservar ambas as propriedades objeto como sendo parte da mesma associação, é utilizado o axioma `InverseObjectProperty`;
- Cardinalidade: a tabela 3.1 apresenta os axiomas OWL 2 que implementam cada uma das cardinalidades UML.

Tabela 3.1: Implementação de cardinalidades UML versus OWL 2

Cardinalidade em UML	Cardinalidade em OWL 2
0..1	ObjectMaxCardinality(1)
1..1	ObjectExactCardinality(1)
0..n	não se aplica
1..n	ObjectMinCardinality(1)

Fonte: Adaptado de El Hajjamy et al. (2016).

- Atributos: de forma geral, são mapeados para propriedades de dados, com domínio (*Domain*) e alcance (*Range*) definidos, para tipos primitivos de dados;
- Composição: uma propriedade objeto considerando as seguintes restrições: a associação de composição é antissimétrica (*AsymmetricObjectProperty*), ir-reflexiva (*IrreflexiveObjectProperty*) e não pode fazer parte de mais de uma composição (*InverseFunctionalObjectProperty*).

3.1.2 Implementação

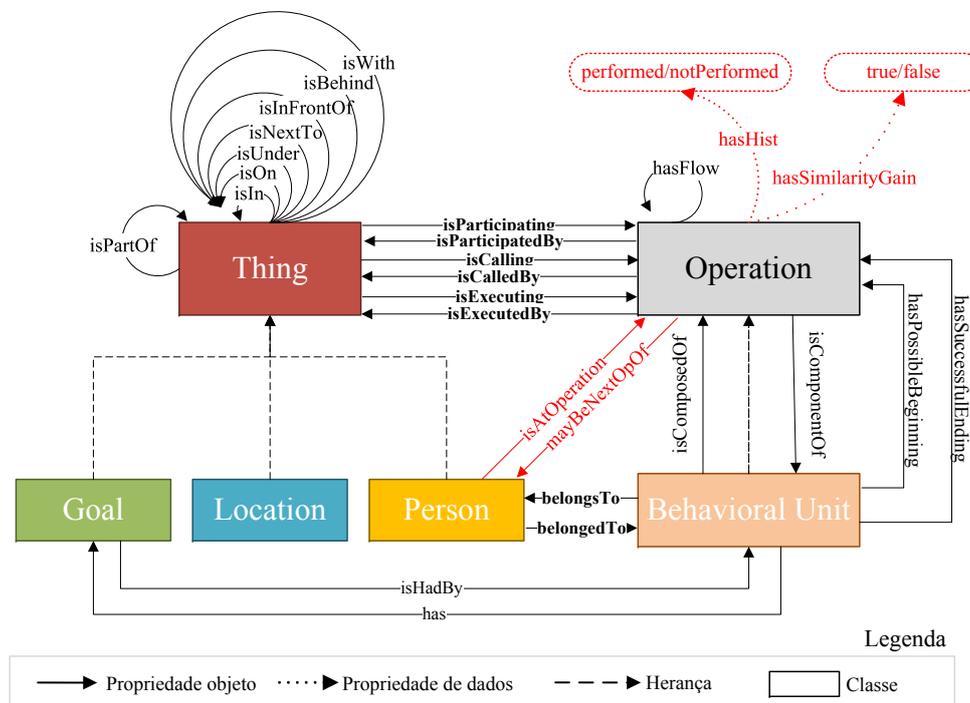
A partir da metodologia descrita anteriormente, e com o apoio do *software Protégé*, obteve-se o meta-modelo semântico que corresponde a uma ontologia genérica da qual são instanciados os modelos de comportamento e de contexto. A Figura 3.1¹ apresenta a representação gráfica dessa ontologia, cuja semântica é equivalente à da linguagem HCM-L, descrita em detalhes no capítulo anterior.

À primeira vista, é possível notar a correspondência, através das cores das classes, com a notação da linguagem HCM-L. Os relacionamentos entre *Thing* (elementos de contexto) e *Operation* (ação) deram lugar a três pares de propriedades-objeto inversas: (*IsParticipating*, *IsParticipatedBy*); (*isCalling*, *isCalledBy*); e (*isExecuting*, *isExecutedBy*). Já entre *Behavioral Unit* (Unidade Comportamental) e *Person* (Pessoa) há o par (*belongsTo*, *belongedTo*) e entre *Behavioral Unit* e *Goal* (Objetivo), o par (*has*, *isHadBy*). O relacionamento de composição entre *Behavioral Unit* e *Operation* foi convertido para o par (*isComposedOf*, *isComponentOf*), acrescido dos axiomas que o tornam uma composição. Os atributos desta, *hasPossibleBeginning* (indica operações de possível início) e *hasSuccessEnding* (indica operações de fim bem sucedido), foram convertidos em duas propriedades-objeto de mesmo nome. As especializações de *Thing* e de *Operation*, foram

¹a nomenclatura dos conceitos foi mantida em língua inglesa para manter a consistência com os modelos apresentados no capítulo anterior, seção 2.3.

implementadas como disjuntas completas.

Figura 3.1: Meta-modelo semântico baseado em HCM-L



Fonte: O autor.

Além das conversões guiadas, apresentadas anteriormente, algumas simplificações foram realizadas afim de viabilizar a geração dos modelos de comportamento via editores de ontologia, tal como o *software Protégé*. A primeira delas diz respeito à classe UML *Flow*, que foi transformada para a propriedade-objeto *hasFlow*, com domínio e alcance sendo *Operation*. Outra simplificação está relacionada às classes UML *Connection* e sua especialização *Part-Of*, as quais foram representadas por suas instâncias, na ontologia, como as seguintes propriedades-objeto: *isIn*, *isOn*, *isUnder*, *isNextTo*, *isInFrontOf*, *isBehind*, *isWith* e *isPartOf*, respectivamente. Essas propriedades permitem relacionar os elementos de contexto como, por exemplo, a bolsa *isOn* (está sobre) a mesa. Ainda, a propriedade *isPartOf* é definida como transitiva para que seja possível descrever elementos de contexto compostos por outros, por exemplo, a porta *isPartOf* (é parte de) da cozinha.

Os atributos de cada classe UML foram convertidos para propriedades de dados, porém foram suprimidas da Figura 3.1 para manter sua legibilidade. As duas propriedades de dados, *hasHist* e *hasSimilarityGain*, e as duas propriedades-objeto, *isAtOperation* e *maybeNextOperationOf*, compõem a parte probabilística do meta-modelo, servindo para fins de predição e inferência. Portanto, serão detalhadas na próxima seção.

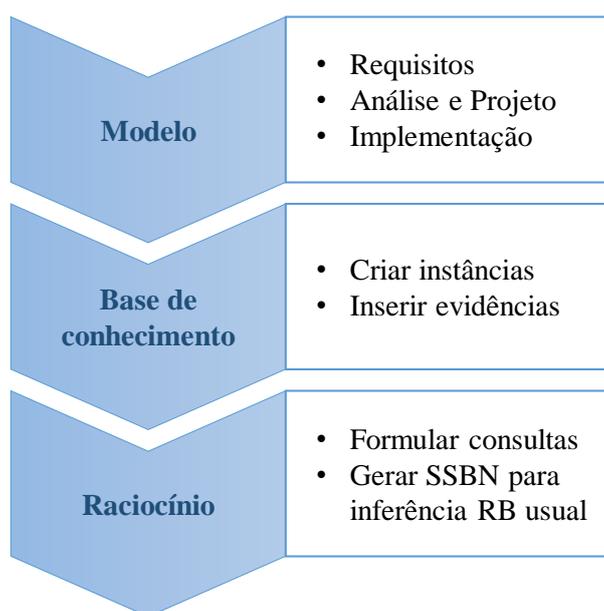
3.2 Modelo Semântico Probabilístico

O modelo semântico probabilístico se refere à ontologia probabilística, implementada em PR-OWL, composta pelos elementos, em vermelho, da Figura 3.1. Esses elementos foram evidenciados através de várias iterações sobre a metodologia de Carvalho (2011), a qual define etapas e boas práticas para a concepção de ontologias PR-OWL.

3.2.1 Metodologia Utilizada

A concepção de ontologias probabilísticas é guiada por um processo denominado Processo de Modelagem de Incerteza para a Web Semântica (*Uncertainty Modeling Process for Semantic Web - UMP-SW*), dividido em três fases inter-dependentes: modelagem, população da base de conhecimento e raciocínio. A fase de modelagem é, geralmente, um processo iterativo que inclui: listar requisitos, identificar objetivos, definir domínio e escopo e implementar a ontologia. Já a fase de população da base de conhecimento compreende criar indivíduos e evidências e, por fim, a fase de raciocínio visa submeter consultas e inferir probabilidades, através de inferência sobre redes Bayesianas (RB) convencionais. A Figura 3.2 apresenta essas fases, bem como as tarefas associadas a cada uma (CARVALHO, 2011).

Figura 3.2: Etapas para a construção de uma ontologia probabilística

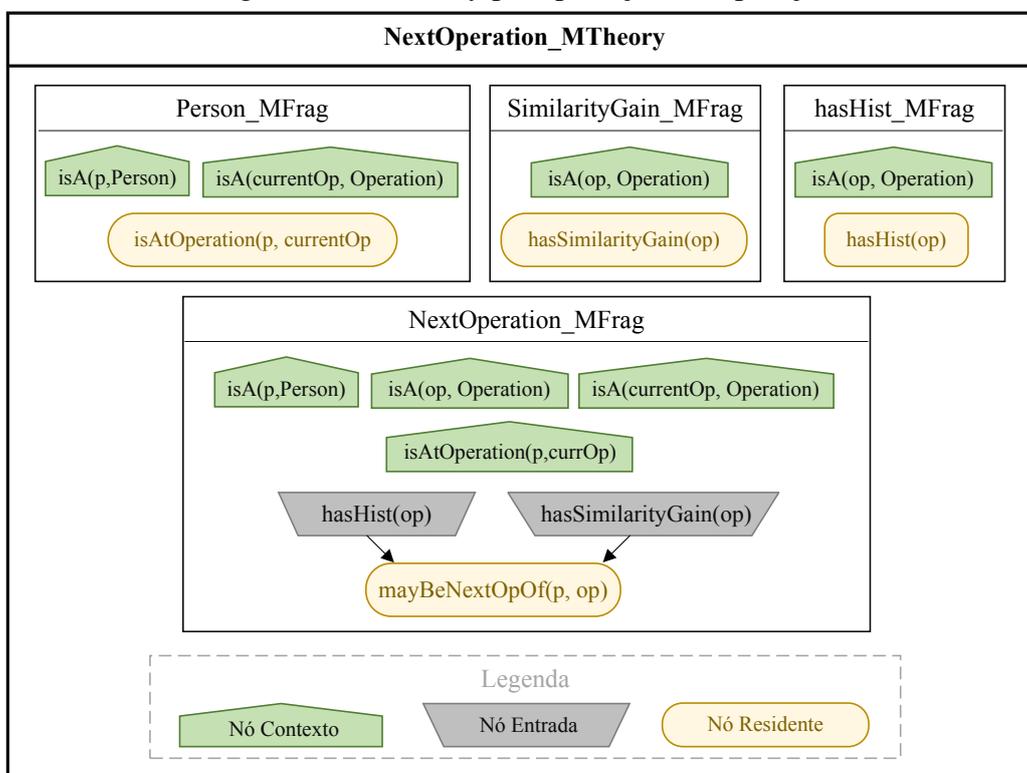


Fonte: Adaptado de Carvalho (2011).

3.2.2 Implementação

Com base na metodologia exposta, e com o apoio do *software* UNBBayes, obteve-se a ontologia probabilística, cujo objetivo é responder a seguinte pergunta (consulta): Qual é a probabilidade do usuário executar uma dada operação? A resposta é provida pela MTheory² da Figura 3.3, mais especificamente por intermédio do nó residente *maybeNextOperationOf(p, op)* que, em bom português, quer dizer: “poderá ser próxima operação de”. Este nome foi escolhido para fazer menção ao nível de incerteza associado na relação entre *Person* e *Operation*.

Figura 3.3: MTheory para predição de Operações



Fonte: O autor.

A MTheory é uma estrutura repetível (*template*) da qual SSBNs são geradas, de acordo com o comportamento do usuário. Em outras palavras, as SSBNs são geradas de acordo com as relações semânticas que estão vinculadas a instância de *Person* e de *Operation* do meta-modelo semântico. Dessa forma, em tempo de execução, quando existir a necessidade de gerar uma SSBN para fazer a predição de uma próxima operação, ou seja, quando uma situação de declínio cognitivo for detectada, a estrutura da rede é ge-

²a nomenclatura dos conceitos foi mantida em língua inglesa para manter a consistência com o meta-modelo semântico.

rada dinamicamente de acordo com a MTheory. Esta é composta pelos quatro fragmentos descritos abaixo, cujas variáveis aleatórias relacionadas aos nós contexto são: “p” para *Person*, “currentOp” (operação atual) e “op” (operação futura) para *Operation*. Os nós residentes serão apresentados como: <nome do nó residente> = {estados}.

- *Person_MFrag*: apresenta a probabilidade de o usuário estar parado em uma dada “currentOp”, dentro da atividade. Tal fato é representado pelo nó residente $isAtOperation(p, currentOp) = \{True, False\}$;
- *SimilarityGain_MFrag*: representa a probabilidade de “op” ser executada de forma similar por diferentes usuários. Em outras palavras, é uma medida de similaridade probabilística baseada na distribuição Gaussiana, cujos parâmetros são calculados usando o número de vezes que se escolhe uma operação específica por todos os usuários que realizaram a mesma atividade. O nó residente responsável é o seguinte: $hasSimilarityGain(op) = \{True, False\}$;
- *hasHist_MFrag*: representa a probabilidade de “op” ser executada com base no histórico de execução do usuário. Pode ser entendida, também, como a importância histórica, representada pelo nó residente $hasHist(op) = \{performed, notPerformed\}$;
- *NextOperation_MFrag*: representa a probabilidade de uma próxima “op” ser recomendada ao usuário através do nó residente $mayBeNextOperationOf(p, op) = \{True, False\}$. A distribuição de probabilidade desse nó é diretamente influenciada pelos dois MFraqs anteriores, funcionando como medidas de prioridade.

Outrossim, para que seja possível gerar a estrutura das SSBNs dinamicamente, de acordo com a MTheory, cada nó residente de um MFrag deve implementar, ainda, sua própria distribuição local de probabilidade, cujos valores podem ser informados por um especialista no domínio ou podem ser gerados através de algoritmos de aprendizado. Nessa perspectiva, se optou por descrever cada distribuição no Capítulo 4, no qual o modelo acima é aplicado em um cenário.

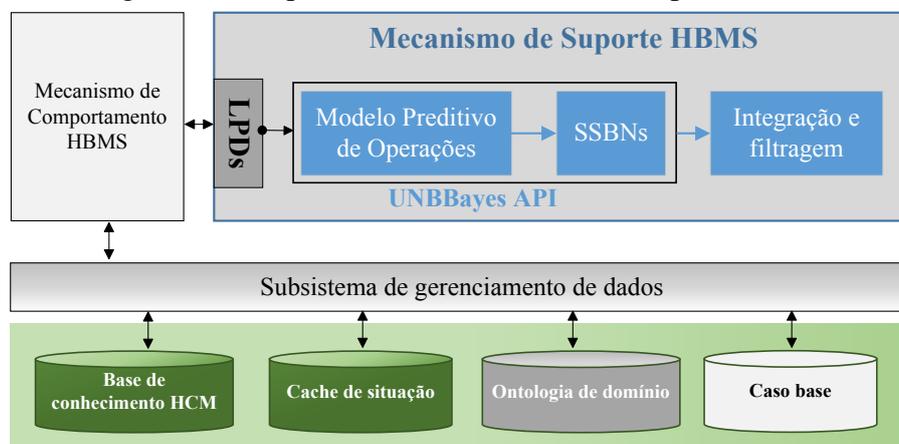
3.3 Arquitetura da Solução

Esta seção apresenta uma visão arquitetural de como o mecanismo de predição e inferência poderia ser implementado dentro de um sistema de assistência pessoal. Nesse sentido, é detalhado o Mecanismo de Suporte HBMS, através da Figura 3.4, responsável por derivar as informações de suporte, conforme explicado no Capítulo 2.

O modelo Preditivo de Operações corresponde ao modelo semântico probabilístico, implementado em PR-OWL, através da ferramenta de modelagem UNBBayes. Esse modelo é alimentado por LPDs, cujos valores de probabilidade podem ser derivados por algoritmos de aprendizado de máquina, existentes no Mecanismo de Comportamento HBMS. Esses algoritmos são sustentados por dados provenientes da base de dados Caso Base, que contém todas as sequências históricas de ações realizadas pelo usuário. De outro modo, as LPDs também podem ser fornecidas por um especialista, caso nenhuma aprendizagem automatizada tenha sido realizada.

Na sequência, as instâncias do modelo de comportamento corrente (por exemplo, reproduzir um DVD) são recuperadas da base de conhecimento HCM, pelo Mecanismo de Comportamento HBMS, e contrastadas com uma ontologia de domínio. Em seguida, essas instâncias substituem os marcadores do modelo semântico probabilístico gerando, assim, as SSBNs, nas quais um algoritmo usual de inferência sobre redes Bayesianas é aplicado. As SSBNs são geradas para cada próxima operação possível em relação àquela que o usuário parou. Por isso, um módulo de integração mescla as SSBNs, selecionando a operação com a maior probabilidade de ser recomendada ao usuário.

Figura 3.4: Arquitetura do Mecanismo de Suporte HBMS



Fonte: O autor.

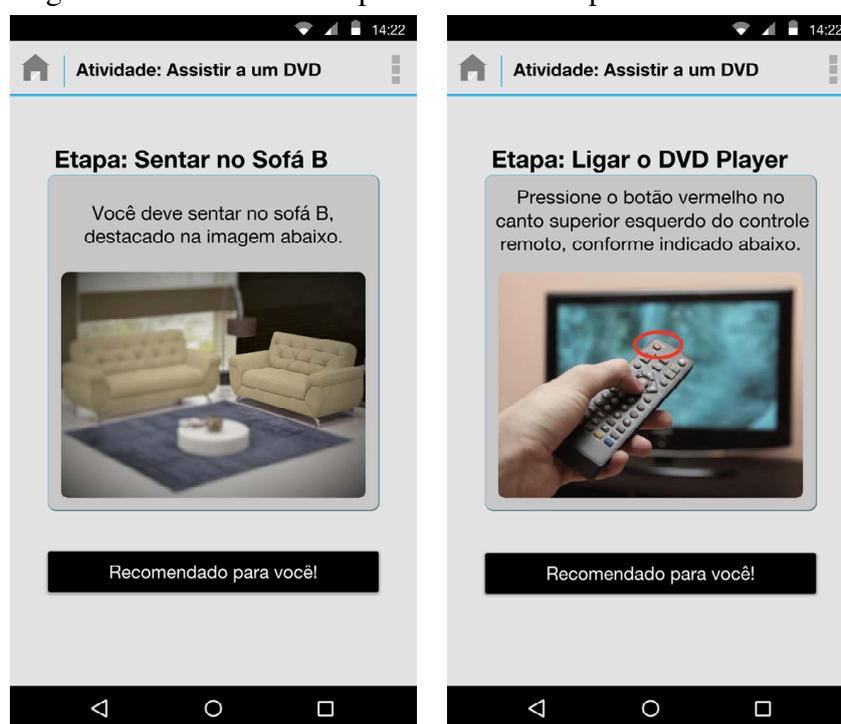
3.4 Interface de Interação com o Usuário

O resultado do processo de predição e inferência, no caso a recomendação de operações, precisa ser entregue ao usuário através de algum dispositivo (*smartphone*, *tablet*, TV, som). Este, por sua vez, deve ser selecionado, automaticamente, de acordo com as limitações (físicas e/ou cognitivas) e localização da pessoa. Embora abordar o suporte

multi dispositivo esteja fora do escopo deste trabalho, foi desenvolvido um protótipo de interface, para dispositivos com sistema Android, na intenção de demonstrar como seria a interação com o usuário alvo.

Nesse sentido, a Figura 3.5 apresenta duas telas que demonstram o auxílio na atividade de assistir a um DVD. A tela da esquerda indica ao usuário qual sofá fornece melhor ângulo de visão e de audição em relação à TV. Em seguida, na tela da direita, o usuário é instruído como proceder o acionamento do aparelho de DVD. Esse exemplo pertence ao estudo de caso deste trabalho, detalhado no próximo capítulo.

Figura 3.5: Interface de suporte baseada em plataforma Android.



Fonte: O autor.

3.5 Considerações Finais

Neste capítulo foi apresentada a abordagem para dotar os sistemas de facilitação de ADLs com a capacidade de lidar com a incerteza podendo, assim, realizar predições mais confiáveis para a recomendação de ações. Portanto, a abordagem é composta: (i) pelo meta-modelo semântico com o qual é possível instanciar modelos de comportamento para utilizá-los como base de conhecimento; (ii) pelo modelo semântico probabilístico que permite raciocinar sobre incerteza para realizar predições mais acuradas; (iii) pela arquitetura que agrupa os dois primeiros elementos em um sistema utilizável.

4 ESTUDO DE CASO

Neste capítulo é desenvolvido um estudo de caso que visa validar a abordagem proposta no capítulo anterior. De acordo com Yin (2013), um estudo de caso caracteriza-se como uma investigação empírica e holística de um fenômeno contemporâneo dentro de seu contexto da vida real. Sendo assim, o estudo de caso é conduzido a partir de um cenário no qual demonstra-se a dificuldade enfrentada por uma pessoa, acometida por declínio cognitivo, ao executar uma atividade simples do cotidiano. Com isso, é evidenciado como a predição de ações pode apoiar os afazeres diários da pessoa, melhorando, assim, sua qualidade de vida no ambiente de vivência. Em seguida, é apresentada a aplicação da abordagem na qual evidencia-se a modelagem do cenário, o raciocínio sobre esta (predição) e, por conseguinte, o auxílio à pessoa.

4.1 Cenário de Utilização

A abordagem proposta pode ser utilizada em vários cenários de atividades diárias dentro de uma casa inteligente. Como exemplo foi escolhida uma atividade específica para validação do modelo preditivo de operações. Sendo assim, João é um idoso que sofre de deficiências cognitivas leves, mais especificamente de um estágio inicial de Alzheimer. Além disso, ele sofre com perdas auditivas e visuais, moderadas.

João vive sozinho em uma casa inteligente (equipada com o sistema HBMS), que consiste em uma cozinha, uma sala de estar, uma sala de jantar, um quarto e um banheiro. Neste ambiente, à tarde, João costuma assistir a um filme usando o DVD *player*. Para isso, ele entra na sala de estar e decide em qual sofá irá sentar, no sofá A ou no sofá B. Entretanto, nem sempre João se recorda qual o sofá fornece melhor distância e ângulo para visão e para audição, respectivamente, sentando ora no sofá A, ora no sofá B. Ao detectar esta situação, o sistema HBMS entra em ação recomendando à João a melhor opção, com base em seu próprio conhecimento. Após encontrar o sofá mais adequado, João ativa o DVD e finalmente a TV. A atividade é encerrada quando a TV é desligada.

O ambiente descrito no cenário corresponde ao laboratório real do projeto HBMS, representado na Figura 4.1¹. Nele, a atividade descrita no cenário foi executada por um ator que simulou possuir declínios cognitivos leves, tal como o do personagem João. Assim, dados reais foram coletados através de sensores que rastreiam, basicamente, as

¹é uma representação fiel do ambiente real, localizado na universidade Alpen-Adria, Klagenfurt, Áustria.

ações das atividades, por exemplo, sensores de presença, e de toque (interruptores, portas e chão). Esses dados foram utilizados para estimar as probabilidades do modelo preditivo (MTheory) que avalia a possibilidade de execução de uma próxima operação, conforme será detalhado mais adiante. Além disso, serviram para avaliar a abordagem.

Figura 4.1: laboratório HBMS



Fonte: O autor.

Embora existam conjuntos de dados (*datasets*) internacionais na área de AAL, tal como CASAS², esses não se adaptam aos requisitos do sistema aqui proposto, devido a: (i) falta de dados que ofereçam escolhas (entre operações) para treinar o modelo preditivo de operações; e (ii) preocupação demasiada em prover dados para testar algoritmos de reconhecimento de atividades.

Portanto, para cobrir as fragilidades citadas foi utilizado o *dataset* HBMS, cujo conteúdo é estruturado em forma de matriz. Nesta, as colunas representam 15 sensores, instalados nos seguintes objetos: geladeira, fogão, micro-ondas, armário A, armário B, mesa da cozinha, chão da cozinha, chão da sala de estar, sofá A, sofá B, TV, DVD *player*, cadeira A, cadeira B e sala de jantar (vide Figura 4.1). Cada linha representa uma execução de uma dada atividade, composta pela quantidade de ativações (ativado/não ativado) de cada sensor. Ao todo, o *dataset* contém 60 amostras, divididas entre 10 execuções de 6 atividades diferentes: (1) preparar uma bebida, (2) preparar uma refeição, (3) preparar café da manhã, (4) assistir TV, (5) assistir um DVD e (6) Relaxar.

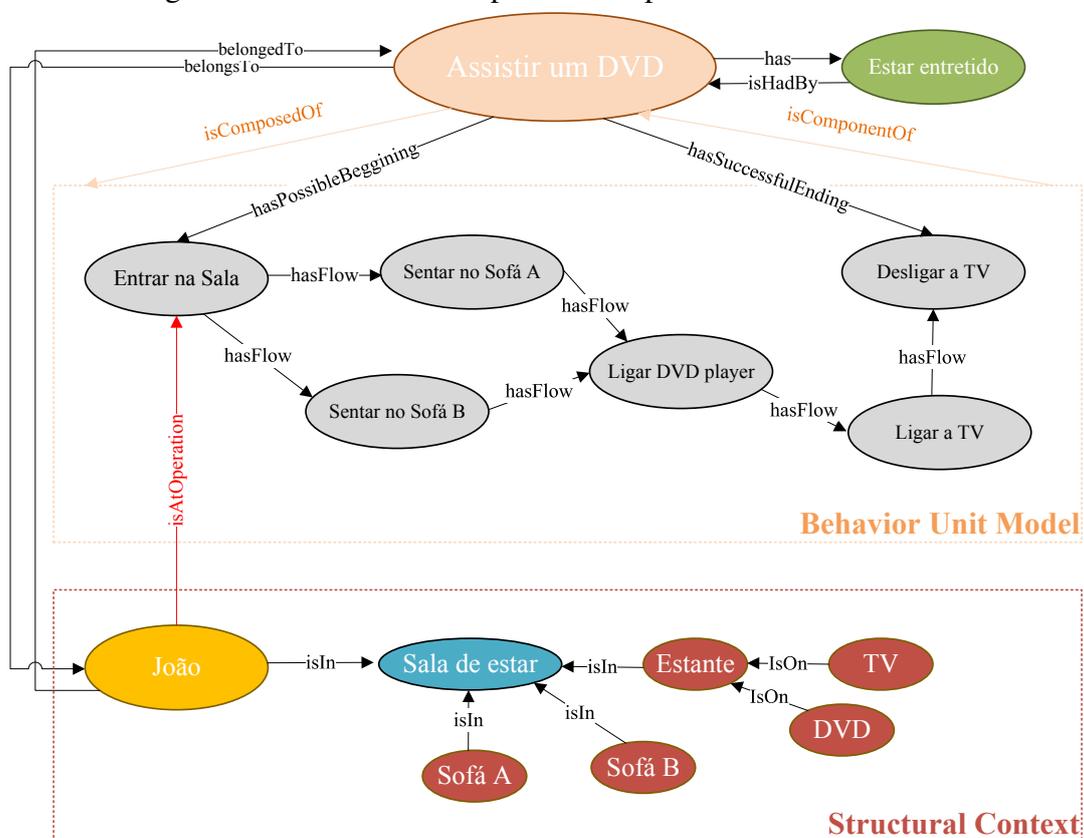
²<http://ailab.eecs.wsu.edu/casas/datasets.html>

Como é possível perceber, 6 cenários seriam possíveis de representar. Entretanto, após uma análise preliminar do *dataset*, verificou-se que somente a atividade (5) possuía um conjunto representativo de dados, mesmo sendo apenas 10 execuções. Frente à isso, a atividade (5) foi a escolhida para aplicação da abordagem, apresentada a seguir.

4.2 Aplicação da Abordagem

A partir da descrição do cenário e do *dataset*, na seção anterior, foi possível derivar o modelo de comportamento para a atividade (5): “Assistir um DVD”. A Figura 4.2 mostra a representação gráfica do modelo, que corresponde à instanciação dos conceitos, conforme cores, definidos no meta-modelo semântico desenvolvido no capítulo anterior. *Behavior Unit Model* se refere ao modelo de comportamento, isoladamente, o qual está diretamente relacionado ao modelo de contexto (*Structural Context*). Os relacionamentos de cada *Operation* com os elementos de contexto foram suprimidos da figura, além das deficiências de João, para fins de legibilidade.

Figura 4.2: Modelo de comportamento para “Assistir um DVD”



Fonte: O autor.

O processo de apoio ao usuário é iniciado após a detecção de seus declínios cognitivos frente às operações da atividade, especialmente as que envolvem escolhas. Essa detecção é realizada pelo Mecanismo de Comportamento HBMS (ver Figura 3.4), que compara a janela de tempo gasta quando a operação é executada normalmente com o tempo atual dispendido. No cenário da Figura 4.2, João está há um certo tempo parado na operação “Entrar na Sala”, o que leva a crer que houve um declínio cognitivo neste ponto. Com isso, as LPDs são informadas para o modelo semântico probabilístico que gera as SSBNs para cada próxima operação possível, “Sentar no Sofá A” e “Sentar no Sofá B”, conforme apresentadas na Figura 4.3, para estimar a chance de recomendar uma ou outra a João. Os valores de cada uma das LPDs foram obtidos a partir do *dataset* HBMS.

Figura 4.3: Distribuições Locais de Probabilidade (LPDs) de cada *Operation*

Sentar no Sofá A		Sentar no Sofá B	
hasHist(op)	hasSimilarityGain(op)	hasHist(op)	hasSimilarityGain(op)
performed=.33, notPerformed=.67	true=.65, false=.35	performed=.67, notPerformed=.33	true=.808, false=.192
mayBeNextOpOf(p, op)		mayBeNextOpOf(p, op)	
<pre> 01. if any op have (hasHist = performed)[02. if any op have (hasSimilarityGain = true) 03. [true =.51, false =.49] 04. else 05. [true =.34, false =.66] 06.] else [07. if any op have (hasSimilarityGain = true) 08. [true =.34, false =.66] 09. else 10. [true =.49, false =.51] 11.] </pre>	<pre> 01. if any op have (hasHist = performed)[02. if any op have (hasSimilarityGain = true) 03. [true =.739, false =.261] 04. else 05. [true =.431, false =.569] 06.] else [07. if any op have (hasSimilarityGain = true) 08. [true =.431, false =.569] 09. else 10. [true =.261, false =.739] 11.] </pre>		

Fonte: O autor.

Os valores da Figura 4.3 são explicados utilizando as LPDs da operação “Sentar no Sofá B”, sendo a mesma lógica aplicável à operação “Sentar no Sofá A”. Assim, a LPD para o nó residente *hasHist(sentarNoSofaB)* significa que a operação foi realizada 67% das vezes (*performed*) e não realizada 33% das vezes (*notPerformed*). Por outro lado, a LPD para o nó residente *hasSimilarityGain(sentarNoSofaB)* significa que a operação foi similarmente realizada (*True*) em 80,8% dos casos e não similarmente realizada (*False*) em 19,2% dos casos (supondo que João viva com uma pessoa que compartilha a realização de algumas atividades). Por fim, a LPD para o nó residente *mayBeNextOpOf(Joao, sentarNoSofaB)* descreve como os valores de *hasHist(sentarNoSofaB)* e *hasSimilarityGain(sentarNoSofaB)* influenciam a inferência das probabilidades para a recomendação da operação “Sentar no Sofá B”. Dessa forma, se:

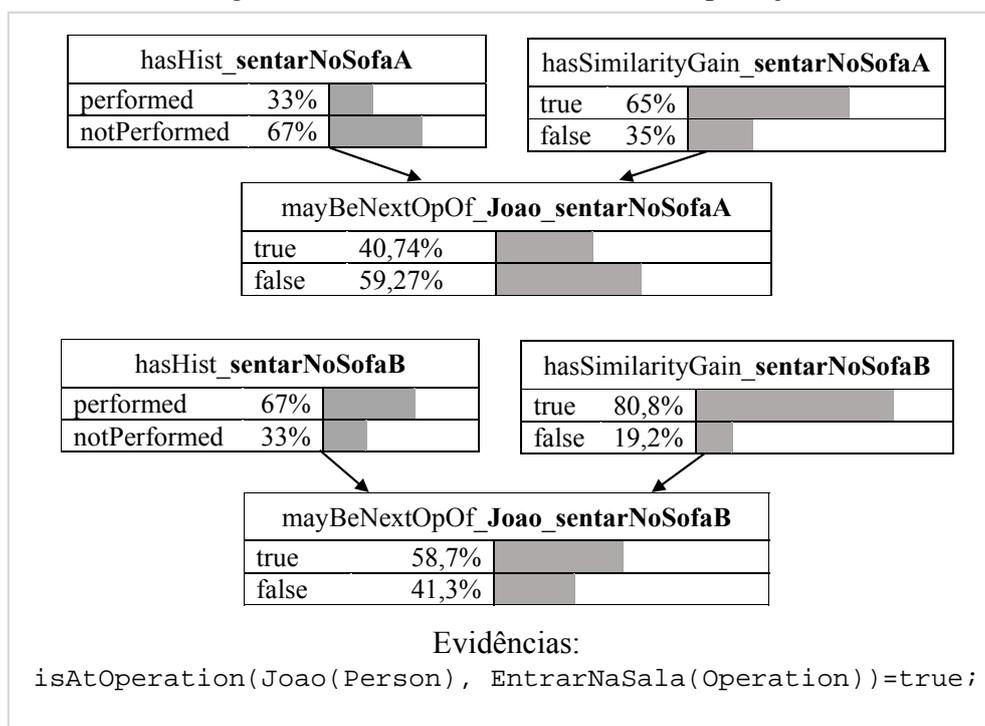
- A operação for muito realizada e de forma similar, então essa terá 73,9% de chance

de ser recomendada e 26,1% de não ser recomendada (linha 3). Caso ela seja muito realizada e de forma não similar, então a chance de recomendação cai para 43% e a de não recomendação sobe para 56,9% (linha 5);

- A operação for pouco realizada e de forma similar, então essa terá 43,1% de chance de ser recomendada e 56,9% de não ser recomendada (linha 8). Caso ela seja pouco realizada e de forma não similar, então a chance de recomendação cai para 26,1% e a de não recomendação sobe para 73,9% (linha 10);

Com isso e, a partir da evidência $isAtOperation(Joao, EntrarNaSala) = true$ que determina a operação da atividade na qual João está parado, duas consultas, uma para cada possível operação seguinte, são realizadas: (A) Qual é a probabilidade de João sentar no sofá A? (B) Qual é a probabilidade de João sentar no sofá B? O resultado dessas consultas é expresso pelo nó *maybeNextOpOf*, apresentado na Figura 4.4, nas SSBNs para a predição e, posterior recomendação, da operação mais adequada. A SSBN superior diz respeito à consulta (A), cuja probabilidade de recomendação é de 40,74%. Já a SSBN inferior faz referência à consulta (B), cuja probabilidade de recomendação é de 58,7%. Portanto, a operação recomendada à João seria “Sentar no Sofá B”, entregue ao dispositivo mais adequado sendo, por exemplo, um *smartphone*.

Figura 4.4: SSBNs com o resultado da predição

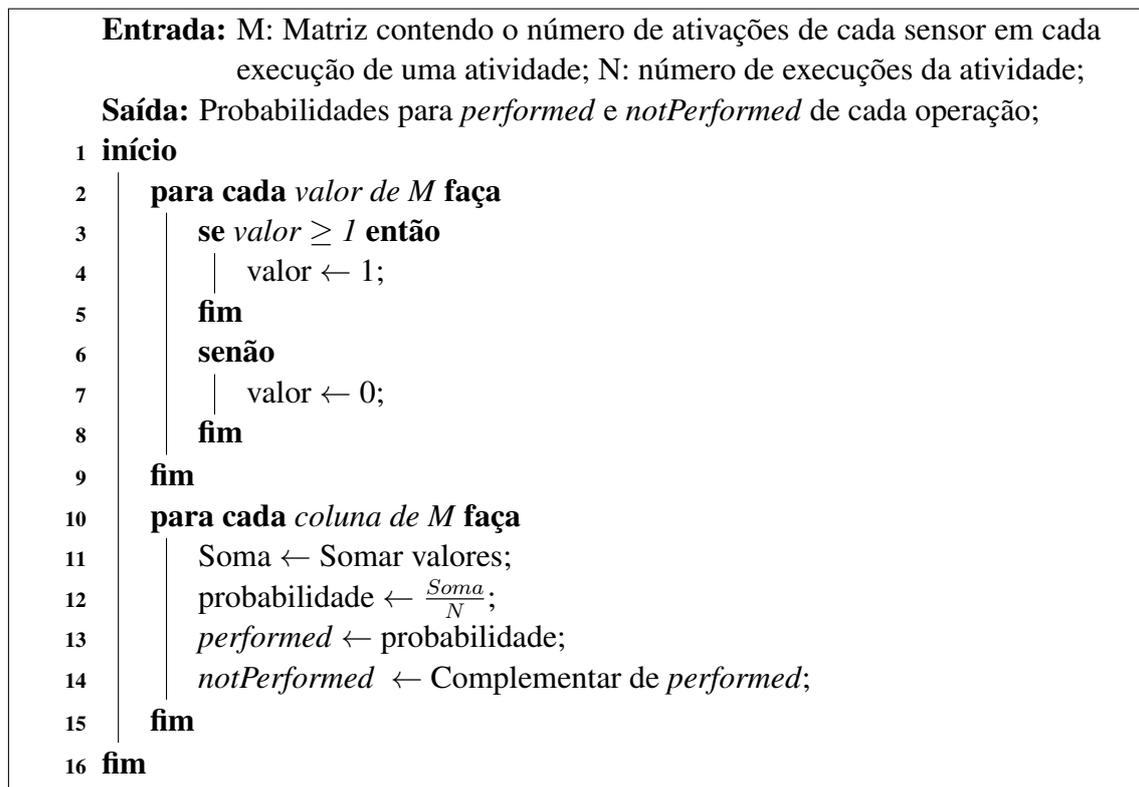


Fonte: O autor.

4.2.1 Obtenção dos valores de probabilidade

Os valores de probabilidade para os estados dos nós residentes *hasHist* e *hasSimilarityGain*, foram obtidos por meio de dois algoritmos aplicados sobre o *dataset* HBMS. O primeiro deles, apresentado pela Figura 4.5, transforma a quantidade de ativações de cada sensor em valores binários (linhas 2 à 9). Com isso, tem-se um novo *dataset* em que cada coluna representa um sensor (a realização ou não de uma operação). Em seguida, cada coluna é somada e dividida pelo número de execuções (N) da atividade, resultando um valor único que representa, em porcentagem, a quantidade de vezes que cada operação foi ou não realizada. Em outras palavras, é obtido o histórico de realização de cada operação.

Figura 4.5: Algoritmo para gerar probabilidades do nó residente *hasHist*.



Fonte: O autor.

O segundo algoritmo, apresentado pela Figura 4.6, leva em consideração o *dataset* original, ou seja, a quantidade de ativações de cada sensor. Como os dados coletados representam execuções de uma só pessoa e, a fim de exemplificar a similaridade de execução entre usuários, são criados dois grupos que remetem à dois perfis de execução utilizando, para isso, o algoritmo k-médias (*k-means*). Na sequência, cada um dos perfis é subme-

tido à função densidade de probabilidade da linha 4, que normaliza os dados segundo a distribuição normal. Por fim, cada um dos perfis é submetido à computação de similaridade, cujo resultado é um valor, em porcentagem, que representa o quão similarmente executada é cada operação. Detalhes do cálculo de similaridade fogem ao escopo deste trabalho e, por isso, não foram relatados.

Figura 4.6: Algoritmo para gerar probabilidades do nó residente *hasSimilarityGain*.

```

Entrada: M: matriz contendo o número de ativações de cada sensor em cada
            execução de uma atividade;  $\mu$ : média;  $\sigma$ : desvio padrão;
Saída: Probabilidades para os estados True e False de cada operação;
1 início
2   Dividir M em dois grupos (M1 e M2) utilizando k-médias;
3   para cada valor M1 e M2 faça
4     valorNormal  $\leftarrow \frac{1}{\sigma\sqrt{2\pi}}e^{-(valor-\mu)^2/2\sigma^2}$ ;
5   fim
6   para cada coluna M1 i e M2 j faça
7     True  $\leftarrow$  computar nível de similaridade (coluna);
8     False  $\leftarrow$  complementar de (True);
9   fim
10 fim

```

Fonte: O autor.

4.3 Considerações Finais

Para demonstrar a aplicação do meta-modelo semântico e do modelo semântico probabilístico propostos, foi desenvolvido um estudo de caso. Nesse foi proposto um cenário no qual um idoso apresenta declínios cognitivos frente às operações da atividade “assistir um DVD” recebendo, a partir disso, conselhos de como a conduzir fluidamente. Para essa atividade, foi instanciado um modelo de comportamento a partir do meta-modelo semântico, servindo de base para o modelo semântico probabilístico que, por sua vez, estima a chance de uma próxima operação ser recomendada. Além disso, foi apresentado o *dataset* HBMS, e dois algoritmos que estimam as probabilidades a priori.

Uma das vantagens ao utilizar um modelo semântico probabilístico para a recomendação é a possibilidade levar em conta raciocínio sobre a incerteza. Isso permite, ao contrário do que acontece com modelos OWL-DL, tomadas de decisão mais precisas. Portanto, no próximo capítulo, é apresentada a avaliação da abordagem.

5 AVALIAÇÃO

Este capítulo descreve a avaliação da abordagem preditiva de ações, relacionada ao cenário apresentado no capítulo anterior. Sendo assim, o objetivo consiste em verificar o quão bem João seria auxiliado, por exemplo, se a operação recomendada “Sentar no Sofá B” seria a realizada, de fato, caso ele estivesse cognitivamente bem. De outra forma, isso pode ser entendido como a capacidade de acerto da abordagem. Por isso, a fim de quantificar tal capacidade, foram adotadas medidas de desempenho, comumente empregadas na avaliação de modelos preditivos em problemas de aprendizado de máquina, sendo: a precisão, a revocação e a medida-F (JAPKOWICZ; SHAH, 2011). Os valores dessas medidas foram alcançados seguindo os assuntos que constam em cada seção a seguir.

5.1 *Holdout* e Amostragem Aleatória

Conforme apresentado no capítulo anterior, o *dataset* HBMS é composto por 60 amostras (execuções) de 6 atividades, dentre elas “Assistir um DVD”. Portanto, as 10 amostras dessa atividade foram extraídas e divididas em duas partições. A primeira partição corresponde ao subconjunto de treinamento e a segunda partição, todavia, ao subconjunto de teste. Esse processo de particionamento é conhecido como *holdout* que, segundo Faceli et al. (2011), consiste em dividir um conjunto de dados em 70% para treino e 30% para teste. No caso deste trabalho, 7 execuções para treino e 3 execuções para teste.

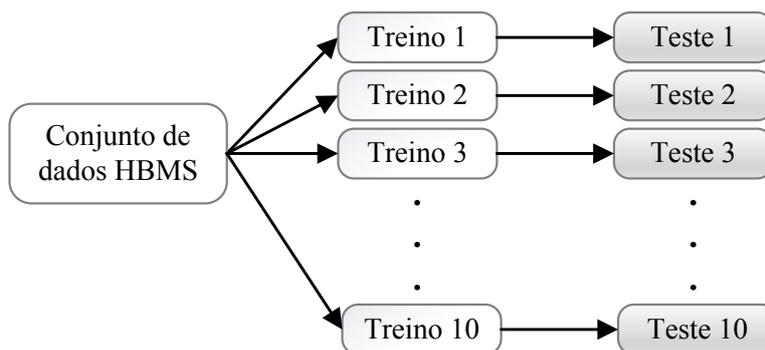
Uma crítica ao emprego de *holdout* é a não possibilidade de avaliar o quanto varia o desempenho de uma abordagem frente à diferentes combinações de instâncias no seu treinamento. Assim, para tornar os resultados menos dependentes da partição definida, são estabelecidas diversas partições aleatórias para obter uma média de desempenho em *holdout*, um método denominado amostragem aleatória. Nesses casos é importante reportar, também, os valores de desvio padrão associados, se forem altos podem indicar sensibilidade às instâncias utilizadas no treinamento (FACELI et al., 2011).

Perante o exposto, em razão da baixa quantidade execuções e, na intenção de extrair o máximo possível do *dataset* HBMS, foi empregada a amostragem aleatória. A Figura 5.1 elucidada a configuração de 10 partições aleatórias, obtidas através do módulo de pré-processamento do *software Weka* com o filtro *random sampling*.

Cada partição de treino foi utilizada para estimar os valores de probabilidade que alimentam o modelo semântico probabilístico para, então, prever e recomendar a possível

próxima operação. Com isso, cada partição de teste foi utilizada para verificar o número de execuções em que o usuário realizou a operação recomendada possibilitando, assim, a construção de uma matriz de confusão para o cálculo das medidas de desempenho apresentadas na próxima seção. Vale destacar, ainda, que esse processo foi realizado 10 vezes resultando em valores médios de desempenho.

Figura 5.1: Amostragem aleatória aplicada



Fonte: O autor.

A quantidade de partições foi definida com base em testes, visto que, por ser aleatória e fundada em poucos dados, a amostragem poderia criar partições iguais ou muito semelhantes. Com base nisso, verificou-se que, acima de 10 partições, tal fato ocorria justificando, assim, a não admissão de um maior número de partições. Aliás, isso implicaria em um aumento ou decréscimo errôneos das médias de desempenho obtidas.

5.2 Medidas de desempenho

As medidas adotadas para aferir ao desempenho da abordagem foram: a precisão, a revocação e a medida-F. O uso dessas é justificado pelo fato de serem amplamente empregadas para avaliar a qualidade dos resultados em diversas áreas de pesquisa, dentre as quais destacam-se: recuperação de informações, processamento de linguagem natural (MANNING; RAGHAVAN; SCHÜTZE, 2008) e inteligência artificial com ênfase em aprendizado de máquina (JAPKOWICZ; SHAH, 2011). Os valores dessas medidas podem ser calculados a partir de uma matriz de confusão.

Uma matriz de confusão, também conhecida como matriz de contingência, reúne o número de predições corretas e incorretas em cada classe. Dado um determinado conjunto de dados, as linhas representam as classes verdadeiras, e as colunas, as classes preditas

pelo classificador. Logo, cada elemento m_{ij} de uma matriz de confusão M_c apresenta o número de exemplos da classe i classificados como pertencentes à classe j . Para k classes, M_c tem dimensão $k \times k$. A diagonal principal apresenta os acertos do classificador, enquanto os outros elementos correspondem aos erros cometidos. Através da análise dessa matriz, obtém-se medidas quantitativas de quais classes um classificador apresenta maior dificuldade (FACELI et al., 2011).

A Figura 5.2 apresenta uma matriz de confusão para um problema de duas classes, sendo uma denotada como positiva (+) e a outra como negativa (-). Assim, têm-se os elementos m_{ij} definidos conforme consta abaixo.

Figura 5.2: Matriz de confusão exemplo

		classe predita	
		+	-
classe verdadeira	+	VP	FN
	-	FP	VN

Fonte: Adaptado de Faceli et al. (2011).

- VP (Verdadeiros Positivos): número de ocorrências da classe positiva classificados corretamente;
- VN (Verdadeiros Negativos): número de ocorrências da classe negativa classificados corretamente;
- FP (Falsos Positivos): número de ocorrências cuja classe verdadeira é negativa mas que foram classificados incorretamente como pertencendo à classe positiva;
- FN (Falsos Negativos): número de ocorrências pertencentes originalmente à classe positiva que foram incorretamente preditos como da classe negativa.

A soma de cada m_{ij} corresponde à quantidade total de exemplos do conjunto de dados de teste, denotada por n , assim: $VP + VN + FP + FN = n$. A partir da contagem desses elementos é possível calcular, então: a precisão como sendo a proporção de instâncias positivas classificadas corretamente entre todas aquelas preditas como positivas (equação 5.1); a revocação como sendo a taxa de acerto na classe positiva (equação 5.2); e a medida-F que representa a média harmônica ponderada da precisão e da revocação. Se i igual a 1, então precisão e revocação têm o mesmo grau de importância (equação 5.3).

$$Precisão = \frac{VP}{VP + FP} \quad (5.1)$$

$$Revocação = \frac{VP}{VP + FN} \quad (5.2)$$

$$F_1 = \frac{2 \times Precisão(i) \times Revocação(i)}{Precisão(i) + Revocação(i)} \quad (5.3)$$

Para fins elucidativos, a Figura 5.3 apresenta o resultado considerando o conjunto de treino 1 e o conjunto de teste 1. Para esse caso, a operação recomendada foi “Sentar no sofá B”, tal como apresentado no cenário do capítulo anterior. Analisando as três instâncias do conjunto teste, constatou-se que “Sentar no sofá B” foi escolhida pelo usuário duas vezes (VP) e, “Sentar no sofá A”, uma vez (FP). Os demais valores (VN e FN) são sempre zero, pois a operação recomendada corresponde à classe positiva.

Figura 5.3: Matriz de confusão para o treino 1 e teste 1

		operação predita	
		Sentar no sofá B	Sentar no sofá A
operação verdadeira	Sentar no sofá B	2	0
	Sentar no sofá A	1	0

Fonte: O autor.

A partir da Figura 5.3 e das equações apresentadas anteriormente, é possível calcular os resultados de cada uma das métricas para a operação predita e recomendada “Sentar no sofá B”, apresentados nas equações 5.4, 5.5 e 5.6 .

$$Precisão(B) = \frac{2}{2 + 1} = 0,6667 \approx 67\% \quad (5.4)$$

$$Revocação(B) = \frac{2}{2 + 0} = 1 = 100\% \quad (5.5)$$

$$F_1(B) = \frac{2 \times 0,6667 \times 1}{0,6667 + 1} = 0,7998 \approx 80\% \quad (5.6)$$

A equação 5.4 mostra que a predição de “Sentar no sofá B” foi 67% precisa, ou seja, que o usuário realmente realizou o que fora predito e recomendado. A equação 5.5 mostra que a predição atingiu uma revocação de 100%, dada a inexistência de falsos negativos (FN). Por fim, a equação 5.6 mostra um valor de 80% para a medida-F.

5.3 Resultados

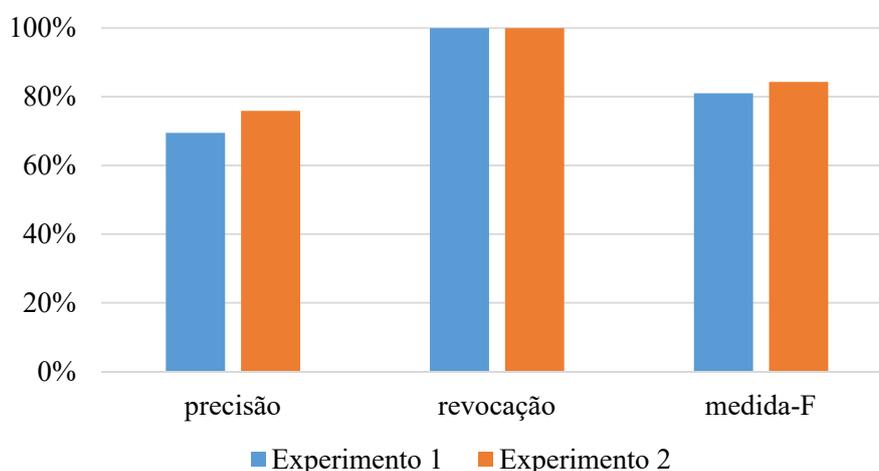
Os resultados apresentados e discutidos nesta seção dizem respeito às médias de desempenho de cada medida apresentada na seção anterior. Nesse sentido, foram definidos dois experimentos, especificados nos itens a seguir.

- Experimento 1: são consideradas as 10 execuções da BU “Assistir um DVD”, isto é, é sabido à qual atividade pertencem as execuções;
- Experimento 2: são incorporadas execuções de outras BUs que também envolvem decisões sobre as operações “Sentar no sofá A” e “Sentar no sofá B”, sendo: (2) preparar uma refeição, (4) assistir TV e (6) relaxar. Com isso, obteve-se um conjunto de dados maior, com 28 execuções.

O experimento 1 está diretamente relacionado à BU do estudo de caso. Já o experimento 2 visa avaliar a capacidade preditiva da abordagem frente à execuções não conhecidas, ou seja, não se sabe à qual BU pertencem. Além disso, o experimento 2 foi concebido na tentativa de amenizar a limitação da baixa quantidade de dados.

A Figura 5.4 apresenta os resultados finais obtidos para cada um dos experimentos. O experimento 1 apresentou precisão de 69,5%; revocação de 100%; e medida-F de 81%, sendo 18,106; 0; e 16,2 seus valores de desvio padrão, respectivamente. O experimento 2, por outro lado, apresentou precisão de 75,9%; revocação de 100%; e medida-F de 84,35%, sendo 14,3; 0; e 12,61 seus valores de desvio padrão, respectivamente. Portanto, esses valores permitem concluir que a abordagem é promissora, especialmente capaz de prever a próxima possível operação do usuário mesmo sem saber qual é a BU em questão.

Figura 5.4: Médias de desempenho da predição



Fonte: O autor.

5.4 Considerações Finais

A avaliação da abordagem foi conduzida, inicialmente, pela amostragem aleatória aplicada ao *dataset* HBMS, resultando em 10 partições de treino e de teste. Cada partição de treino foi empregada na obtenção dos valores de probabilidade para alimentar o modelo semântico probabilístico que, com isso, gera a predição da próxima operação possível. Essa, por sua vez, é utilizada para verificar a sua realização, ou não, pelo usuário na partição de teste. Esse processo é repetido 10 vezes, gerando igual número de matrizes de confusão que são utilizadas para calcular os valores médios das medidas de desempenho adotadas: precisão, revocação e medida-F.

Portanto, foi possível concluir que, apesar da baixa quantidade de dados disponível, os resultados obtidos foram promissores, apresentando uma precisão média de aproximadamente 70%. Acredita-se que melhores resultados poderiam ser obtidos caso existisse uma maior quantidade de dados. Por isso, está prevista uma nova coleta de dados envolvendo mais usuários no laboratório HBMS que resultará em um maior *dataset*. Assim, novos experimentos serão possíveis.

6 CONCLUSÃO

Este capítulo discute as considerações finais, com ênfase nos objetivos alcançados e resultados obtidos através do desenvolvimento deste trabalho. Além disso, são apresentadas as contribuições científicas bem como as lições aprendidas e limitações. Por fim, são apresentadas as perspectivas para trabalhos futuros.

Esta dissertação propôs uma abordagem que visa beneficiar os sistemas para Ambientes de Vivência Assistida com a capacidade de prever ações humanas para a facilitação de atividades diárias, particularmente quando declínios cognitivos relacionados à elas ocorrem. Para tanto, os objetivos específicos foram alcançados:

- *Desenvolver um meta-modelo semântico para a modelagem de comportamento e de contexto, baseado no meta-modelo da linguagem HCM-L:* o meta-modelo semântico desenvolvido se traduz como uma ontologia genérica, cujos conceitos são fundados em um diagrama de classes da UML no qual está representado o meta-modelo da linguagem HCM-L. Por isso, a concepção de tal ontologia foi guiada através de uma metodologia para conversão de diagramas de classe UML para ontologias OWL-DL com o auxílio do *software Protégé*;
- *Adaptar o modelo semântico probabilístico para a previsão de situações indesejadas, proposto por Machado (2015), para a previsão de ações sobre os modelos de comportamento:* o modelo semântico probabilístico para a previsão de ações foi adaptado, inicialmente, do modelo proposto por Machado (2015) e, por conseguinte, exaustivamente refinado seguindo a metodologia de Carvalho (2011) para a criação de ontologias probabilísticas PR-OWL. Esse processo de modelagem foi apoiado pelo uso do *software UNBBayes* viabilizando, assim, uma das principais contribuições deste trabalho que se refere ao raciocínio sobre a incerteza;
- *Propor uma arquitetura de predição e inferência de ações utilizando, como prova de conceito, o sistema HBMS:* a arquitetura de predição e inferência foi proposta com base nos elementos do processo de raciocínio sobre os modelos de comportamento instanciados do meta-modelo semântico, isto é: as distribuições de probabilidade (LPDs), o modelo semântico probabilístico e as redes de específica situação (SSBNs). O sistema HBMS serviu como demonstração para a implementação dessa arquitetura como uma solução para Ambientes de Vivência Assistida;
- *Avaliar a abordagem e seu desempenho através de medidas como a precisão, a revocação e a medida-F:* a abordagem foi demonstrada através da definição de um

estudo de caso cujo cenário representou uma situação de declínio cognitivo de um usuário na atividade de assistir um DVD. Nesta, dentre duas possíveis próximas operações a abordagem previu a operação “Sentar no sofá B”. Com isso, foi necessário aferir o quão bem um usuário seria auxiliado, ou seja, se a operação prevista foi por ele realizada. Assim, foi obtido, em média, uma precisão de 69,5%, revocação de 100% e medida-F de 81%.

A trajetória deste trabalho possibilitou alcançar os objetivos discutidos acima resultando, com isso, em duas contribuições centrais que compreendem:

- o meta-modelo semântico: através dele é possível gerar modelos de comportamento complexos ou não, bem como de elementos contextuais. Isso é justificado pelo embasamento conceitual do meta-modelo semântico, isto é, a linguagem HCM-L. Portanto, abordagens que endereçam modelagem de comportamento podem se beneficiar dessa conceituação semântica exaustivamente estudada por Mayr et al. (2016) e por este trabalho. Outra vantagem é que os modelos podem ajudar a amenizar o problema de partida a frio enfrentado por métodos que modelam comportamento puramente baseados em dados;
- o modelo semântico probabilístico: permite realizar predição e inferência sobre as instâncias do meta-modelo semântico (modelos de comportamento), através da representação e do tratamento de incerteza. Isso é benéfico, pois permite tomadas de decisão mais precisas, particularmente quando consideradas em soluções com tecnologias da Web Semântica. Além disso, o meta-modelo semântico probabilístico representa a continuação da extensa pesquisa desenvolvida por Machado (2015).

Apesar dos resultados promissores, a abordagem apresenta algumas limitações. Em relação ao meta-modelo semântico, os modelos de comportamento e de contexto podem se tornar complexos e, por isso, difíceis de manter e gerenciar, mesmo considerando a utilização de *softwares* gerenciadores de ontologias, tal como o *Protégé*. Outra limitação refere-se à dimensão temporal não explorada no modelo semântico probabilístico que não foi representada por não estar expressa no *dataset* HBMS. A avaliação da abordagem ficou limitada à baixa quantidade de dados provida por esse, assim como o cenário.

A experiência obtida com o desenvolvimento deste trabalho permitiu elaborar alguns aprendizados podendo, estes, virem a ser úteis a trabalhos futuros. O primeiro deles tem a ver com ontologias como sendo um dos principais meios para representação de contexto. Além disso, não há um consenso entre os conceitos “comportamento” e “ativi-

dade (ADL)”, ambos se referindo à mesma coisa, ou seja, à uma sequência de ações que juntas levam ao alcance de um objetivo definido.

6.1 Trabalhos Futuros

Como resultado deste trabalho, os seguintes trabalhos futuros foram identificados como possíveis:

- Refinar o modelo semântico probabilístico, pois este leva em consideração o histórico do usuário na realização de uma operação assim como sua similaridade em relação a outros usuários. Esses nós influenciam positivamente a predição, porém torna-se necessário analisar outros cenários para identificar se existem outras relações semânticas que podem ser utilizadas como nós de entrada que possam influenciar o nó residente $\text{mayBeNextOpOf}(u, op)$;
- Investigar como tratar a mudança de comportamento do usuário nas atividades ao longo do tempo;
- Investigar algoritmos de aprendizado de máquina para adquirir valores de probabilidade, para os nós $\text{hasHist}(op)$ e $\text{hasSimilarityGain}(op)$, automaticamente ao invés de obtê-los de forma semi-automática como realizado neste trabalho;
- Explorar *datasets* voltados para a validação de abordagens para o reconhecimento de atividades de forma que se prestem para a predição de ações;
- Investigar formas de como transformar os modelos desenvolvidos com a linguagem HCM-L para modelos do meta-modelo semântico aqui desenvolvido para, com isso, usufruírem do poder de inferência sobre ontologias OWL-DL considerando raciocínio sobre a incerteza com PR-OWL.

REFERÊNCIAS

- ABOWD, G. D. et al. Towards a Better Understanding of Context and Context-Awareness. In: **Computing Systems**. [s.n.], 1999. v. 40, n. 3, p. 304–307. ISBN 978-3-540-66550-2. Available from Internet: <http://link.springer.com/10.1007/3-540-48157-5_29>.
- Al Machot, F.; MAYR, H. C. Improving Human Activity Recognition by Smart Windowing and Spatio-Temporal Feature Analysis. In: **Proceedings of the 9th ACM International Conference on Pervasive Technologies Related to Assistive Environments - PETRA '16**. New York, New York, USA: ACM Press, 2016. p. 1–7. ISBN 9781450343374. Available from Internet: <<http://dl.acm.org/citation.cfm?doid=2910674.2910697>>.
- ALLOULOU, H. et al. Uncertainty handling in semantic reasoning for accurate context understanding. **Knowledge-Based Systems**, v. 77, p. 16–28, 2015. ISSN 09507051.
- BETTINI, C. et al. A survey of context modelling and reasoning techniques. **Pervasive and Mobile Computing**, Elsevier B.V., v. 6, n. 2, p. 161–180, apr 2010. ISSN 15741192. Available from Internet: <<http://linkinghub.elsevier.com/retrieve/pii/S1574119209000510>>.
- BUREAU, P. R. **Communication from the Commission to the European Parliament and the Council on a European initiative on Alzheimer's Disease and Other Dementias**. [S.l.], 2009. 10 p. Available from Internet: <http://ec.europa.eu/health/ph_information/dissemination/documents/com2009_380_en.pdf>.
- CALVARESI, D. et al. Exploring the ambient assisted living domain: a systematic review. **Journal of Ambient Intelligence and Humanized Computing**, p. 1–19, 2016. ISSN 1868-5145. Available from Internet: <<http://dx.doi.org/10.1007/s12652-016-0374-3>>.
- CARVALHO, R. N. **Representation and Modeling Methodology**. Thesis (PhD) — George Mason University, 2011.
- CARVALHO, R. N.; LASKEY, K. B.; COSTA, P. C. G. PR-OWL 2.0 - Bridging the gap to OWL semantics. In: CEUR-WS.ORG. **Proceedings of the 6th International Workshop on Uncertainty Reasoning for the Semantic Web (URSW 2010), collocated with the 9th International Semantic Web Conference (ISWC 2010)**. [S.l.], 2010. p. 73–84.
- CARVALHO, R. N. et al. Probabilistic Ontology and Knowledge Fusion for Procurement Fraud Detection in Brazil. In: **Uncertainty Reasoning for the Semantic Web II**. [S.l.]: Springer Berlin Heidelberg, 2013. v. 7123, p. 19–40.
- CEBALLOS, H. G.; FLORES-SOLORIO, V.; GARCIA, J. P. A Probabilistic BPMN Normal Form to Model and Advise Human Activities. In: **Engineering Multi-Agent Systems: Third International Workshop, EMAS 2015, Istanbul, Turkey, May 5, 2015, Revised**. Springer International Publishing, 2015. p. 51–69. Available from Internet: <http://link.springer.com/10.1007/978-3-319-26184-3_4>.
- CHEN, L.; NUGENT, C.; OKEYO, G. An ontology-based hybrid approach to activity modeling for smart homes. **IEEE Transactions on Human-Machine Systems**,

IEEE, v. 44, n. 1, p. 92–105, feb 2014. ISSN 21682291. Available from Internet: <<http://ieeexplore.ieee.org/lpdocs/epic03/wrapper.htm?arnumber=6689346>>.

Conselho Nacional de Pesquisa. **Risk Analysis and Uncertainty in Flood Damage Reduction Studies**. Washington, D.C.: National Academies Press, 2000. 216 p. ISBN 978-0-309-07136-9. Available from Internet: <<http://www.nap.edu/catalog/9971>>.

COSTA, P. C. G. **Bayesian semantics for the Semantic Web**. [S.l.]: George Mason University, 2005.

COSTA, P. C. G. et al. A First-Order Bayesian Tool for Probabilistic Ontologies. In: **Proceedings of the Twenty-First International FLAIRS Conference**. [S.l.: s.n.], 2008.

COSTA, P. C. G.; LASKEY, K. B. Multi-entity bayesian networks without multi-tears. 2006.

COSTA, P. C. G.; LASKEY, K. B. PR-OWL: A framework for probabilistic ontologies. **Frontiers in Artificial Intelligence and Applications**, IOS Press, v. 150, p. 237, 2006.

Del Fabro Neto, A. et al. A context-aware model for human activity prediction and risk inference in actions. **Journal of Applied Computing Research**, v. 5, n. 1, p. 59–69, jul 2016. ISSN 2236-8434. Available from Internet: <<http://revistas.unisinos.br/index.php/jacr/article/view/10076>>.

DEY, A. K. Understanding and Using Context. **Personal and Ubiquitous Computing**, Springer-Verlag, v. 5, n. 1, p. 4–7, feb 2001. ISSN 1617-4909. Available from Internet: <<http://link.springer.com/10.1007/s007790170019>>.

El Hajjamy, O. et al. MAPPING UML TO OWL2 ONTOLOGY. **Journal of Theoretical and Applied Information Technology**, v. 1590, n. 1, 2016. Available from Internet: <www.jatit.org>.

EUROPE, A. **Active and Assisted Living Programme - ICT for ageing well**. 2008. Available from Internet: <<http://www.aal-europe.eu/>>.

FACELI, K. et al. Inteligência Artificial: Uma Abordagem de Aprendizado de Máquina. **Livros Técnicos e Científicos**, 2011.

GRUBER, T. R. A translation approach to portable ontology specifications. **Knowledge Acquisition**, v. 5, n. 2, p. 199–220, 1993. ISSN 1042-8143. Available from Internet: <<http://www.sciencedirect.com/science/article/pii/S1042814383710083>>.

GUARINO, N. Formal Ontology and Information Systems. In: **Formal Ontology in Information Systems: Proceedings of the first international conference (FOIS'98), June 6-8, Trento, Italy**. [S.l.]: Press, 1998. p. 6–8.

GUIZZARDI, G. **Ontological Foundations for Conceptual Modeling with Applications**. 695–696 p. Thesis (PhD), 2005. Available from Internet: <http://doc.utwente.nl/50826http://link.springer.com/10.1007/978-3-642-31095-9_45>.

HABERLIN, R. J. **UnBBayes PR-OWL 2.0 Tutorial**. 2013.

HAWKINS, K. P. et al. Probabilistic human action prediction and wait-sensitive planning for responsive human-robot collaboration. In: **13th IEEE-RAS International Conference on Humanoid Robots (Humanoids)**. [S.l.: s.n.], 2013.

HELAOUI, R.; RIBONI, D.; STUCKENSCHMIDT, H. A probabilistic ontological framework for the recognition of multilevel human activities. In: **Proceedings of the 2013 ACM international joint conference on Pervasive and ubiquitous computing - UbiComp '13**. New York, New York, USA: ACM Press, 2013. p. 345. ISBN 9781450317702. Available from Internet: <<http://dl.acm.org/citation.cfm?doid=2493432.2493501http://dl.acm.org/citation.cfm?id=2493501>>.

HLEL, E.; JAMOSSI, S.; HAMADOU, A. B. A Probabilistic Ontology for the Prediction of Author's Interests. In: . Springer International Publishing, 2015. p. 492–501. Available from Internet: <http://link.springer.com/10.1007/978-3-319-24306-1_48>.

HOWARD, C.; STUMPTNER, M. A Survey of Directed Entity-Relation-Based First-Order Probabilistic Languages. **ACM Computing Surveys**, ACM, v. 47, n. 1, p. 1–40, may 2014. ISSN 03600300. Available from Internet: <<http://dl.acm.org/citation.cfm?doid=2620784.2560546>>.

JACOBSEN, L. a. et al. America's aging population. **Population Bulletin**, v. 66, n. 1, p. 1–18, 2011. ISSN 0032468X.

JAPKOWICZ, N.; SHAH, M. **Evaluating Learning Algorithms: A Classification Perspective**. New York, NY, USA: Cambridge University Press, 2011. ISBN 0521196000, 9780521196000.

KATZ, S.; AKPOM, C. A. A measure of primary sociobiological functions. **International journal of health services : planning, administration, evaluation**, v. 6, n. 3, p. 493–508, 1976. ISSN 0020-7314 (Print).

KOFOD-PETERSEN, A.; MIKALSEN, M. Context: Representation and Reasoning Representing and Reasoning about Context in a Mobile Environment. **Special issue of the Revue d'Intelligence Artificielle on "Applying Context-Management"(2005)**, 2005.

LASKEY, K. B. MEBN: A language for first-order Bayesian knowledge bases. **Artificial intelligence**, Elsevier, v. 172, n. 2, p. 140–178, 2008.

LASKEY, K. B. et al. PR-OWL 2 Case Study: A Maritime Domain Probabilistic Ontology. 2011.

LAWTON, M. P.; BRODY, E. M. Assessment of Older People: Self-Maintaining and Instrumental Activities of Daily Living. **The Gerontologist**, Oxford University Press, v. 9, n. 3 Part 1, p. 179–186, sep 1969. ISSN 0016-9013. Available from Internet: <http://gerontologist.oxfordjournals.org/cgi/doi/10.1093/geront/9.3_Part_1.179>.

LEONTYEV, A. N. **Activity, consciousness, and personality**. Englewood Cliffs, N.J.: Prentice-Hall, 1978. ISBN 9780130035332. Available from Internet: <<http://lchc.ucsd.edu/MCA/Paper/leontev/>>.

LI, R.; LU, B.; MCDONALD-MAIER, K. D. Cognitive assisted living ambient system: a survey. **Digital Communications and Networks**, v. 1, n. 4, p. 229–252, 2015. ISSN 23528648.

LI, Y.; CHEN, J.; FENG, L. Dealing with Uncertainty : A Survey of Theories and Practices. **IEEE TRANSACTIONS ON KNOWLEDGE AND DATA ENGINEERING**, v. 25, n. 11, p. 2463–2482, 2013.

MACHADO, A. **Sensibilidade à Situação em Ambientes de Vivência Assistida : Uma Abordagem Reativa , Proativa e Extensível**. Thesis (PhD), 2015. Available from Internet: <<http://hdl.handle.net/10183/119422>>.

MACHOT, F. A.; MAYR, H. C.; MICHAEL, J. Behavior Modeling and Reasoning for Ambient Support: HCM-L Modeler. In: **Modern Advances in Applied Intelligence**. [s.n.], 2014. v. 8482, p. 388–397. Available from Internet: <http://link.springer.com/10.1007/978-3-319-07467-2_41>.

MANNING, C. D.; RAGHAVAN, P.; SCHÜTZE, H. **Introduction to Information Retrieval**. New York, NY, USA: Cambridge University Press, 2008. ISBN 0521865719, 9780521865715.

MATSUMOTO, S. et al. **There's No More Need to be a Night OWL: on the PR-OWL for a MEBN Tool Before Nightfall**. [S.l.]: iConcept Press, 2011.

MAYR, H. C. et al. HCM-L: Domain-Specific Modeling for Active and Assisted Living. In: _____. **Domain-Specific Conceptual Modeling**. Cham: Springer International Publishing, 2016. p. 527–552. ISBN 978-3-319-39417-6. Available from Internet: <http://dx.doi.org/10.1007/978-3-319-39417-6_24http://link.springer.com/10.1007/978-3-319-39417-6_24>.

MAYR, H. C.; MICHAEL, J. Control pattern based analysis of HCM-L, a language for cognitive modeling. In: **International Conference on Advances in ICT for Emerging Regions (ICTer2012)**. IEEE, 2012. p. 169–175. ISBN 978-1-4673-5530-8. Available from Internet: <<http://ieeexplore.ieee.org/lpdocs/epic03/wrapper.htm?arnumber=6421414>>.

MICHAEL, J. Using cognitive models for behavioral assistance of humans. **it - Information Technology**, v. 58, n. 1, p. 44–48, jan 2016. ISSN 1611-2776. Available from Internet: <<http://www.degruyter.com/view/j/itit.2016.58.issue-1/itit-2015-0050/itit-2015-0050.xml>>.

MICHAEL, J.; Al Machot, F.; MAYR, H. C. ADOxx based tool support for a behavior centered modeling approach. In: **Proceedings of the 8th ACM International Conference on Pervasive Technologies Related to Assistive Environments - PETRA '15**. New York, New York, USA: ACM Press, 2015. p. 1–8. ISBN 9781450334525. Available from Internet: <<http://dl.acm.org/citation.cfm?doid=2769493.2769503>>.

MICHAEL, J. et al. Cognitive Modeling and Support for Ambient Assistance. In: MAYR, H. C. et al. (Ed.). **Information Systems: Methods, Models, and Applications**. Berlin, Heidelberg: Springer Berlin Heidelberg, 2013, (Lecture Notes in Business Information Processing, v. 137). p. 96–107. ISBN 978-3-642-38369-4. Available from Internet: <<http://link.springer.com/10.1007/978-3-642-38370-0>>.

MICHAEL, J.; MACHOT, F. A.; MAYR, H. C. A Behavior Centered Modeling Tool Based on ADOxx. In: NURCAN, S. et al. (Ed.). **Joint Proceedings of the CAiSE 2014 Forum and CAiSE 2014 Doctoral Consortium co-located with the 26th International Conference on Advanced Information Systems Engineering (CAiSE 2014), Thessaloniki, Greece, June 18-20, 2014**. CEUR-WS.org, 2014. (CEUR Workshop Proceedings, v. 1164), p. 153–160. Available from Internet: <<http://ceur-ws.org/Vol-1164/PaperDemo03.pdf>>.

MICHAEL, J.; MAYR, H. C. Conceptual Modeling for Ambient Assistance. In: NG, W.; STOREY, V. C.; TRUJILLO, J. (Ed.). **Conceptual Modeling - ER 2013**. 1. ed. Hong-Kong, China: Springer-Verlag Berlin Heidelberg, 2013. v. 8217, p. 403–413. ISBN 978-3-642-41923-2. Available from Internet: <http://dx.doi.org/10.1007/978-3-642-41924-9_33http://link.springer.com/10.1007/978-3-642-41924-9_33>.

MICHAEL, J.; MAYR, H. C. Creating a Domain Specific Modelling Method for Ambient Assistance. In: **International Conference on Advances in ICT for Emerging Regions**. Colombo, Sri Lanka: [s.n.], 2015. p. 1–6.

MICHAEL, J.; MAYR, H. C. Intuitive Understanding of a Modeling Language. In: **Proceedings of the Australasian Computer Science Week Multiconference**. New York, NY, USA: ACM, 2017. (ACSW '17), p. 35:1—35:10. ISBN 978-1-4503-4768-6. Available from Internet: <<http://doi.acm.org/10.1145/3014812.3014849>>.

MINOR, B.; DOPPA, J. R.; COOK, D. J. Data-driven activity prediction: algorithms, evaluation methodology, and applications. **Proceedings of the 21th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining**, p. 805–814, 2015. Available from Internet: <<http://dl.acm.org/citation.cfm?id=2783258.2783408>>.

MONEKOSSO, D.; FLOREZ-REVUELTA, F.; REMAGNINO, P. Ambient Assisted Living. **IEEE Intelligent Systems**, 2015.

MOODY, D. L. The Physics” of Notations: Toward a Scientific Basis for Constructing Visual Notations in Software Engineering. **IEEE Transactions on Software Engineering**, v. 35, n. 6, p. 756–779, 2009. ISSN 0098-5589.

MOORE, P. et al. A Survey of Context Modeling for Pervasive Cooperative Learning. In: **2007 First IEEE International Symposium on Information Technologies and Applications in Education**. IEEE, 2007. p. K5–1–K5–6. ISBN 978-1-4244-1385-0. Available from Internet: <<http://ieeexplore.ieee.org/document/4409367/>>.

NI, Q.; HERNANDO, A. B. G.; CRUZ, I. P. de la. **The elderly’s independent living in smart homes: A characterization of activities and sensing infrastructure survey to facilitate services development**. [S.l.: s.n.], 2015. 11312–11362 p. ISSN 14248220. ISBN 3463414929.

NUGENT, C. D. et al. Experiences in the development of a Smart Lab. **International Journal of Biomedical Engineering and Technology**, v. 2, n. 4, p. 319–331, 2009. Available from Internet: <<http://www.inderscienceonline.com/doi/abs/10.1504/IJBET.2009.027796>>.

ONU. **World population, ageing**. [S.l.], 2015. 164 p. Available from Internet: <www.un.org/.../population/.../WPA2009/WPA2009>.

POLASTRO, R. B. **Lógica probabilística baseada em redes Bayesianas relacionais com inferência em primeira ordem**. Thesis (PhD) — Universidade de São Paulo, São Paulo, may 2012. Available from Internet: <<http://www.teses.usp.br/teses/disponiveis/3/3152/tde-13062013-163105/>>.

RODRÍGUEZ, N. D. et al. A survey on ontologies for human behavior recognition. **ACM Computing Surveys**, ACM, v. 46, n. 4, p. 1–33, mar 2014. ISSN 03600300. Available from Internet: <<http://dl.acm.org/citation.cfm?doid=2597757.2523819>>.

SADRI, F. Ambient intelligence. **ACM Computing Surveys**, v. 43, n. 4, p. 1–66, oct 2011. ISSN 03600300. Available from Internet: <<http://doi.acm.org/10.1145/1978802.1978815><http://www.doc.ic.ac.uk/~sim/Papers/Other/AmIsurveyfinalMarch2010.pdf><http://dl.acm.org/citation.cfm?doid=1978802.1978815>>.

SCHILIT, B.; ADAMS, N.; WANT, R. Context-aware computing applications. In: **Workshop on Mobile Computing Systems and Applications**. IEEE Comput. Soc. Press, 1994. p. 85–90. ISBN 0-8186-6345-6. ISSN 15277755. Available from Internet: <<http://ieeexplore.ieee.org/lpdocs/epic03/wrapper.htm?arnumber=512740>>.

SUZMAN, R.; BEARD, J. Global Health and Aging. **NIH Publication no 117737**, v. 1, n. 4, p. 273–277, 2011. ISSN 00959006. Available from Internet: <[http://links.jstor.org/sici?sici=0095-9006\(196024\)1:4%3C273:HAA%3E2.0.CO;2-C](http://links.jstor.org/sici?sici=0095-9006(196024)1:4%3C273:HAA%3E2.0.CO;2-C)>.

WEISER, M. Some computer science issues in ubiquitous computing. **Communications of the ACM**, ACM, v. 36, n. 7, p. 75–84, jul 1993. ISSN 00010782. Available from Internet: <<http://portal.acm.org/citation.cfm?doid=159544.159617>>.

YIN, R. K. **Case Study Research: Design and Methods**. SAGE Publications, 2013. ISBN 9781483322247. Available from Internet: <<https://books.google.com.br/books?id=OgyqBAAAQBAJ>>.

YURUR, O. et al. Context-awareness for mobile sensing: A survey and future directions. **IEEE Communications Surveys and Tutorials**, v. 18, n. 1, p. 68–93, 2016. ISSN 1553877X.

ZEDLITZ, J.; JÖRKE, J.; LUTTENBERGER, N. From UML to OWL 2. In: **Communications in Computer and Information Science**. [s.n.], 2012. v. 295 CCIS, p. 154–163. ISBN 9783642328251. Available from Internet: <http://link.springer.com/10.1007/978-3-642-32826-8_16>.