



Programa de Pós-Graduação em

Computação Aplicada

Mestrado/Doutorado Acadêmico

João Elison da Rosa Tavares

Apollo: Um Modelo para Predição de Acidentes por Causas
Externas em Ambiente Inteligentes

São Leopoldo, 2022

UNIVERSIDADE DO VALE DO RIO DOS SINOS — UNISINOS
UNIDADE ACADÊMICA DE PESQUISA E PÓS-GRADUAÇÃO
PROGRAMA DE PÓS-GRADUAÇÃO EM COMPUTAÇÃO APLICADA
NÍVEL DOUTORADO

JOÃO ELISON DA ROSA TAVARES

**APOLLO: UM MODELO PARA PREDIÇÃO DE ACIDENTES POR CAUSAS
EXTERNAS EM AMBIENTES INTELIGENTES**

São Leopoldo
2022

João Elison da Rosa Tavares

**APOLLO: UM MODELO PARA PREDIÇÃO DE ACIDENTES POR CAUSAS
EXTERNAS EM AMBIENTES INTELIGENTES**

Tese apresentada como requisito para a
obtenção do título de Doutor, pelo programa de
Pós-Graduação em Computação Aplicada da
Universidade do Vale do Rio dos Sinos -
UNISINOS

Orientador:
Prof. Dr. Jorge Luis Victória Barbosa

São Leopoldo
2022

T231a Tavares, João Elison da Rosa.
 Apollo : um modelo para predição de acidentes por causas
 externas em ambientes inteligentes / João Elison da Rosa
 Tavares. – 2022.
 160 f. : il. ; 30 cm.

 Tese (doutorado) – Universidade do Vale do Rio dos Sinos,
 Programa de Pós-Graduação em Computação Aplicada, 2022.
 "Orientador: Prof. Dr. Jorge Luis Victória Barbosa".

 1. Computação ubíqua. 2. Cuidados ubíquos. 3. Ambientes
 inteligentes. 4. Robótica ubíqua. 5. Causas externas acidentais.
 6. Riscos à saúde. I. Título.

CDU 004.75.057.5

ATA DE BANCA EXAMINADORA DE TESE DE DOUTORADO Nº 05/2022

Aluno: João Elison da Rosa Tavares

Título da Tese: "APOLLO: UM MODELO PARA PREDIÇÃO DE ACIDENTES POR CAUSAS EXTERNAS EM AMBIENTES INTELIGENTES"

Banca: Prof. Dr. Jorge Luis Victoria Barbosa – Orientador
Prof. Dr. Cristiano André da Costa – UNISINOS
Prof. Dr. Fabiano Passuelo Hessel - PUCRS
Prof. Dr. José Palazzo Moreira de Oliveira - UFRGS

Aos vinte e oito dias do mês de março do ano de 2022, às 14h reuniu-se a Comissão Examinadora de Defesa de tese composta pelos professores: Prof. Dr. Jorge Luis Victoria Barbosa, Orientador – UNISINOS (por webconferência); Prof. Dr. Cristiano André da Costa, Avaliador - UNISINOS (por webconferência); Prof. Dr. Fabiano Passuelo Hessel, Avaliador – PUCRS (por webconferência); Prof. Dr. José Palazzo Moreira de Oliveira, Avaliador – UFRGS (por webconferência); para analisar e avaliar a Tese apresentada pelo aluno **João Elison da Rosa Tavares** (por webconferência).

Considerações da Banca:

Após a apresentação do aluno, os professores se reuniram para realização da avaliação. Durante a banca, foram indicadas pelos professores diversas melhorias, as quais deverão constar na versão final do texto e foram confirmadas na reunião.

Ocorreu alteração do título? (X)Não () Sim

Indicar o novo título:

A Banca Examinadora, em cumprimento ao requisito exigido para a obtenção do Título de Doutor em Computação Aplicada, julga esta tese:

(X) APROVADA () REPROVADA

Conforme Artigo 75 do Regimento do Programa o texto definitivo, com aprovação do Orientador, deverá ser entregue no prazo máximo de sessenta (60) dias após a defesa. O resultado da banca é de consenso entre os avaliadores. A emissão do Diploma está condicionada a entrega da versão final da Tese. A sessão da Defesa de Tese ocorreu integralmente por webconferência para atender às recomendações da OMS e Ministério da Saúde com relação ao Covid-19.

São Leopoldo, 28 de março de 2022.



Prof. Dr. Jorge Luis Victoria Barbosa
Orientador

Por um mundo novo e melhor.

*Em vez de se tornar um homem de sucesso,
tente tornar-se um homem de valor.*

— ALBERT EINSTEIN

AGRADECIMENTOS

Agradeço à Deus pela vida, por ter saúde e pelas oportunidades. Que eu possa transformar todas as bênçãos recebidas em ações em prol dos demais.

À minha amada esposa Ângela por toda a sua paciência, amor, apoio e parceria em todas as horas. Ao meu pequeno príncipe João Pedro, minha inspiração para ser melhor a cada dia. Obrigado por entender as ausências do papai enquanto ele estava "tabaiando". Parabéns, querido, por tua superação em tua "kita-sanduíche", na Alemanha. Vamos colocar no teu currículo tua primeira experiência internacional =). Meus amores, esta título é de nossa família.

Aos meus pais Ilda e João Eroni (*in memoriam*). Mãe, foste minha primeira e será minha eterna professora. Obrigado por ter me ensinado as primeiras letras e números. Hoje, retribuo ajudando outros seres humanos a se desenvolverem pelo meio da educação, como me ensinaste. Pai, lamento não teres esperado um pouquinho mais para celebrar este momento e te abraçar. Te agradeço muito por todo teu apoio e inspiração de força e superação. Sei que está celebrando conosco este momento especial, junto à Deus.

Aos meu sogros Angelo e Flávia por todo o apoio em diversos momentos, tanto pelas palavras de incentivo quanto pelo apoio nos cuidados do nosso "anjinho" João Pedro. Obrigado Júlia e Guilherme também por estarem sempre por perto nos ajudando.

Ao meu orientador Prof. Dr. Jorge Barbosa, grande mestre e parceiro de caminhada acadêmica e profissional em diversas "frentes de batalha". Sabes que te considero um modelo de professor e pesquisador, no qual sempre vou me inspirar para ser e fazer o melhor pela educação, pela ciência e pela humanidade. Avante!

À Unisinos por todo o suporte e apoio em todos os momentos.

Obrigado à FAPERGS e ao CNPq por apoiarem parte desta pesquisa. Meu agradecimento especial à CAPES pela concessão da bolsa de doutorado-sanduíche via PrInt que possibilitou meu intercâmbio na *Friedrich-Alexander-Universität (FAU) Erlangen-Nürnberg*.

Ao PPGCA e todos os professores que fazem um trabalho de excelência, em especial aos professores Cristiano André da Costa (CAC) e Rodrigo da Rosa Righi. Obrigado CAC por todos os ensinamentos e apoio na jornada do doutorado-Sanduíche. Obrigado Righi por tuas sempre inspiradoras palavras de apoio e suporte incondicional como coordenador do PGGCA e como colega/amigo. Vocês foram fundamentais para que minha experiência na FAU fosse possível em meio a uma pandemia global.

Obrigado ao Prof. Dr. Björn Eskofier e a todo o time do *Machine Learning and Data Analytics Lab (MaDLab)* da FAU pelas oportunidades de aprendizado e experiência internacional. *Danke Schön!*

Obrigado a todos os colegas professores e coordenadores de cursos da computação da Unisinos, por todo o suporte e parceria durante o período deste doutorado.

A todos os alunos, bolsistas, colegas, pesquisadores, professores e colaboradores da Unisinos e FAU que de algum modo contribuíram para que eu chegasse até aqui.

A todos os amigos e colegas de Nova Acrópole pelo compartilhamento desta parte de nossa trilha filosófica. Em especial, aos queridos Fernando Zenker e Bárbara Regina Klimiuk Siniaglia pela compreensão e suporte durante todos estes anos.

Obrigado aos meus irmãos Suelen e Eguinaldo, a todos os demais amigos e familiares não nominados aqui, mas que de algum modo me acompanharam nesta experiência.

Muito Obrigado!

“A simplicidade é o último grau da sofisticação.”
(Leonardo da Vinci)

RESUMO

Segundo dados da Organização Mundial da Saúde (OMS), em torno de 8% do total das mortes no mundo, aproximadamente 5 milhões/ano, são resultantes de causas externas. Estas causas podem ser intencionais, tais como homicídio com arma de fogo, ou não intencionais, sendo os acidentes domésticos como queda ou choque elétrico, os mais frequentes. Estes acidentes afetam principalmente as Pessoas com Autonomia Reduzida (PAR), como, por exemplo, idosos, crianças e Pessoas com Deficiência (PCD). Embora os protocolos e padrões da área médica tenham evoluído de modo a auxiliar no diagnóstico e mapeamento destes acidentes, observam-se ainda lacunas no suporte efetivo à prevenção destes incidentes de saúde. Pela perspectiva tecnológica, o desenvolvimento acelerado das últimas décadas vem proporcionando a aplicação da Internet das Coisas (*Internet of Things, IoT*), o uso de *wearables* e o desenvolvimento de ambientes inteligentes que contribuem para o monitoramento das atividades das pessoas, identificação de padrões ou detecção de acidentes, tais como quedas. Entretanto, embora a detecção de eventos possa colaborar para agilizar o atendimento médico e minimizar as consequências de um trauma, esta abordagem segue um modelo reativo pós-trauma. Em contrapartida, esta tese apresenta o modelo Apollo, que realiza a predição de acidentes baseando-se em históricos de contextos das PAR em ambientes inteligentes. O Apollo contribui cientificamente para a prevenção de incidentes por causas externas a partir da identificação de riscos e predição de acidentes, aplicando a abordagem dos cuidados ubíquos em ambientes inteligentes, contando ainda com o suporte de robôs de serviço. O modelo Apollo emprega algoritmos de aprendizado de máquina supervisionados para a detecção e classificação de riscos, em base aos históricos de contextos das PAR. Além disso, utiliza o modelo *Hidden Markov Model (HMM)* para a predição de acidentes. Complementarmente, a ontologia ApolloOnto foi projetada para formalizar o domínio da aplicação e estruturar os contextos processados. O Apollo *Simulator* foi implementado para a geração de *datasets* sintéticos que viabilizaram os experimentos. Para a avaliação da acurácia do Apollo foram modelados 15 cenários baseados em heurísticas e validados por 5 especialistas. Os cenários avaliados consideraram a predição de quedas de idosos, queimadura de surdos, choque elétrico e afogamento de crianças. A detecção de riscos atingiu *F1-score* médio de 97,9 %, enquanto a predição de acidentes obteve acurácia média de 100 %. Os resultados indicam a viabilidade e a efetividade do Apollo no suporte à predição de acidentes.

Palavras-chave: Computação Ubíqua. Cuidados Ubíquos. Ambientes Inteligentes. Robótica Ubíqua. Causas Externas Acidentais. Riscos à Saúde.

ABSTRACT

According to data from the World Health Organization (WHO), around 8% of all deaths in the world, approximately 5 million/year, are the result of external causes. These causes can be intentional, such as homicide with a firearm, or unintentional, with domestic accidents such as falling or electric shock being the most frequent. These accidents mainly affect People with Reduced Autonomy (PRA), such as the elderly, children, and People with Disabilities (PWD). Although protocols and standards in the medical field have evolved to assist in the diagnosis and mapping of these accidents, gaps in effective support for the prevention of these health incidents are still observed. From a technological perspective, the accelerated development of the last decades has provided the application of the Internet of Things, the use of wearables and the development of intelligent environments that contribute to the monitoring of activities of people, identifying patterns or detecting accidents such as falls. However, although the detection of events can help to expedite medical care and minimize the consequences of trauma, this approach follows a post-trauma reactive model. On the other hand, this thesis presents the Apollo model, which predicts accidents based on historical contexts of PRA in intelligent environments. Apollo scientifically contributes to external causes prevention by identifying risks and predicting accidents, applying the ubiquitous care approach in intelligent environments, and with the support of service robots. The Apollo model employs supervised machine learning algorithms for the detection and classification of risks, based on the historical contexts of the PRA. Furthermore, it uses the Hidden Markov Model (HMM) model for accident prediction. In addition, the ApolloOnto ontology was designed to formalize the application domain and structure the processed contexts. Apollo Simulator was implemented to generate synthetic datasets that made the experiments possible. For the evaluation of Apollo's accuracy, 15 scenarios were modeled based on heuristics and validated by 5 experts. The scenarios evaluated considered the prediction of falls of the elderly, burns of the deaf, electric shock, and drowning of children. Risk detection reached an average F1-score of 97.9 %, while accident prediction achieved an average accuracy of 100 %. The results indicate the feasibility and effectiveness of Apollo in supporting accident prediction.

Keywords: Ubiquitous Computing. Ubiquitous Healthcare. Smart Environments. Ubiquitous Robotics. Unintentional External Causes. Health Risks.

LISTA DE FIGURAS

1	Mapeamento dos principais fatores de risco para quedas de idosos.	28
2	Etapas do processo de filtragem.	42
3	Aplicação de ambientes inteligentes para os cuidados ubíquos.	43
4	Distribuição dos artigos selecionados por ano e local de publicação.	51
5	Visão Geral do modelo Apollo.	64
6	Arquitetura do modelo Apollo.	65
7	Rotinas de aglutinação e fuzziificação dos dados de sensoriamento no módulo Gerenciador de Contextos.	68
8	Diagrama SMA dos agentes do modelo Apollo.	73
9	ApolloOnto - Visão das superclasses no modo ramificado.	75
10	ApolloOnto - Visão geral da hierarquia estruturada.	76
11	ApolloOnto - Visão ramificada das classes <i>Risco</i> e <i>Acidente</i> com suas respectivas instâncias.	77
12	ApolloOnto - Visão ramificada da classe <i>Contexto</i> e suas subclasses.	78
13	Tela do simulador Gazebo utilizado para modelagem e simulação do <i>ApolloBot</i>	81
14	Tela principal do <i>Apollo Simulator</i>	83
15	Recorte de parte de <i>dataset</i> de classificação multiclasse gerado pelo <i>Apollo Simulator</i>	84
16	Metodologia de avaliação de contextos de riscos e acidentes do modelo Apollo.	85
17	Resumo da lista dos 28 atributos relativos às 1.152 amostras utilizadas para os modelos de <i>machine learning</i>	90
18	Síntese da preparação do <i>dataset</i> com categorização binária para processamento dos modelos de <i>machine learning</i>	97
19	Diagrama de transição de estados do modelo <i>HMM</i> elaborado baseando-se no <i>dataset</i> de históricos de contextos gerado pelo <i>Apollo Simulator</i>	98
20	Código-fonte do modelo <i>HMM</i> do Apollo considerando os valores computados para o <i>dataset</i> de históricos de contextos.	99
21	Equações utilizadas para o cálculo das métricas de <i>performance</i> do modelo <i>HMM</i> do Apollo.	99
22	Síntese da comparação entre os algoritmos supervisionados de <i>machine learning</i> para classificação binária das amostras.	99
23	Síntese da comparação entre os algoritmos supervisionados de <i>machine learning</i> para classificação multiclasse das amostras.	100
24	Listagem dos hiperparâmetros processados para a obtenção do modelo de <i>machine learning Random Forest</i> para o <i>dataset</i> com classificação binária com melhor performance média geral.	100
25	Listagem dos hiperparâmetros processados para a obtenção do modelo de <i>machine learning Random Forest</i> para o <i>dataset</i> com classificação multiclasse com melhor performance média geral.	100
26	Métricas individuais, médias e desvios padrão obtidos para o processamento dos 10 segmentos do modelo <i>Random Forest</i> aplicado ao <i>dataset</i> de classificação binária aplicando os parâmetros de melhor performance média geral.	101
27	Métricas individuais, médias e desvios padrão obtidos para o processamento dos 10 segmentos do modelo <i>Random Forest</i> aplicado ao <i>dataset</i> de classificação multiclasse aplicando os parâmetros de melhor performance média geral.	101

28	Gráfico de relação dos atributos mais importantes para o modelo <i>Random Forest</i> com classificação binária com melhor performance média.	101
29	Gráfico de relação dos atributos mais importantes para o modelo <i>Random Forest</i> com classificação multiclasse com melhor performance média.	102
30	Matriz de confusão resultante do processamento do modelo <i>Random Forest</i> com classificação binária com melhor performance média.	102
31	Matriz de confusão resultante do processamento do modelo <i>Random Forest</i> com classificação multiclasse com melhor performance média.	103
32	Gráfico da curva ROC resultante do processamento do modelo <i>Random Forest</i> com classificação binária com melhor performance média.	103
33	Gráfico do relatório de classificação resultante do modelo <i>Random Forest</i> com classificação binária com a melhor performance média.	104
34	Gráfico do relatório de curva de precisão e <i>recall</i> resultante do modelo <i>Random Forest</i> com classificação binária com melhor performance média.	105
35	Gráfico do relatório de curva de precisão e <i>recall</i> resultante do modelo <i>Random Forest</i> com classificação multiclasse com melhor performance média.	105
36	Resultados do processamento do modelo preditivo <i>HMM</i> do Apollo para o cenário de teste 1 (CT1).	106
37	Resultados do processamento do modelo preditivo <i>HMM</i> do Apollo para o cenário de teste 2 (CT2).	106
38	Resultados do processamento do modelo preditivo <i>HMM</i> do Apollo para o cenário de teste 3 (CT3).	106
39	Resultados do processamento do modelo preditivo <i>HMM</i> do Apollo para o cenário de teste 4 (CT4).	106
40	Resultados do processamento do modelo preditivo <i>HMM</i> do Apollo para o cenário de teste 5 (CT5).	107
41	Resultados da avaliação da acurácia do modelo <i>HMM</i> do Apollo.	107

LISTA DE TABELAS

1	Questões de pesquisa.	39
2	Termos da <i>string</i> de busca.	39
3	Bases de dados pesquisadas.	40
4	Lista de Critérios de Inclusão (CI) e Critérios de Exclusão (CE).	41
5	Distribuição dos artigos selecionados por tipo de classificação.	44
6	Distribuição dos artigos selecionados por escopo.	44
7	Distribuição dos artigos selecionados por tecnologia.	46
8	Distribuição das tecnologias em % dos artigos selecionados por grupo de fator de impacto (FI).	47
9	Distribuição dos artigos selecionados por uso de modelo.	48
10	Distribuição dos artigos selecionados por doença.	48
11	Distribuição dos artigos selecionados por grupo.	49
12	Conferências (C) e <i>Journals</i> (J) onde os artigos têm sido publicados.	57
13	Comparativo entre os trabalhos relacionados.	58
14	Síntese do <i>dataset</i> gerado pelo <i>Apollo Simulator</i> para treinamento dos modelos de <i>machine learning</i>	88
15	Distribuição das amostras de cenários por tipo de risco mapeado presentes no <i>dataset</i> gerado pelo <i>Apollo Simulator</i> para treinamento dos modelos de <i>machine learning</i>	89
16	Distribuição das amostras de cenários por perfil mapeado no <i>dataset</i> gerado pelo <i>Apollo Simulator</i> para treinamento dos modelos de <i>machine learning</i>	89
17	Normalização dos Estados Ocultos e Eventos Observáveis do <i>HMM</i> do modelo <i>Apollo</i>	92
18	Artigos selecionados a partir do mapeamento sistemático.	134
19	Cenários desenvolvidos com base na literatura.	139
20	Perfil dos cuidadores entrevistados.	145
21	Relação de cenários validados por cuidador.	145
22	Descrição dos atributos da estrutura do dicionário do <i>Apollo Simulator</i> baseado na ontologia <i>ApolloOnto</i>	146
23	Dados da estrutura de dicionário do <i>Apollo Simulator</i> baseado na ontologia <i>ApolloOnto</i>	148
24	Cenários-base utilizados para geração de instâncias de históricos de contextos do modelo <i>Apollo</i>	157
25	Cenários de teste utilizados para a avaliação da acurácia preditiva do modelo <i>HMM</i> , considerando instâncias de históricos de contextos de PARs modelados e gerados pelo <i>Apollo Simulator</i>	159

LISTA DE ABREVIATURAS

Classif.	Classificação
monit.	monitoramento
Tecnol.	Tecnologia
<i>U-Health</i>	<i>Ubiquitous Healthcare</i>

LISTA DE SIGLAS

AI	Ambiente Inteligente
AAL	<i>Ambient Assistive Living</i>
API	<i>Application Programming Interface</i>
AS	<i>Ambient Sensor</i>
CAPES	Coordenação de Aperfeiçoamento de Pessoal de Nível Superior
CICEL	Classificação Internacional de Causas Externas de Lesões
CID	Classificação Internacional de Doenças
CIF	Classificação Internacional de Funcionalidade, Incapacidade e Saúde
EP	Estado Postural
FAPERGS	Fundação de Amparo à Pesquisa do Estado do Rio Grande do Sul
HMM	<i>Hidden Markov Model</i>
IA	Inteligência Artificial
ICD	<i>International Classification of Diseases</i>
ICECI	<i>International Classification of External Causes of Injury</i>
ICF	<i>International Classification of Functioning, Disability and Health</i>
IoT	<i>Internet of Things</i>
IoHT	<i>Internet of Health Things</i>
IoMT	<i>Internet of Medical Things</i>
JSON	<i>JavaScript Object Notation</i>
ML	<i>Machine Learning</i>
ODS	Objetivos de Desenvolvimento Sustentável
OMS	Organização Mundial da Saúde
ONU	Organização das Nações Unidas
PAR	Pessoas com Autonomia Reduzida
PCD	Pessoas com Deficiência
PCDA	Pessoas com Deficiência Auditiva
SR	<i>Service Robot</i>
U-Healthcare	<i>Ubiquitous Healthcare</i>
URDF	<i>Unified Robotic Description Format</i>
W	<i>Wearable</i>
WS	<i>Web Service</i>
WHO	<i>World Health Organization</i>
XML	<i>eXtensible Markup Language</i>

LISTA DE SÍMBOLOS

° Graus

SUMÁRIO

1	INTRODUÇÃO	17
1.1	Motivação	19
1.2	Problema	19
1.3	Questão de Pesquisa	20
1.4	Hipótese	21
1.5	Objetivos	21
1.6	Metodologia	22
1.7	Contribuições Científicas	23
1.8	Organização da Tese	24
2	FUNDAMENTAÇÃO TEÓRICA	26
2.1	Pessoas com Autonomia Reduzida (PAR)	26
2.2	Causas Externas de Morbidade e Mortalidade	29
2.3	Contexto, Históricos de Contextos e Predição de Contextos	30
2.4	Cuidados Ubíquos	32
2.5	Ambientes Inteligentes	33
2.6	Robôs de Serviço	35
3	TRABALHOS RELACIONADOS	36
3.1	<i>Surveys, Revisões e Mapeamentos Sistemáticos sobre Ambientes Inteligentes e Cuidados Ubíquos</i>	36
3.2	Metodologia do Mapeamento Sistemático	37
3.2.1	Questões de Pesquisa	38
3.2.2	Processo de Pesquisa	38
3.2.3	Processo de Seleção	40
3.2.4	Análise e Classificação dos Artigos Seleccionados	41
3.3	Discussão sobre o Mapeamento Sistemático	50
3.4	Estado da Arte	52
3.4.1	<i>Situation Awareness in Ambient Assisted Living for Smart Healthcare</i>	53
3.4.2	<i>Multi-level Assessment Model for Wellness Service Based on Human Mental Stress Level</i>	53
3.4.3	<i>Decision Making in Assistive Environments Using Multimodal Observations</i>	54
3.4.4	<i>An Improved Extreme Learning Machine Model for the Prediction of Human Scenarios in Smart Homes</i>	54
3.4.5	<i>Design of a Predictive Scheduling System to Improve Assisted Living Services for Elders</i>	55
3.4.6	<i>DOMUS: A Domestic Ontology Managed Ubiquitous System</i>	55
3.4.7	<i>Heath-PRIOR: An Intelligent Ensemble Architecture to Identify Risk Cases in Healthcare</i>	55
3.4.8	<i>Ambient and Wearable Sensor Fusion for Abnormal Behaviour Detection in Activities of Daily Living</i>	56
3.4.9	Comparativo	56
4	MODELO APOLLO	60
4.1	Conceitos Envolvidos no Trabalho	60
4.1.1	Risco	60
4.1.2	Acidente	61

4.1.3	Pessoa com Autonomia Reduzida (PAR)	61
4.1.4	Ambiente Inteligente (AI)	61
4.1.5	Contexto	61
4.1.6	Ontologia	62
4.2	Visão Geral	62
4.3	Arquitetura	63
4.4	Componentes do Modelo	66
4.4.1	Camada Servidor	66
4.4.2	Camada de Consumo	71
4.4.3	Camada de Provisionamento	72
4.5	ApolloOnto	74
5	ASPECTOS DE IMPLEMENTAÇÃO E AVALIAÇÃO	79
5.1	Artefatos de Software	79
5.1.1	Servidor Apollo	79
5.1.2	Interfaces de Provisionamento	80
5.1.3	Interfaces de Consumo	81
5.1.4	ApolloOnto	82
5.1.5	Apollo Simulator	82
5.2	Avaliação da Acurácia de Detecção de Riscos e Predição de Acidentes Baseada em Contextos Sintéticos	84
5.2.1	Detecção de Riscos	88
5.2.2	Predição de Acidentes	91
5.3	Resultados	93
5.3.1	Avaliação da Acurácia de Detecção de Riscos e Predição de Acidentes Baseada em Contextos Sintéticos	93
6	DISCUSSÃO	108
6.1	Contribuições do Mapeamento Sistemático da Literatura	108
6.2	Avaliação da Acurácia de Detecção de Riscos e Predição de Acidentes Baseada em Contextos Sintéticos	111
6.2.1	Detecção de Riscos	111
6.2.2	Predição de Acidentes	112
6.3	Limitação da Pesquisa	112
7	CONSIDERAÇÕES FINAIS	114
7.1	Conclusão	114
7.2	Contribuições Científicas do Modelo Apollo	115
7.3	Contribuições Acadêmicas e Publicações	116
7.4	Trabalhos Futuros	119
	REFERÊNCIAS	121
	APÊNDICE A – INFORMAÇÕES COMPLEMENTARES	134

1 INTRODUÇÃO

Segundo dados da Organização Mundial da Saúde (OMS), em torno de 8% do total das mortes no mundo, aproximadamente 5 milhões/ano, são resultantes de causas externas (WHO, 2021a). As causas externas, de acordo com a Classificação Estatística Internacional de Doenças e Problemas Relacionados à Saúde, 10ª revisão (CID-10) (WHO, 2019a), nos Capítulos XIX e XX, podem ser subdivididas em intencionais (consideradas como “violência”, por exemplo, homicídio com arma de fogo) ou não intencionais (classificadas como “acidentes”, por exemplo, choque elétrico). Esta classificação, a partir de janeiro de 2022, será atualizada para a versão 11 (CID-11) (WHO, 2022a), tendo os Capítulos 22 e 23 como referenciais para o mapeamento das causas externas de morbidade e mortalidade.

Particularmente, no Brasil, entre 2010 e 2015, a mortalidade por causas externas representou o terceiro principal motivo de óbitos, com índice de 8,1%, superado apenas pelas doenças do aparelho circulatório e neoplasias (tumores). Consta-se ainda que, sobretudo nos últimos anos, houve um aumento expressivo de mortes enquadradas nesta categoria (DATASUS, 2022).

De modo geral, a epidemiologia das causas externas aponta para uma maior frequência de eventos não intencionais, tais como asfixia, quedas, queimaduras, choque elétrico e consumo incorreto de medicamentos (IMAMURA, 2022). Além disso, quando as estatísticas são analisadas pela perspectiva da faixa etária, observa-se em destaque que crianças com até 9 anos de idade têm um alto índice de morbimortalidade por conta de acidentes domésticos, tais como asfixia, sufocamento, queimadura e afogamento, representando a principal causa de óbito para este grupo (PEDIATRIA, 2022).

Os idosos representam outra parte da população que também sofrem com um alto índice de morbidade por causas externas, especialmente quedas, que geralmente resultam em traumas permanentes (VARELLA, 2022). De acordo com a OMS (WHO, 2022b), anualmente 684 mil pessoas morrem por consequência de quedas, sendo a segunda principal causa de mortes acidentais no mundo. De modo que em torno de 80% destes acidentes acontecem em países com baixa ou média renda *per capita*, ou seja, nações menos desenvolvidas economicamente. Além disso, anualmente em torno de 38 milhões de quedas severas ocorrem no mundo, demandando hospitalização e altos custos financeiros para a viabilização dos tratamentos médicos.

Complementarmente, as pesquisas indicam que o próprio domicílio é o principal local de ocorrência de morbidade acidental, de modo que parte destes traumas poderiam ser evitados, se houvesse planejamento e monitoramento das pessoas, especialmente as pessoas com autonomia reduzida. As Pessoas com Autonomia Reduzida (PAR) são aquelas que, devido à idade ou doença congênita ou adquirida, apresentam uma redução das suas capacidades normais e, consequentemente, têm sua autonomia reduzida de modo temporário ou permanente, enquadrando-se neste grupo, idosos, crianças, pessoas com deficiência e gestantes (TRABALHO, 2022), por exemplo.

Em contrapartida, nas últimas décadas, houveram avanços significativos no desenvolvi-

mento de protocolos para prevenção de acidentes no atendimento de urgência e emergência para estes incidentes pela área médica. Além da CID-10 (WHO, 2019a) e CID-11 (WHO, 2022a), a OMS implementou a Classificação Internacional de Funcionalidade, Incapacidade e Saúde (CIF, ou *ICF* em inglês) (WHO, 2022c), que serve como classificação complementar à CID-10 e à CID-11, especialmente quando os acidentes envolvem Pessoas com Deficiência (PCD). Especificamente no que tange às causas externas, em 2004, foi lançada a Classificação Internacional de Causas Externas de Lesões (CICEL, ou *ICECI* em inglês), dada a necessidade de qualificação no diagnóstico e no acompanhamento do crescente número de incidentes por causas externas (WHO, 2022d). Além disso, protocolos para auxílio ao diagnóstico e atendimento de emergência foram criados para aprimorar o suporte aos casos mais críticos de morbidade por causas externas (WHO, 2022d,b).

Pela perspectiva tecnológica, a evolução expressiva e acelerada que vem acontecendo nos últimos anos no desenvolvimento e no aprimoramento de novas tecnologias, tem tornado possível a utilização de pequenos dispositivos inteligentes voltados para o auxílio nos cuidados de saúde de modo contínuo e desvinculados da clínica médica ou de hospitais. Este paradigma centrado no usuário e em suas necessidades é chamado de *Internet of Health Things (IoHT)* (COSTA et al., 2018). Além disso, o uso de *smartphones* e pequenos computadores vestíveis de propósito geral, chamados de *wearables*, tais como *smartwatches*, contribuem para a coleta de dados móvel de modo transparente para o usuário. Deste modo, sinais vitais, bem como dados de movimento e localização dos usuários, podem ser obtidos continuamente. Este *status* tecnológico vem oportunizando a concretização da visão de computação ubíqua “invisível” e “onipresente” projetada por Mark Weiser em 1991 (WEISER, 1991). Posteriormente, em 2001, Mahadev Satyanarayanan definiu este paradigma como computação pervasiva, detalhando ainda mais os seus aspectos tecnológicos (SATYANARAYANAN, 2001).

Nas últimas décadas também houveram avanços do ponto de vista da automação dos ambientes físicos, habilitando-se a integração de tecnologias transformam casas e escritórios em ambientes inteligentes, por exemplo. Os ambientes inteligentes são locais dotados de sensores, atuadores e interfaces acessíveis de usuário que, conjugados com *softwares* que empregam métodos de inteligência artificial e computação em nuvem, permitem auxiliar de modo proativo os usuários em suas Atividades da Vida Diária (AVD) (SADRI, 2011). A convergência destas tecnologias orientadas para os cuidados de saúde das pessoas viabilizam a concretização do paradigma chamado de cuidados ubíquos (*Ubiquitous Healthcare*, em inglês) (ROSA TAVARES; VICTÓRIA BARBOSA, 2020; CONNELLY et al., 2017; ACAMPORA et al., 2013).

Neste sentido, priorizando-se o tema da saúde, inclusive, a Organização das Nações Unidas (ONU) vem conduzindo em escala global o programa *Objetivos de Desenvolvimento Sustentável* (ODS), que particularmente em seu *Objetivo 3* trata de "Saúde e Bem-estar" (ONU, 2022). Esta é uma iniciativa que visa a redução dos índices de morbimortalidade, promovendo mais qualidade de vida e bem-estar às pessoas, a partir de um plano de ações recomendado. Portanto,

em base a este desafio global e de real necessidade, esta tese contribui tecnologicamente e socialmente para a promoção da saúde, especialmente evitando que acidentes ocorram de modo a preservar vidas humanas.

1.1 Motivação

Diante deste cenário, observou-se a oportunidade de apoiar a prevenção da morbidade por causas externas não intencionais, a partir da aplicação de um modelo preditivo que considera o perfil (SPARREMBERGER et al., 2019) das pessoas com autonomia reduzida, em ambientes inteligentes (ROSA TAVARES; VICTÓRIA BARBOSA, 2020; SADRI, 2011), especialmente suas residências, baseando-se em históricos de contextos (FILIPPETTO; LIMA; BARBOSA, 2021a; MARTINI et al., 2021a; ARANDA et al., 2021a), visando-se a aplicação dos cuidados ubíquos (MACHADO et al., 2021; ROSA TAVARES; VICTÓRIA BARBOSA, 2020).

Portanto, apresenta-se nesta tese o modelo Apollo¹, que a partir da coleta de dados de dispositivos usados pela pessoa e instalados no ambiente, permite a predição de riscos à saúde por causas externas acidentais. O Apollo é um modelo adaptativo quanto à disponibilidade das fontes de dados e considera os históricos de contextos para a predição de acidentes nas atividades das pessoas no ambiente inteligente. As PAR ou seus cuidadores são notificados dos riscos via interface acessível e mais adequada por conta de suas limitações. Além disso, familiares e cuidadores podem participar da gestão da saúde das PAR acompanhando cotidianamente suas rotinas. Finalmente, o modelo Apollo contempla a integração de robôs de serviço com o ambiente inteligente, possibilitando que estes agentes atuem de modo proativo, seja colaborando para a prevenção de acidentes, removendo objetos ou desativando recursos, seja interagindo com os usuários, orientando-os dos riscos ou ainda acionando os serviços de emergência.

1.2 Problema

Segundo pesquisas (IMAMURA, 2022; PEDIATRIA, 2022), a maioria dos traumas sofridos por crianças e idosos têm origem em causas externas não intencionais ou acidentais. A maioria destes acidentes ocorrem em ambientes fechados, normalmente no próprio domicílio (VARELLA, 2022). Por outro lado, existem padrões, protocolos e recomendações internacionais para a prevenção da morbimortalidade por causas externas (WHO, 2019a, 2022a,c,d). Além disso, existem técnicas e tecnologias que possibilitam o suporte aos cuidados de saúde em ambientes inteligentes que podem contribuir para a automação dessas medidas de prevenção.

Considerando estes cenários para a predição de riscos à saúde, alguns desafios são apresentados, como: o gerenciamento dos históricos de contextos das pessoas; a identificação de riscos à saúde por causas externas; a predição tempestiva e eficaz de acidentes; a gestão dinâmica de contextos de acordo com mudanças do perfil, de suas necessidades e de contexto; a atuação no

¹O deus olímpico da mitologia grega, sendo considerado o deus da cura, dentre outras virtudes. Grafia adaptada.

ambiente inteligente de acordo com a predição de contextos através de interfaces acessíveis e robôs de serviço.

Neste sentido, projeta-se que o modelo Apollo gerencie dinamicamente as atividades das pessoas no ambiente inteligente e que ele atue proativamente para evitar os traumas externos acidentais, alertando os responsáveis e ativando/desativando recursos no ambiente, como por exemplo a desativação da alimentação da tomada elétrica quando uma criança se encontrar em risco de choque elétrico.

Dessa forma, a presente tese propõe utilizar como linha central de pesquisa a aplicação da predição de contextos (FILIPPETTO; LIMA; BARBOSA, 2021a; da Rosa; BARBOSA; RIBEIRO, 2016) para os cuidados ubíquos (ROSA TAVARES; VICTÓRIA BARBOSA, 2020) como estratégia para predição de ocorrências de acidentes que possam ocasionar traumas por causas externas acidentais, especialmente para PAR em ambientes inteligentes.

1.3 Questão de Pesquisa

Assim, a pesquisa buscou uma resposta para a seguinte questão de pesquisa geral:

“Como seria um modelo computacional para a detecção de riscos à saúde das pessoas com autonomia reduzida por causas externas acidentais e predição de acidentes em ambientes inteligentes baseado em históricos de contextos?”.

No âmbito dessa questão de pesquisa geral, surgem questões de pesquisa específicas:

- Como a identificação de riscos, baseada em análise de históricos de contextos pode auxiliar na prevenção de acidentes por causas externas à saúde das pessoas com autonomia reduzida?
- Como a predição de acidentes, baseada em identificação de riscos pode auxiliar na prevenção de morbidade e mortalidade por causas externas à saúde das pessoas com autonomia reduzida?
- Como os ambientes inteligentes, com sensoriamento e atuação, podem apoiar na redução de acidentes na redução da vulnerabilidade de pessoas com autonomia reduzida à exposição de riscos que possam prejudicar a sua saúde?
- Como os robôs de serviço em ambientes inteligentes podem contribuir proativamente para a prevenção de acidentes das pessoas com autonomia reduzida?
- Como a correlação entre o perfil da pessoa com autonomia reduzida e as estatísticas, padrões e protocolos da área da saúde, pode gerar parâmetros relevantes para a identificação de riscos por causas externas não intencionais?

1.4 Hipótese

Esta tese considera a hipótese de que um modelo baseado em históricos de contextos pode detectar riscos à saúde por causas externas acidentais e realizar a predição de acidentes, adaptando-se o provisionamento de dados e ações de acordo com os sensores e atuadores disponíveis no ambiente inteligente ou computadores vestíveis utilizados pelo usuário, empregando robôs de serviço ubíquos para interação com o usuário e apoio ao monitoramento.

Portanto, um modelo orientado aos cuidados ubíquos em ambientes inteligentes pode auxiliar na redução do número de acidentes, bem como educar e recomendar ações que beneficiem a manutenção da saúde das pessoas com autonomia reduzida, prevenindo acidentes originados por causas externas e apoiando na promoção do seu bem-estar, com vistas à efetivação da visão de saúde integral proposta pela OMS (WHO, 2022e).

1.5 Objetivos

O objetivo geral desta tese consiste em propor um modelo computacional baseado no processamento de históricos de contextos que permita a identificação de riscos e a predição de acidentes que possam afetar a saúde das pessoas com autonomia reduzida em ambientes inteligentes, de modo adaptativo aos sensores e atuadores existentes e com interface de usuário acessível. Espera-se com isso, auxiliar as pessoas na prevenção de eventos que causem ocorrências de morbimortalidade acidentais relatados na literatura médica.

A partir do tema principal, são aprofundados assuntos em áreas específicas, como a predição de contextos (da Rosa; BARBOSA; RIBEIRO, 2016), históricos de contextos (MARTINI et al., 2021b)(ARANDA et al., 2021b)(FILIPPETTO; LIMA; BARBOSA, 2021b), ambientes inteligentes (ROSA TAVARES; VICTÓRIA BARBOSA, 2020; SADRI, 2011) aplicados aos cuidados ubíquos (ROSA TAVARES; VICTÓRIA BARBOSA, 2021) e os robôs de serviço (SANTOS et al., 2021; CHIBANI et al., 2013) para auxiliar na identificação de riscos à saúde das pessoas com autonomia reduzida por causas externas acidentais.

Nesse sentido buscou-se atingir os seguintes objetivos específicos:

- a) Realizar uma revisão bibliográfica sobre os temas: cuidados ubíquos; históricos e predição de contextos; padrões voltados para a área da saúde; tipos de morbimortalidade resultantes de causas externas não intencionais; estatísticas oficiais relacionadas às causas externas acidentais; ambientes inteligentes voltados para os cuidados ubíquos; robótica de serviço e ubíqua; educação ubíqua; e, como esses tópicos podem auxiliar na gestão dos riscos à saúde e na prevenção de acidentes;
- b) Realizar uma investigação do estado da arte sobre ambientes inteligentes orientados aos cuidados ubíquos;
- c) Criar um modelo para o apoio aos cuidados de saúde, que aplique o mapeamento e iden-

tificação de riscos externos associados às PAR nos ambientes inteligentes e a predição de acidentes durante sua execução, além de suportar a gestão dinâmica de riscos que engloba a inclusão, alteração e exclusão de pessoas, objetos e recursos dos ambientes inteligentes;

- d) Concentrar os estudos em tópicos específicos dos cuidados ubíquos, como históricos de contextos, predição de contextos, além de conceitos específicos relacionados à morbimortalidade por causas externas acidentais e ambientes inteligentes;
- e) Implementar protótipos e aplicá-los para avaliar a contribuição do modelo quanto à acurácia na identificação dos riscos à saúde das pessoas com autonomia reduzida. Pretende-se avaliar também a assertividade do modelo quanto à predição dos acidentes indesejados. Avaliar ainda a facilidade de uso e utilidade percebida pelo usuário quanto às aplicações que implementam interfaces de usuário especiais. Para tanto, será necessária a utilização do modelo Apollo em diferentes cenários que englobem atividades do cotidiano das PAR, bem como a avaliação da efetividade de seu uso em tais atividades, considerando diferentes perfis e riscos.

Para atingir estes objetivos, três requisitos devem ser cumpridos. O primeiro consiste na coleta de dados de contexto do usuário, tais como histórico de saúde, localização semântica, aceleração do movimento, sinais fisiológicos, entre outros. Estes dados são oriundos de diferentes fontes e dispositivos inteligentes. Podem ser coletados dos *smartphones* dos usuários por meio de sua geolocalização, por exemplo, ou tipo de atividade (parado ou caminhando, por exemplo). Podem originar-se ainda de *wearables* que coletam dados fisiológicos. O segundo consiste na coleta de dados do ambiente inteligente através de sensores que captam diferentes dados de contexto, tais como temperatura, umidade relativa do ar, luminosidade e presença de fumaça. O terceiro consiste em alimentar a base de dados com os padrões históricos de contextos de riscos, acidentes e indicadores de saúde para subsidiar a análise, inferência e predição de novos contextos.

1.6 Metodologia

A metodologia de pesquisa exploratória tem as características necessárias para lidar com escopos maiores (MALHOTRA, 2001), como neste trabalho. Logo, o primeiro passo desta pesquisa foi investigar na literatura como os riscos à saúde por causas externas não intencionais são tratados e como a computação pode apoiar para a detecção e predição destes acidentes.

Após a conclusão da revisão da literatura, um modelo computacional para suporte aos cuidados ubíquos em ambientes inteligentes foi projetado, com sua definição e sua implementação através de protótipos. Estes protótipos serviram como ferramentas para os testes de hipóteses realizados e aplicação dos conceitos apresentados para a predição de riscos à saúde por causas externas. Foram utilizados em diferentes cenários de ambientes inteligentes, a fim de avaliar a efetividade do modelo para a predição de riscos e suporte aos cuidados ubíquos.

Inicialmente o modelo foi testado com técnicas de simulação que geram resultados próximos a situações reais (AZIZA et al., 2016; CHIÊM; MACQ; SPEYBROECK, 2012), visando avaliar a acurácia na identificação de riscos. Posteriormente, os protótipos foram usados para avaliar a efetividade das funcionalidades propostas para a predição de acidentes.

Para isso, os seguintes passos foram adotados como método de pesquisa:

- a) Na primeira etapa, foram realizados estudos sobre os temas fundamentais da pesquisa desde levantamento dos riscos relacionados a causas externas acidentais ligados aos principais acidentes envolvendo PAR, até cuidados ubíquos, históricos de contextos, predição de contextos, ambientes inteligentes, inteligência artificial e robótica de serviço;
- b) A segunda etapa envolveu a pesquisa por trabalhos relacionados à predição de acidentes por causas externas não intencionais;
- c) A terceira etapa promoveu a criação de um modelo que suporte a detecção de riscos por causas externas acidentais e predição de acidentes, em ambientes inteligentes, através do uso de conceitos computacionais para seu auxílio;
- d) Após a definição do modelo, a quarta etapa consistiu na implementação de três protótipos que concretizam o modelo Apollo, simulando ambientes inteligentes, promovendo a predição de riscos com suporte de robôs ubíquos, atuando proativamente para a prevenção de riscos por causas externas;
- e) A partir da implementação dos protótipos, a quinta etapa viabilizou a simulação de cenários que contemplam AVDs, para os quais o modelo Apollo pode ser aplicado;
- f) Os experimentos foram realizados com base em dados sintéticos gerados pelo *Apollo Simulator*, uma aplicação desenvolvida no âmbito desta tese para geração de contextos, cuja aplicação viabilizou simulações sem a exposição de pessoas a riscos reais. O *Apollo Simulator* se baseou em heurística extraída da literatura especializada e validada por profissionais da área da saúde;
- g) A sexta etapa consistiu na documentação dos resultados obtidos pela avaliação da aplicabilidade do modelo para detecção de riscos por causas externas não intencionais e predição de acidentes, cobrindo os resultados, discussões, conclusões finais e oportunidades de trabalhos futuros.

1.7 Contribuições Científicas

Diante da pesquisa da literatura e análise do estado da arte, observou-se que o Apollo é o único modelo que congrega características que possibilitam a detecção de riscos à saúde por causas externas acidentais e predição de acidentes, baseando-se em históricos de contextos em

ambientes inteligentes e voltado para PAR, visando a manutenção da saúde e bem-estar dos usuários.

Portanto, observa-se que as principais contribuições científicas do modelo Apollo são:

- a) Um modelo computacional orientado à predição de acidentes que afetam a saúde de pessoas com autonomia reduzida em ambientes inteligentes, baseado em predição de contextos;
- b) Um modelo computacional orientado à detecção de riscos que afetam a saúde de pessoas com autonomia reduzida em ambientes inteligentes, baseado em detecção e classificação de contextos, utilizando algoritmos de aprendizado de máquina;
- c) Uma ontologia chamada ApolloOnto, que caracteriza o domínio da predição de acidentes para PAR em ambientes inteligentes;
- d) Apollo *Simulator*, um simulador para geração de contextos orientados a AVD que considera acidentes mais frequentes sofridos por PAR em suas residências;
- e) ApolloBot, uma interface para robô de serviço que aplica o paradigma de robótica ubíqua para suporte proativo no ambiente inteligente;

1.8 Organização da Tese

Esta tese está estruturada em sete capítulos, sendo que, no primeiro, encontra-se a introdução. Os demais capítulos são descritos a seguir:

- a) Capítulo 2: Fundamentação Teórica – trata dos conceitos utilizados neste trabalho. Neste capítulo, são descritos os conceitos referentes a causas externas de morbimortalidade, padrões relacionados da área da saúde, tais como, CID-10, CID-11, CIF e CICEL, além de estatísticas e protocolos oficiais. As características e necessidades específicas das pessoas com autonomia reduzida são descritas. São apresentados ainda, históricos de contextos, ambientes inteligentes, robótica de serviço e a visão de computação ubíqua aplicada aos cuidados de saúde;
- b) Capítulo 3: Trabalhos Relacionados – inicialmente é apresentado um mapeamento sistemático realizado na área de ambientes inteligentes aplicados para os cuidados ubíquos, visando a identificação de modelos que possuam relação com esta tese. Além disso, os trabalhos relacionados selecionados são estudados em detalhes e um comparativo entre eles é sintetizado em uma tabela comparativa;
- c) Capítulo 4: Modelo Apollo – neste capítulo é descrito o modelo para a detecção de riscos à saúde por causas externas acidentais e predição de acidentes, onde são definidas sua arquitetura, detalhes sobre cada módulo e componente, além de aspectos relacionados às estratégias de identificação de riscos e predição de acidentes;

- d) Capítulo 5: Aspectos de Implementação e Avaliação – o quinto capítulo apresenta aplicações desenvolvidas para a avaliação do modelo Apollo em diferentes cenários, com diferentes grupos de pessoas. Este capítulo é apresentado com o objetivo de contextualizar como o modelo Apollo pode ser aplicado para o apoio aos idosos, crianças e surdos. Além disso, a validação do modelo Apollo é realizada a partir de métricas de acurácia na detecção de riscos e predições de acidentes realizadas em cada cenário;
- e) Capítulo 6: Discussão – neste capítulo são discutidos os resultados e apresentados os avanços e contribuições científicas do modelo proposto em relação ao estado da arte, bem como as lacunas inicialmente identificadas, além de oportunidades mapeadas e aprendizados que ocorreram durante esta pesquisa;
- f) Capítulo 7: Considerações Finais – o último capítulo apresenta as considerações finais e trabalhos futuros, além de destacar as principais contribuições científicas obtidas ao longo do desenvolvimento desta tese, concretizadas em artigos publicados, experiências em colaboração com grupos de pesquisa internacionais e patentes registradas.

2 FUNDAMENTAÇÃO TEÓRICA

Este capítulo sistematiza os principais conceitos utilizados para o desenvolvimento do modelo apresentado nesta tese. O capítulo está dividido em seis seções principais. A Seção 2.1 aborda a definição de Pessoas com Autonomia Reduzida (PAR), para contextualização do público-alvo a ser suportado pelo modelo proposto nesta tese. Na Seção 2.2 são apresentados os fundamentos referentes às Causas Externas de Morbidade e Mortalidade. Na Seção 2.3 são apresentados os conceitos de contexto, históricos de contextos e predição de contextos com o objetivo de embasar a aplicação destes elementos como componentes centrais do modelo Apollo para a predição de acidentes. Na Seção 2.4 o tema Cuidados Ubíquos apresenta a abordagem da computação ubíqua voltada para os cuidados de saúde das pessoas de modo transparente. Na Seção 2.5 são apresentados os fundamentos e características dos Ambientes Inteligentes, com o intuito de mostrar como esta abordagem pode contribuir para a identificação de riscos e predição de acidentes externos à saúde das PAR. Por fim, a Seção 2.6 aborda o tema dos robôs de serviço.

2.1 Pessoas com Autonomia Reduzida (PAR)

De acordo com a Organização das Nações Unidas (ONU) (UN, 2022), a população mundial está envelhecendo. Em geral, os países estão vivenciando o aumento proporcional do número de idosos em suas populações. Projeta-se que o número de pessoas com mais de 60 anos dobre até 2050 e mais do que triplique até 2100, partindo de 962 milhões globalmente para 2,1 bilhões em 2050 e 3,1 bilhões, em 2100. O crescimento da quantidade de pessoas idosas está ocorrendo de modo mais acelerado que o de jovens. Os idosos podem enfrentar problemas, como a perda de autonomia, e, no longo prazo, estão sujeitos a contraírem doenças crônicas (ALAM; REAZ; ALI, 2012a).

Os idosos também sofrem de algumas causas conhecidas de morbidade e mortalidade, como quedas acidentais, ingestão de medicamentos incorretos, esquecimento do consumo de medicamentos, Amnésia e *Alzheimer*. Há também um aumento no número de pessoas que vivem sozinhas, que em geral, não abdicam de sua autonomia e independência (AL-AAMA, 2011). Portanto, estes idosos preferem ficar em suas casas ao invés de se transferirem para instituições de saúde quando precisam de cuidados especializados ou de acompanhamento continuado (MATTIMORE et al., 1997).

As estatísticas apontam ainda para a ocorrência anual de aproximadamente 40 mil mortes de idosos devido a quedas¹. Para os idosos com mais de 80 anos, a taxa de mortalidade associada

¹Queda foi definida como a mudança de uma posição para outra, de nível inferior, caracterizando uma síndrome geriátrica. No presente estudo, significa queda espontânea da própria altura ao solo ou para um nível inferior, caracterizando uma síndrome geriátrica. Inclui-se aqui a queda decorrente do processo de transferência (mudar de posição, como levantar da cama ou de uma cadeira). Ficam excluídas as quedas decorrentes de atividades físicas com risco de queda, principalmente práticas esportivas radicais e aquelas arriscadas, como subir em escadas para

a quedas é seis vezes mais alta do que aquela correspondente entre os idosos de 65 a 79 anos, por caírem mais vezes e serem mais frágeis. Nos Estados Unidos, a prevalência foi de 30%, aumentando para 50%, a partir dos 75 anos. A prevalência de quedas aumenta em subgrupos portadores de deficiência física (CUNHA; LOURENÇO, 2014).

No Brasil, diversos autores observaram prevalência entre 30% e 60%. A condição justificou o estudo por sua alta prevalência, suas consequências, sequelas e alto custo. Concluiu-se que a prevalência de queda entre os idosos varia de 14% (estudos populacionais europeus) até 50% ou mais em idosos acima de 80 anos internados em instituições de longa permanência. A identificação dos fatores de risco dependeu do ambiente, do perfil da população de estudo e do tipo de estudo (CUNHA; LOURENÇO, 2014).

Os fatores associados às quedas em idosos foram identificados através de revisões sistemáticas, tendo sido valorizados dois grupos: intrínsecos e extrínsecos. Os primeiros incluem fatores hemodinâmicos, uso de medicamentos, doenças neurológicas, doenças neurosensoriais e doenças osteomusculares. Entre os fatores de risco extrínseco, citou-se iluminação inadequada, piso escorregadio, objetos ou móveis em locais inadequados, além de escadas e rampas sem as devidas adaptações (DE ALMEIDA et al., 2012).

Com base nesta revisão da literatura, foi realizado o mapeamento das variáveis mais relevantes para a queda de idosos, diagramadas no mapa mental da Figura 1, que serviram de referência para a elaboração dos critérios de risco associados ao perfil dos idosos no desenvolvimento do modelo Apollo.

Além disso, a OMS informa que mais de 1 bilhão de pessoas vivem com deficiências em todo o mundo (WHO, 2019b). As causas mais comuns de deficiência incluem doenças crônicas, como diabetes, doenças cardiovasculares, câncer, lesões devido a acidentes de trânsito, conflitos, quedas, minas terrestres, deficiências mentais, defeitos congênitos, desnutrição, HIV / AIDS e outras doenças transmissíveis (WHO, 2019c). Complementarmente, houve um aumento na taxa de ocorrência de algumas doenças nos últimos anos, segundo a OMS. Principalmente doenças crônicas, como diabetes, obesidade e depressão, que exigem monitoramento contínuo (WHO, 2019c).

A acessibilidade, portanto, é um fator que deve ser considerado não somente para tornar os ambientes mais acessíveis e inclusivos como também mais seguros. Assim, este é um termo amplo que representa a inclusão da pessoa com deficiência na participação de atividades como o uso de produtos, serviços e informações. Os exemplos mais comuns de iniciativas são adaptações em prédios, com rampas de acesso para cadeira de rodas e banheiros adaptados para deficientes (CAMARADEPUTADOS, 2015).

Deste modo, pode-se afirmar que este é um atributo essencial para garantir a inclusão e a melhoria da qualidade de vida das pessoas, devendo estar presente nos espaços em geral, no transporte, na informação e na comunicação, inclusive nos sistemas e tecnologias da informação

trocar lâmpadas. Não serão consideradas outras causas de quedas, como as causas externas (acidentes, agressões) (CUNHA; LOURENÇO, 2014).

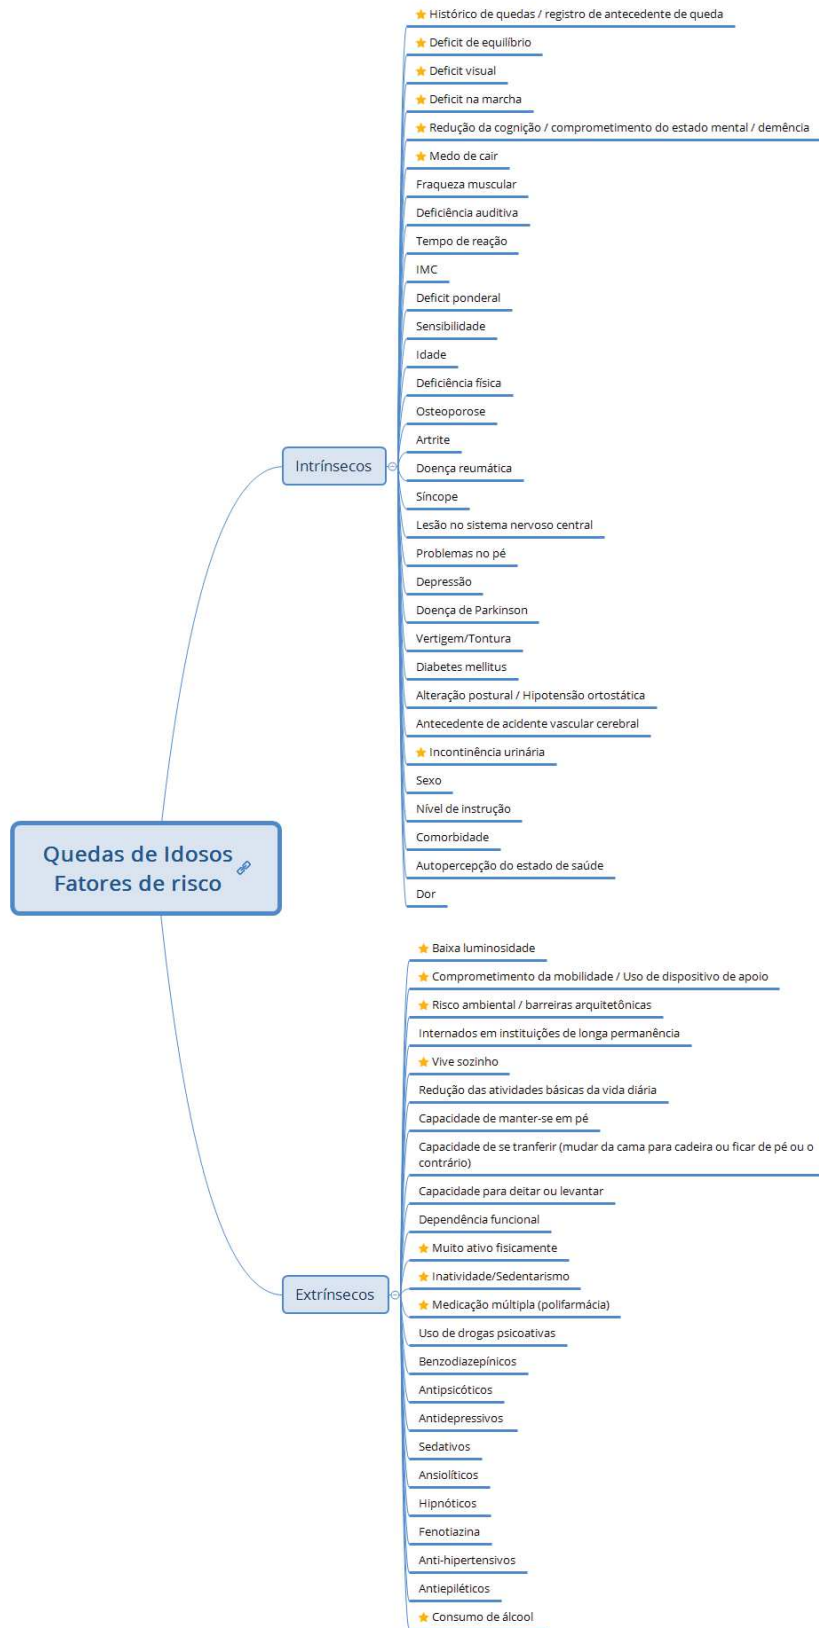


Figura 1 – Mapeamento dos principais fatores de risco para quedas de idosos.
Fonte: Adaptado de (DE ALMEIDA et al., 2012).

e comunicação (D. PUPO; A., 2006).

Além destes perfis, crianças, gestantes, pessoas com necessidades especiais e outros tipos de doenças podem ter sua capacidade funcional, cognitiva ou autonomia reduzidas de modo temporário ou permanente. No âmbito desta pesquisa, as pessoas que enquadram-se nestes critérios são consideradas Pessoas com Autonomia Reduzida (PAR).

2.2 Causas Externas de Morbidade e Mortalidade

As causas externas representam um dos principais fatores para a morbidade e mortalidade de pessoas globalmente. A OMS indica que aproximadamente 8% do total das mortes no mundo, ou aproximadamente 5 milhões/ano, são resultantes de causas externas (WHO, 2021a). Todavia, dada a amplitude e a quantidade de diferentes causas, a Classificação Estatística Internacional de Doenças e Problemas Relacionados à Saúde, 10ª revisão (CID-10) (WHO, 2019a), nos capítulos XIX e XX, subdivide as causas em intencionais (consideradas como “violência”, por exemplo, homicídio com arma de fogo) ou não intencionais (classificadas como “acidentes”, por exemplo, choque elétrico). Esta classificação, a partir de janeiro de 2022, será atualizada para a versão 11 (CID-11) (WHO, 2022a), tendo os capítulos 22 e 23 como referenciais para o mapeamento das causas externas de morbidade e mortalidade.

Especificamente, no que tange às causas externas, em 2004, foi lançada a Classificação Internacional de Causas Externas de Lesões (CICEL, ou *ICECI* em inglês), dada a necessidade de qualificação no diagnóstico e no acompanhamento do crescente número de incidentes por causas externas (WHO, 2022d). Além disso, a OMS implementou a Classificação Internacional de Funcionalidade, Incapacidade e Saúde (CIF, ou *ICF* em inglês) (WHO, 2022c), que serve como classificação complementar à CID, especialmente quando os acidentes envolvem Pessoas com Deficiência (PCD). Adicionalmente, protocolos para auxílio ao diagnóstico e ao atendimento de emergência vêm sendo implementados para aprimorar o suporte nos casos mais críticos de morbidade por causas externas (WHO, 2022d) (WHO, 2022b).

Somente no Brasil, entre 2010 e 2015, a mortalidade por causas externas representou o terceiro principal motivo de óbitos, com índice de 8,1%, superado apenas pelas doenças do aparelho circulatório e neoplasias (tumores). Constata-se ainda que, sobretudo nos últimos anos, houve um aumento expressivo de mortes enquadradas nesta categoria (DATASUS, 2022).

A epidemiologia das causas externas aponta para uma maior frequência de eventos não intencionais, tais como asfixia, quedas, queimaduras, choque elétrico e consumo incorreto de medicamentos (IMAMURA, 2022). Além disso, quando as estatísticas são analisadas pela perspectiva da faixa etária, observa-se em destaque, que crianças com até 9 anos de idade, têm um alto índice de morbimortalidade por conta de acidentes domésticos, tais como asfixia, sufocamento, queimadura e afogamento, representando a principal causa de óbito para esta grupo (PEDIATRIA, 2022).

Os idosos representam outra parte da população que também sofrem com um alto índice

de morbidade por causas externas, especialmente quedas, que geralmente resultam em traumas permanentes (VARELLA, 2022). De acordo com a OMS (WHO, 2022b), anualmente, 684 mil pessoas morrem por consequência de quedas, sendo que 80% destes acidentes acontecem nos países menos desenvolvidos economicamente. Além disso, anualmente em torno de 38 milhões de quedas severas ocorrem no mundo, demandando hospitalização e altos custos financeiros para viabilização dos tratamentos ambulatoriais e com internações hospitalares.

Complementarmente, as pesquisas indicam que o próprio domicílio é o principal local de ocorrência de morbidade acidental, de modo que parte destes traumas poderiam ser evitados, caso houvesse planejamento e acompanhamento das pessoas, especialmente das pessoas com autonomia reduzida. As pessoas com autonomia reduzida são aquelas que devido à idade e/ou à doença congênita ou adquirida apresentam uma redução das suas capacidades normais e, conseqüentemente, têm sua autonomia reduzida de modo temporário ou permanente. Enquadram-se neste grupo, por exemplo, idosos, crianças, pessoas com deficiência e gestantes (TRABALHO, 2022).

Ainda, de acordo com a OMS, a prevenção de acidentes passa pela gestão de riscos em diferentes contextos, especialmente, associando características das pessoas e dos ambientes em que se encontram, haja vista que os acidentes podem ocorrer tanto por fatores intrínsecos quanto por fatores ambientais. Neste sentido a gestão dos riscos consiste na identificação, análise, avaliação e estabelecimento de planos para minimizar os seus efeitos (DALTON, 2016).

A gestão de riscos é geralmente definida como um conjunto de princípios e práticas que visam identificar, analisar e gerar respostas aos fatores de risco com o objetivo de melhorar as chances de alcançar os resultados esperados (BANNERMAN, 2008). Segundo a norma ISO 31000 (ABNT, 2009), o grau de intensidade do risco pode ser classificado em leve, médio ou elevado. Esta classificação será adotada no decorrer desta tese para rotular os riscos acidentais associados a cada contexto mapeado.

2.3 Contexto, Históricos de Contextos e Predição de Contextos

Contexto pode ser considerado qualquer informação relevante para a interação entre o usuário e o ambiente em que ele se encontra (NARENDRA et al., 2005; DEY, 2001). Um sistema de computação ubíqua deve ser minimamente intrusivo, com ciência de seu contexto. O sistema deve estar a par do estado do usuário e do ambiente em que ele se encontra, e deve modificar seu comportamento de acordo com estas informações (SATYANARAYANAN, 2001).

O contexto de um usuário pode conter um número grande de informações, como, por exemplo, atributos do local físico, estado fisiológico, estado emocional, história pessoal, padrões de comportamento, dentre outros. Portanto, contextos são fragmentos de informação que podem ser usados para caracterizar a situação de um participante em uma interação (DEY, 2001).

Uma questão fundamental é obter informações diversas a respeito dos usuários e dos ambientes físicos, via *hardware* e *software*, para que funcione de uma maneira ciente de contexto.

Em determinados casos, as informações desejadas já podem fazer parte dos dados de computação pessoal do usuário.

Um ambiente ciente de contexto é constituído de aplicações que são executadas de acordo com a presença do usuário e seu comportamento, além de recursos transmitidos na rede (SATYANARAYANAN, 2001). Estas aplicações podem se adaptar ao ambiente físico, *hardware* e recursos de *software* disponíveis em determinado momento, sempre visando prover as melhores configurações de acordo com as experiências do usuário (DEY, 2001).

Informações de contexto são normalmente classificadas em três subconjuntos, chamados domínios de contexto (FOURNIER et al., 2006): domínio de usuário, domínio de sistema e domínio físico.

- O Domínio de usuário provê o conhecimento para que as aplicações possam se adaptar de acordo com o comportamento dos usuários;
- O Domínio de sistema descreve os recursos de *software* e *hardware* disponíveis aos usuários. As aplicações se utilizam das descrições e características dos dispositivos e recursos para adaptar o comportamento do sistema, alterar seu conteúdo ou modificar as interfaces para os usuários;
- Por fim, o Domínio físico ou ambiente trata da descrição do local e das condições do ambiente físico. A mobilidade do usuário ou uma variação natural das condições físicas podem alterar o comportamento de uma aplicação dentro de um ambiente ciente de contexto.

Os históricos de contextos registram atividades de entidades nos contextos percorridos, mantendo, assim, um histórico de seus deslocamentos e de sua atuação em cada contexto (SILVA et al., 2010).

Muitos dos sistemas cientes de contexto são reativos, isto é, eles adaptam suas decisões baseadas no contexto atual e nos históricos de contextos (DEY, 2001). Porém, diversos estudos têm se voltado para a predição de contextos (FILIPPETTO; LIMA; BARBOSA, 2021a; MARTINI et al., 2021a), onde, a partir de dados armazenados no histórico, utilizam-se de métodos para a previsão de um novo contexto. Assim, ocorre a predição de necessidades futuras, tornando o sistema proativo (VANSYCKEL; BECKER, 2014; D.; M.; C., 2015; PEJOVIC; MUSOLESI, 2015). O sistema passa a inferir sobre as intenções dos usuários, prevendo como será seu contexto no futuro e permitindo aos sistemas análises sobre esses novos cenários (BURBEY; MARTIN, 2012).

Algumas das técnicas utilizadas para prever o contexto utilizam dados históricos. Dessa forma além do contexto atual, faz-se necessário que tenham sido armazenadas informações sobre os contextos passados e que estas possam ser obtidas para que os dados sejam utilizados para prever contextos futuros (D.; M.; C., 2015; BURBEY; MARTIN, 2012).

2.4 Cuidados Ubíquos

Em 1991, Mark Weiser apresentou os princípios de uma visão para a computação ubíqua, intitulada como “invisível” e “onipresente”. Também apresentou alguns cenários que utilizariam, no futuro, este novo conceito (WEISER, 1991). Esse paradigma proposto por Weiser previa um ambiente de computação distribuído e integrado, saturado de dispositivos computacionais, onde a noção de computação pessoal como a utilizada atualmente desapareceria. O computador se tornaria parte de todo o ambiente através de diferentes dispositivos, como assistentes pessoais, roupas, utensílios domésticos, carros e outros.

Uma década depois, Satyanarayanan (SATYANARAYANAN, 2001) acrescentou que uma das visões da computação ubíqua, ou pervasiva, terminologia adotada por ele, é a criação de ambientes computacionais com grande capacidade de comunicação, que abarcam de uma forma inteligente a computação com os usuários. De acordo com Satyanarayanan (SATYANARAYANAN, 2001), a computação pervasiva incorpora quatro conceitos principais: espaços inteligentes, invisibilidade, escalabilidade localizada e mascaramento de condições desiguais.

A partir desses conceitos, a computação ubíqua pode ser descrita como ambientes saturados de dispositivos com grande capacidade computacional onde o usuário, muitas vezes, se utiliza da computação sem que perceba devido às características dos sistemas. Um ponto chave para definição diz respeito à adaptação dos sistemas para que estes possam se tornar dinâmicos a partir das necessidades dos usuários, criando o conceito de espaços inteligentes (VANSYCKEL; BECKER, 2014).

Espaços inteligentes se referem à utilização da infraestrutura computacional existente em um local de forma a aperfeiçoar seu uso no ambiente por seus usuários. A invisibilidade é caracterizada pela capacidade de um sistema ubíquo não ser percebido enquanto é utilizado. A escalabilidade localizada apresenta a teoria de que, em um ambiente ubíquo, a demanda por recursos fisicamente próximos é maior do que por recursos distantes. E o mascaramento de condições desiguais mostra que, pela possibilidade de existirem ambientes com menor capacidade de recursos que outros, o ambiente pessoal do usuário deve compensar esta carência, possibilitando, assim, que a mudança de ambiente não seja percebida pelo usuário (SATYANARAYANAN, 2001).

WEISER (1991) descreve a computação ubíqua como o conceito de computadores que “se espalham pela teia da vida cotidiana até que eles não se distingam dela”. Ele acreditava que a ubiquidade é a chave para fornecer ambientes eficazes, flexíveis e convenientes. Nesse sentido, o uso de *smartphones*, *wearables* e dispositivos *IoT* estão crescendo rapidamente (ALBERTI et al., 2017), especialmente quando aplicados a cuidados com a saúde e bem-estar (VIANNA; BARBOSA, 2019). Cresce também o desenvolvimento de redes de sensores sem fio (*Wireless Sensor Networks*, *WSN*) ou redes de sensores corporais (*Body Sensor Networks*, *BSN*), que fornecem suporte para a comunicação entre esses dispositivos na rede local ou com a nuvem (ROSA TAVARES; VICTÓRIA BARBOSA, 2020; OGUNDUYILE; OLUGBARAB; LALL,

2013).

A convergência de diferentes tecnologias aplicadas à saúde deu origem ao termo “Cuidados Ubíquos” (*Ubiquitous Healthcare, U-Healthcare*) (OGUNDUYILE; OLUGBARAB; LALL, 2013). A *U-Healthcare* pode atuar na coleta, no acompanhamento e apoio ao diagnóstico, na prevenção de doenças e na promoção do bem-estar e qualidade de vida (VIANNA; BARBOSA, 2019), auxiliando na promoção da saúde integral das pessoas, que, segundo a OMS (2021), definiu-se: “a saúde é um estado de completo bem-estar físico, mental e social, e não consiste apenas na ausência de doença ou enfermidade”. Em termos gerais, cuidados ubíquos podem ser entendidos como o suporte à saúde de modo contínuo, transparente e proativo, orientado ao paradigma ubíquo. Trata-se da aplicação da tecnologia a favor da prevenção, manutenção ou aprimoramento da saúde das pessoas, considerando seu histórico, seu estado atual e os cenários futuros (ROSA TAVARES; VICTÓRIA BARBOSA, 2020, 2021).

O uso da computação ubíqua para conduzir soluções voltadas para a saúde (*u-health*) e bem-estar (*wellness*) das pessoas é o objetivo da *U-Healthcare* (também utiliza-se a terminologia *P-Healthcare*) ou *U-Medicine* (adota-se alternativamente o termo análogo *P-Medicine*) (KIM; KIM; LEE, 2008). Segundo LITTLE; BRIGGS (2009), muitas aplicações que seguem o paradigma da *P-Healthcare* têm sido empregados para monitorar e auxiliar nos cuidados com a saúde e o acompanhamento domiciliar de idosos.

2.5 Ambientes Inteligentes

O termo *Ambient Intelligence (AmI)* foi criado em 2001 pela *European Community's Information Society Technology (ISTAG)*, sendo desde então aprofundado e aplicado ao redor do mundo para diversas áreas de pesquisa. *AmI* é a visão de futuro em que os ambientes passam a apoiar as pessoas que os habitam (ROSA TAVARES; VICTÓRIA BARBOSA, 2020; SADRI, 2011).

Segundo SADRI (2011), o ambiente inteligente é discreto, interconectado, adaptável, dinâmico e adota tecnologia embarcada. Nesta visão, o computador tradicional, com entrada e saída convencionais, deverá desaparecer. Entretanto, sensores e microcontroladores serão integrados nos objetos do cotidiano, provendo a computação por interface natural.

Não obstante, o *AmI* é sensível às necessidades dos seus habitantes e capaz de antecipar suas necessidades e comportamentos. Ele é ciente dos requisitos e preferências pessoais e interage com as pessoas de uma forma “amigável”, inclusive sendo capaz de expressar, reconhecer e responder a emoções (ROSA TAVARES; VICTÓRIA BARBOSA, 2020).

A ampliação da abordagem ubíqua, associada às técnicas de computação em nuvem e inteligência artificial (IA), promovem o paradigma *Ambient Intelligent (AmI)* ou *Smart Environment* (SADRI, 2011), como *Smart Cities* (ROSTIROLLA et al., 2018), que oferecem serviços inteligentes aos usuários em uma cidade. *AmI* permite expandir as capacidades humanas, através de ambientes com uma capacidade computacional de detecção e atuação, de forma

adaptativa e responsiva, apoiando as necessidades e preferências dos usuários (SADRI, 2011).

A visão do *AmI* pode ser vista como a convergência de pelo menos três áreas da computação: computação ubíqua, tecnologia de redes de sensores e inteligência artificial, a qual representa a visão de um futuro em que os ambientes apoiam as pessoas que os habitam. Este ambiente previsto é discreto, interconectado, adaptável, dinâmico, incorporado e inteligente (ACAMPORA et al., 2013; SADRI, 2011).

Para viabilizar o *AmI*, diversas metodologias e tecnologias são aplicadas (inteligência artificial, big data, entre outras), podendo ser utilizado em muitos locais, tais como, casas inteligentes, comércios, diferentes tipos de negócios e museus, além de situações para apoio a cuidados de idosos e de saúde,, sistemas de recomendação, entre outros cenários (SADRI, 2011).

Portanto, a aplicação do paradigma AmI à saúde ubíqua é um dos cenários com maior potencial de desenvolvimento da atualidade, principalmente por oferecer a possibilidade de suporte contínuo na assistência à saúde, visando proporcionar uma melhor qualidade de vida às pessoas (Sadri, 2011). Todavia, embora existam vários estudos focados em cuidados ubíquos, a maioria dos trabalhos é focada em coleta de dados, monitoramento, suporte remoto ou notificação de saúde pós-incidente. Além disso, as lacunas de pesquisa indicam que há oportunidades para desenvolver trabalhos relacionados especialmente à previsão/predição de eventos de saúde (ACAMPORA et al., 2013).

Outros conceitos relacionados aos ambientes inteligentes, que estão sendo debatidos atualmente, especialmente na comunidade científica internacional, são *Assistive Environments (AE)*, *Ambient Assistive Living (AAL)* e *Ambient Intelligence (AmI)*. Segundo BECKER et al. (2009a), como a população mundial está envelhecendo, há uma necessidade crescente de suporte para oferecer mais independência a pessoas idosas. (*AEs*) incorporam as tecnologias pervasivas e ubíquas mais recentes e provêm uma alternativa viável ao tradicional *assistive living*.

Com o envelhecimento da população, certamente aumentarão as necessidades por cuidados com a saúde e assistência médica pessoal, que elevarão o custo total da tradicional assistência domiciliar. Com o crescimento da capacidade computacional e a aplicação da computação ubíqua, pode-se pensar em alternativas viáveis para substituir, parcialmente ou integralmente, as necessidades de monitoramento contínuo e suporte para pessoas idosas ou com deficiências (BECKER et al., 2009a).

O paradigma do *Ambient Assistive Living (AAL)* engloba ambientes inteligentes acessíveis, desenvolvidos para auxiliar pessoas idosas ou com deficiências, proporcionando-lhes uma vida independente (ABASCAL et al., 2009).

Os avanços em diversas áreas tecnológicas, tais como, computação, redes de comunicação e sensoriamento, possibilitaram a criação de ambientes inteligentes, de modo que aplicações executadas em computação embarcada coletam dados do ambiente a partir de sensores e se comunicam através deles por redes cabeadas e *wireless*. A ideia é poder proporcionar serviços inteligentes para ajudar pessoas nas suas atividades do cotidiano, principalmente quando se

tratam de PCDs e idosos (ABASCAL et al., 2009).

O objetivo do *Ambient Intelligence (AmI)* é permitir que usuários interajam com dispositivos em rede e tenham serviços em seus ambientes de forma natural e universal, por meio de uma interação por linguagem natural e *wearable computing* (ZIMMERMANN et al., 2004).

2.6 Robôs de Serviço

Desde a primeira vez que o termo Robô foi escrito por Karel Capek, em 1921, durante a peça teatral os "Robôs Universais de Rossum" (*Rossumovi Univerzální Roboti, R.U.R.* em Theco) (TMPR, 2019), uma considerável evolução aconteceu no desenvolvimento técnico e científico no campo da robótica (DEL DOTTORE et al., 2018). Atualmente, há laboratórios (BOSTON-DYNAMICS, 2022; GEORGIATECH, 2022; BRL, 2022) e companhias (ROBOTREPORT, 2022) especializadas na fabricação de robôs, os quais estão disponíveis para atividades industriais (MITSUBISHIELECTRIC, 2022; ONROMROBOTICS, 2022; ABBROBOTICS, 2022), e para assistência a pessoas em diferentes contextos do cotidiano (IROBOT, 2022; MAYTRONICS, 2022; UBROBOT, 2022). A evolução no campo da robótica industrial teve uma aceleração significativa a partir dos anos 1960. Muitas soluções surgiram em diferentes áreas, tais como, automotiva, elétrica eletrônica, metal e maquinários, entre outras (GARCIA et al., 2007).

Por outro lado, os robôs de serviço têm sido desenvolvidos principalmente nas últimas décadas (GARCIA et al., 2007; OBERC et al., 2019; ZIELINSKA, 2019). A aplicação desta categoria de robôs ainda é mais frequente na comercialização de dispositivos autônomos domésticos, tais como, robôs aspiradores de pó e robôs limpadores de pisos de piscina (IROBOT, 2022; MAYTRONICS, 2022). Somente em 2019, as fabricantes de robôs comercializaram mais de 22 milhões de robôs domésticos. Enquanto isso, alguns grupos de pesquisa têm focado seus esforços no desenvolvimento de robôs para cuidados de saúde (PAPADOPOULOS et al., 2020; NOCENTINI et al., 2019).

Em particular, há um subconjunto de robôs de serviço para suporte médico, social e assistivos de cuidados humanos (BONACCORSI et al., 2016a). Robôs de serviço podem auxiliar médicos e profissionais da área da saúde abordando cuidados preventivos e paliativos de saúde, principalmente em tarefas repetitivas. Além disso, robôs de serviço têm auxiliado em cirurgias de alta precisão, com supervisão de médicos especialistas. Sem falar que robôs de serviço podem dar suporte a enfermeiros no controle da administração de medicamentos para pacientes internados em hospitais ou em casa (A. et al., 2019). Por fim, robôs de serviço ainda podem auxiliar nos cuidados e tratamentos psicológicos de pacientes (D'ONOFRIO et al., 2019).

3 TRABALHOS RELACIONADOS

Este capítulo apresenta a investigação do estado da arte visando identificar os estudos mais relevantes e de maior impacto relacionados aos ambientes inteligentes que suportam os cuidados ubíquos de pessoas. O capítulo se divide em quatro seções principais. Inicialmente, foram pesquisados artigos que investigaram ambientes inteligentes e cuidados ubíquos através de *surveys*, mapeamentos ou revisões sistemáticas. A Seção 3.1 relaciona as pesquisas mais próximas do objetivo inicial de identificar as lacunas e as oportunidades metodológicas que abarcam a pesquisa de ambientes inteligentes e cuidados ubíquos. A Seção 3.2 apresenta a metodologia de mapeamento sistemático da literatura que foi aplicada, de modo a aprofundar a pesquisa na área, servindo de base para a seleção dos trabalhos mais relevantes e relacionados a esta tese. Na Seção 3.3 os resultados do mapeamento sistemático realizado são apresentados, detalhando-se as respostas para as questões de pesquisa aplicadas. Por fim, a Seção 3.4 apresenta e compara os trabalhos relacionados selecionados como o estado da arte para o modelo Apollo.

3.1 *Surveys*, Revisões e Mapeamentos Sistemáticos sobre Ambientes Inteligentes e Cuidados Ubíquos

A revisão sistemática de literatura de *IoT* para cuidados ubíquos, apresentada por AHMADI et al. (2018), destaca os componentes da arquitetura proposta, tecnologias aplicadas, características de arquitetura baseada em nuvem e desafios do uso de *IoT* para cuidados ubíquos. Além disso, os autores citaram que os tópicos de segurança e interoperabilidade em arquiteturas *IoT* voltadas para saúde ainda se apresentam em número reduzido. No que diz respeito aos efeitos mais importantes da *IoT* na área da saúde, os pesquisadores listaram a capacidade de troca de informações, a diminuição do tempo de hospitalização e dos custos de saúde. Ahmadi e colegas (AHMADI et al., 2018) citaram que os principais desafios da *IoT* na área da saúde são questões de segurança e privacidade. Para a pesquisa relacionada, com abrangência de apenas seis anos, entre 2010 e 2016, eles selecionaram 60 artigos e revelaram que o atendimento domiciliar foi uma das principais áreas de aplicação da *IoT* na saúde, conforme mencionado na revisão sistemática. Este trabalho relacionado não abordou grupos populacionais, doenças ou modelos preditivos para a saúde.

Liu e colegas 2016 abordaram na revisão sistemática, casas inteligentes e tecnologias de monitoramento doméstico de saúde para os idosos. O objetivo do estudo foi realizar uma revisão sistemática da literatura para determinar os níveis de disponibilidade tecnológica para os Idosos e evidências de casas inteligentes e tecnologias de monitoramento de saúde domiciliar que apoiam o envelhecimento domiciliar para os idosos que têm necessidades especiais. Uma análise de 48 artigos dentre 1.863 trabalhos científicos, indicou que a disponibilidade tecnológica para casas inteligentes e tecnologias de monitoramento de saúde domiciliar ainda é baixa. A pesquisa se concentrou apenas nos idosos. Esta pesquisa relacionada também abrangeu apenas

seis fontes de dados entre 2010 e 2014. No entanto, uma lacuna apontada por LIU et al. (2016) é a mesma identificada nesta tese: a falta de trabalhos preventivos e preditivos para a saúde em ambientes inteligentes, por exemplo, para a prevenção de quedas.

A pesquisa sobre ambientes inteligentes em saúde, apresentada por (ACAMPORA et al., 2013), cita (*AmI*) como um novo paradigma em tecnologia da informação que visa potencializar as capacidades das pessoas por meio de ambientes digitais sensíveis, adaptáveis e responsivos às suas necessidades humanas, hábitos, gestos, e emoções. Acampora e colegas (ACAMPORA et al., 2013) examinaram a infraestrutura e tecnologia necessária para alcançar a visão de inteligência ambiental, como ambientes inteligentes e dispositivos médicos vestíveis.

Este trabalho relacionado também discutiu como *AmI* pode apoiar as pessoas afetadas por diversas deficiências físicas, mentais ou doenças crônicas. O trabalho relacionado apresenta apenas uma análise qualitativa. Foram apontados alguns estudos de caso de sucesso na área, bem como desafios para traçar possíveis caminhos de pesquisa futura. ACAMPORA et al. (2013) categorizaram as tecnologias, algoritmos e aplicações e as relacionaram à inteligência ambiental na área da saúde.

A revisão realizada por (ALAM; REAZ; ALI, 2012b) apresenta uma visão geral da área de pesquisa de casas inteligentes, bem como tecnologias associadas a ela. O artigo descreve informações agregadas sobre sensores, dispositivos multimídia, protocolos de comunicação e sistemas que são amplamente utilizados na implementação de casas inteligentes. ALAM; REAZ; ALI (2012a) não aplicou uma metodologia de pesquisa mais formal como o mapeamento sistemático. Portanto, este artigo relacionado não apresentou detalhes dos critérios de seleção e classificação dos artigos analisados. A atenção à saúde no trabalho relacionado é parcial e não enfatiza doenças suportadas por casas inteligentes como indicado anteriormente nesta tese. Todavia, a revisão apresentou uma taxonomia de tecnologias, protocolos e serviços utilizados nos trabalhos pesquisados, de modo análogo à abordagem utilizada nesta tese.

Após a investigação das revisões de literatura existentes relacionando os temas de ambientes inteligentes e cuidados ubíquos, identificou-se cinco lacunas de pesquisa: (a) quais são os modelos de ambiente inteligente que suportam os cuidados ubíquos; (b) como a computação preditiva está sendo usada em ambientes inteligentes para apoiar os cuidados ubíquos; (c) quais são as doenças mais comuns suportadas por ambientes inteligentes aplicados aos cuidados ubíquos; (d) quais são os grupos de pessoas mais frequentemente suportados por ambientes inteligentes aplicados aos cuidados ubíquos; e (e) quais são as técnicas e tecnologias mais utilizadas em ambientes inteligentes voltados para os cuidados ubíquos. Para suplantando estas lacunas, pretende-se responder a oito questões de pesquisa, que são apresentadas na Seção 3.2.

3.2 Metodologia do Mapeamento Sistemático

Esta seção descreve os procedimentos experimentais adotados para planejar e executar o estudo de mapeamento sistemático. Para isso, adotou-se as diretrizes estabelecidas para este

tópico na literatura (KITCHENHAM; BUDGEN; BRERETON, 2011; KITCHENHAM; CHARTERS, 2007; KITCHENHAM et al., 2010; PETERSEN et al., 2008; PETERSEN; VAKKALANKA; KUZNIARZ, 2015). A Seção 3.2.1 traz os objetivos e as questões de pesquisa investigadas. A Seção 3.2.2 apresenta a estratégia de busca e bibliotecas digitais utilizadas para recuperar estudos representativos. A Seção 3.2.3 descreve os critérios de inclusão e exclusão usados para filtrar os estudos recuperados e todos os procedimentos usados para extrair dados desses estudos selecionados. Finalmente, a Seção 3.2.4 detalha a análise e a classificação dos artigos selecionados.

Esta tese adota a metodologia de mapeamento sistemático. Essa abordagem elimina ou reduz significativamente o viés quando comparado a revisões de referência única, obtendo-se assim resultados mais confiáveis (Cooper, 2016). Esse tipo de metodologia não discute apenas a descoberta final, mas todas as atividades relacionadas à descoberta. Assim, o mapeamento sistemático coleta dados sobre os locais onde a atividade ocorre e a mídia onde ela foi publicada, mapeando essa ligação. O mapeamento geralmente se concentra em artigos publicados, mas pode considerar outras mídias, como livros, jornais e propostas de financiamento. A metodologia consiste na execução das seguintes etapas: (a) elaboração das questões de pesquisa; (b) projetar o processo de busca; e (c) definir os critérios de filtragem dos resultados.

3.2.1 Questões de Pesquisa

As questões de pesquisa, apresentadas na Tabela 1, levaram este estudo a descobrir trabalhos que poderiam ser vinculados a ambientes inteligentes e cuidados ubíquos. Este trabalho aborda três Questões Gerais (QG), três Questões Focais (QF) e duas Questões Estatísticas (QE). O objetivo das QG é entender como os ambientes inteligentes estão apoiando a saúde ubíqua. As QF identificam como modelos específicos são usados para prever eventos relacionados a doenças e quais são os principais grupos de pessoas e doenças relatadas. Por fim, os QE encontram dados estatísticos sobre a área em estudo.

3.2.2 Processo de Pesquisa

De acordo com PETERSEN et al. (2008; 2015), o processo de pesquisa é dividido em três estágios: (a) especificação da *string* de pesquisa; (b) escolha das bases de dados para aplicar a *string* de pesquisa; e (c) obtenção dos resultados.

Portanto, a partir da definição das questões de pesquisa, procurou-se definir as palavras-chave que respondiam às questões elaboradas. Assim, inicialmente, foram realizados testes com termos candidatos a palavras-chave no campo de busca. Estes testes consistiram na combinação de dois elementos: (a) *Smart Environments* e (b) *Ubiquitous Healthcare*.

Assim, o primeiro estágio consistiu na identificação dos principais termos e seus sinônimos mais relevantes. As *strings* de pesquisa resultam da concatenação de termos usados pelos

Tabela 1 – Questões de pesquisa.

Id	Questão
QG1	Como os ambientes inteligentes estão sendo aplicados para os cuidados ubíquos?
QG2	Quais técnicas e tecnologias estão sendo usadas para apoiar nos cuidados ubíquos em ambientes inteligentes?
QG3	Há algum modelo para ambiente inteligente para suportar os cuidados ubíquos de saúde?
QF1	Quais são as doenças mais comuns endereçadas pelos ambientes inteligentes voltados para os cuidados ubíquos?
QF2	Qual é o grupo de pessoas mais frequentemente suportado pelos ambientes inteligentes voltados para os cuidados ubíquos?
QF3	Como a computação preditiva vem sendo usada em ambientes inteligentes com suporte aos cuidados ubíquos?
QE1	Em quais veículos os pesquisadores têm publicado?
QE2	Qual é o número de publicações por ano?

motores de busca para retornar estudos potencialmente relevantes na literatura atual.

Neste estudo, escolheu-se os termos *Smart Environments* e *Ubiquitous Healthcare*, tendo como sinônimos para *Smart Environments* os termos encontrados no artigo de (SADRI, 2011) e para *Ubiquitous Healthcare*, os termos encontrados em OGUNDUYILE; OLUGBARAB; LALL (2013), conforme visualiza-se na Tabela 2.

Tabela 2 – Termos da *string* de busca.

Termos principais	Termos sinônimos
<i>Smart environment</i>	<i>Ambient Intelligence OR AmI OR Ambient Assistive Living OR AAL</i>
<i>Ubiquitous healthcare</i>	<i>Pervasive healthcare OR U-Healthcare OR U-Health OR P-Health</i>

A partir desses elementos, foi elaborada a *string* de busca: ((*smart environment OR ambient intelligence OR ami OR ambient assistive living OR aal*) AND (*ubiquitous healthcare OR pervasive healthcare OR u-healthcare OR u-health OR p-health*)).

A definição da *string* de busca permitiu definir parâmetros de pesquisa a serem utilizados nas bases de dados. Assim, o segundo passo foi selecionar bases de dados relevantes para a área de estudo para aplicação da *string* de busca. Oito bancos de dados de pesquisa foram usados, incluindo o *Journal of Medical Internet Research (JMIR)*, *PubMed Central*, *ACM Digital Library*, *Google Scholar*, *IEEE Xplore Digital Library*, *Science Direct*, *Springer Library* e *Wiley Online Library* (Tabela 3). As duas primeiras são referências para pesquisas na área da saúde e as demais são renomadas bases de dados de pesquisa em Ciência da Computação.

A busca na *ACM Digital Library* exigiu o uso de recursos de busca avançada, onde a *string* de busca acima foi inserida no campo *Edit Query*. O processo de busca no Google Acadêmico foi feito utilizando a *query string* na busca avançada, considerando apenas o título para os re-

Tabela 3 – Bases de dados pesquisadas.

Base de pesquisa	URL
<i>Journal of Medical Internet Research (JMIR)</i>	http://jmir.org
<i>PubMed Central (PMC)</i>	http://ncbi.nlm.nih.gov/pmc
<i>ACM Digital Library (ACM)</i>	http://dl.acm.org
<i>Google Scholar (Scholar)</i>	http://scholar.google.com
<i>IEEE Xplore Digital Library (IEEE)</i>	http://ieeexplore.ieee.org/Xplore/home.jsp
<i>Science Direct</i>	http://sciencedirect.com
<i>Springer Library (Springer)</i>	http://link.springer.com
<i>Wiley Online Library (Wiley)</i>	http://onlinelibrary.wiley.com

sultados mais relevantes. No *IEEE Xplore*, foi usado o *Command Search* do menu *Other Search Options*. Na base de dados *JMIR*, a *string* de pesquisa foi inserida no campo de critérios. Na *PubMed Central*, foi utilizada a Pesquisa Avançada e a *string* de busca foi inserida nos campos de resumo e título. No repositório *Science Direct*, a *query string* foi aplicada ao título, resumo e palavras-chave. Na *Springer Library*, além de usar a *string* de pesquisa como consulta de pesquisa, foi necessário remover os documentos categorizados como “Somente visualização”. Por fim, na base de dados *Wiley*, o campo *abstract*, na opção *Advanced Search*, processou a *string* de busca.

3.2.3 Processo de Seleção

Esta seção visa estabelecer os Critérios de Inclusão (CI) e os Critérios de Exclusão (CE) utilizados para filtrar artigos potencialmente relevantes recuperados do mecanismo de busca utilizado. Os CIs definem o que deve ser considerado para incluir um determinado trabalho na amostra de artigos representativos. Os CEs definem os requisitos para remover obras consideradas inadequadas para responder às questões de pesquisa. A tabela 4 mostra os CIs e CEs.

Os critérios de inclusão e exclusão auxiliam no processo de filtragem para obter os estudos mais relevantes, eliminando ruídos gerados na busca. Os estudos obtidos no processo de busca foram filtrados, retirando as impurezas que não se enquadravam nos critérios de inclusão CI1, CI2 e CI3. Os demais artigos foram armazenados em uma planilha, onde os textos foram organizados em *tags* específicas para cada banco de dados da pesquisa.

O próximo passo foi analisar os artigos por título e resumo. Os artigos foram reunidos na mesma pasta e quaisquer artigos duplicados foram removidos. Os artigos (BOTIA; VILLA; PALMA, 2012) e (DO et al., 2018) foram adicionados por heurística, pois são relevantes para este estudo mesmo não sendo encontrados no processo de busca. O próximo filtro foi baseado nas duas primeiras etapas da abordagem *three-pass-method* (KESHAV, 2007). A primeira etapa é uma varredura rápida e consiste em: (a) leitura do título, resumo e introdução; (b) leitura

Tabela 4 – Lista de Critérios de Inclusão (CI) e Critérios de Exclusão (CE).

Critério	Descrição
Critérios de Inclusão	
CI1	O estudo deve ter sido publicado em uma conferência, seminário ou periódico.
CI2	O estudo deve ser relacionado ao contexto de uso de ambientes inteligentes aplicados aos cuidados ubíquos.
CI3	O estudo deve ser um artigo completo.
Critérios de Exclusão	
CE1	Os estudos que foram publicados antes de 2009.
CE2	O estudo que não foi escrito em inglês.
CE3	Os estudos que foram publicados em livros, revistas, dissertações ou teses.
CE4	Os estudos que apresentam paradigmas que não estão relacionados aos ambientes inteligentes ou aos cuidados ubíquos.
CE5	Os estudos que não estão relacionados às questões de pesquisa.
CE6	Artigos duplicados.

apenas dos títulos das seções e subseções, ignorando todo o resto; (c) *overview* do conteúdo matemático, se houver, para determinar os fundamentos teóricos subjacentes; e (d) leitura das conclusões.

A segunda etapa consiste em olhar atentamente para as figuras, diagramas e outras ilustrações do papel, prestando atenção especialmente aos gráficos. Por fim, os artigos pré-selecionados foram filtrados analisando o texto completo e observando os critérios de exclusão de CE4, CE5, e CE6. A Figura 2 apresenta o processo de filtragem, com CIs e CEs aplicados em cada etapa.

A base de dados *Science Direct* retornou a menor quantidade de artigos, apenas 20, porém retornou os artigos mais assertivos relacionados à *string* de busca, os quais constituem 40% dos resultados filtrados. Os resultados da base de dados *IEEE* constituíram 49,04% dos resultados filtrados. Embora tenha retornado mais artigos quando comparado às outras bases que utilizaram a mesma *string* de busca, havia muitos artigos não relacionados, os quais foram desconsiderados. Após a filtragem dos resultados, foram removidos os artigos retornados pelo Google Acadêmico que estavam também relacionados nas demais bases de dados utilizadas. O processo de filtragem mostrou muitos artigos focados apenas em telemedicina ou aplicativos para interação com o paciente. Estes foram removidos do estudo.

3.2.4 Análise e Classificação dos Artigos Selecionados

Esta subseção apresenta os resultados obtidos a partir da análise e da classificação dos artigos selecionados. A Tabela 18 (Apêndice A) lista os artigos revisados e mostra suas características, apresentando uma visão geral dos dados coletados. Apresenta-se tabelas e diagramas para prover um *overview* das informações obtidas. Cada artefato foca na apresentação de dados pertinentes a cada questão de pesquisa. Os resultados para cada questão de pesquisa são apresentados nas subseções seguintes.

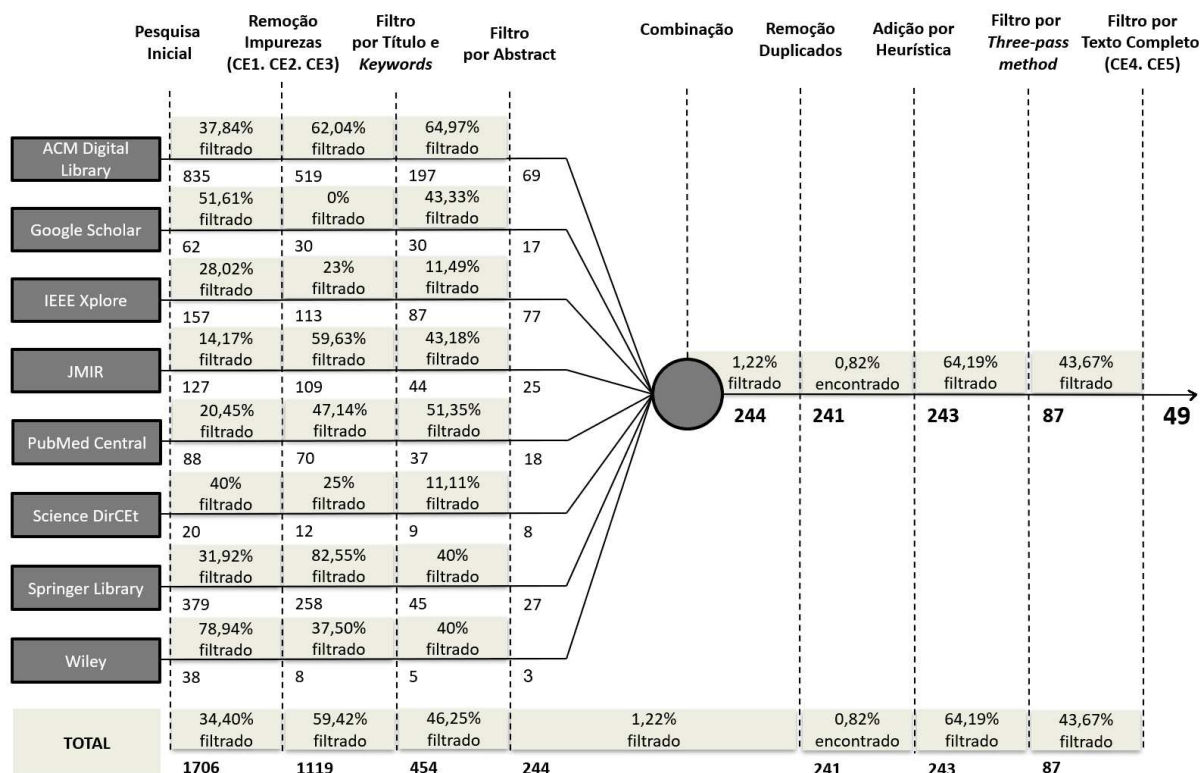


Figura 2 – Etapas do processo de filtragem.

Fonte: Elaborado pelo autor.

3.2.4.1 Como os ambientes inteligentes estão sendo aplicados para os cuidados ubíquos? (QG1)

Esta questão investigou a efetiva aplicação de ambientes inteligentes aos cuidados ubíquos. A abordagem utilizada foi extrair o tipo de classificação adotado em cada artigo selecionado. A Figura 3 apresenta a frequência da aplicação de ambientes inteligentes aos cuidados ubíquos em diferentes perspectivas, considerando o escopo, a classificação e a tecnologia. Como pode ser observado no lado esquerdo da Figura 3, a ciência do contexto baseada na detecção de objetos, pessoas ou atividades são as aplicações mais frequentes para os artigos selecionados. Além disso, o lado direito da Figura 3 mostra que os sensores de ambiente (*ambient sensors - AW*) para monitoramento é a principal tecnologia utilizada dentre os artigos selecionados.

A Tabela 5 apresenta a distribuição dos artigos selecionados por tipo de classificação. Os dados indicam que a ciência do contexto é a mais frequente, estando presente em 17 dos 49 artigos selecionados (34,69%, 17/49). O sistema de suporte é o segundo mais frequente, correspondendo a 28,57% (14/49) dos artigos selecionados. As demais aplicações são adotadas em diferentes estudos, tais como assistência robotizada (18,36%, 9/49), e sistema de identificação de atividades (18,36%, 9/49).

O monitoramento é considerado parte fundamental de um ambiente inteligente (AL-SHAQI; MOURSHED; REZGUI, 2016) e esta característica está presente como requisito base em todos




Figura 3 – Aplicação de ambientes inteligentes para os cuidados ubíquos.
Fonte: Elaborado pelo autor.

os artigos selecionados. Monitorar significa obter dados coletados de sensores do ambiente, *wearables* (para leitura de biosinais) ou via robôs de serviço. Em alguns casos, além do monitoramento, o artigo selecionado também agregou detecção, notificação e atuação no ambiente, apoiando o usuário em suas necessidades de cuidados à saúde.

Neste quesito, a classificação dos artigos selecionados foi: (a) somente monitoramento – alguns casos onde ocorre somente a coleta de dados fisiológicos do usuário ou dados do ambiente; (b) detecção – projetos que abordam sistemas de reconhecimento de atividades, detectando a ocorrência ou mudança de padrões de comportamento do usuário no ambiente - alguns trabalhos citam *Activity Daily Living (ADL)*, um termo geral para eventos cotidianos, tais como dormir, alimentar-se, assistir TV, entre outras atividades; (c) Notificação – situação mais frequente, onde mensagens ou alertas são enviados para o usuário idoso, seus familiares ou tutores, quando ocorrerem quedas ou situações de risco - identificou-se alguns trabalhos que atuam como sistema persuasivo (DEEN, 2015); (d) Notificação/Atuação – os artigos selecionados neste escopo, além de notificação, também realizam ações no ambiente inteligente, modificando variáveis do ambiente, como por exemplo, alguns dos artigos selecionados implementaram notificações para o usuário lembrar do consumo de medicamentos ou água; e (e) Atuação – geralmente associado a robôs que atuam no ambiente apoiando o usuário ou modificando o próprio ambiente.

A Tabela 6 apresenta a distribuição dos artigos selecionados por escopo. Os dados indicam que a detecção é o tipo mais frequente, estando presente em 15 artigos selecionados (30,61%, 15/49). Os resultados indicam que a maior parte das pesquisas focam em monitoramento, detecção e notificação de incidentes de saúde e eventos relacionados à saúde, como, por exemplo

Tabela 5 – Distribuição dos artigos selecionados por tipo de classificação.

Tipo de classificação	Número de artigos	%	Id do artigo
Ciência do contexto	17	34,69	S1, S2, S3, S7, S11, S12, S13, S14, S15, S19, S25, S28, S30, S31, S36, S47, S49
Sistema de suporte	14	28,57	S4, S6, S8, S16, S17, S20, S26, S22, S24, S29, S38, S43, S45, S46
Assistência robotizada	9	18,36	S9, S18, S21, S27, S32, S33, S35, S39, S41
Sistema de identificação de atividades	9	18,36	S5, S10, S23, S34, S37, S40, S42, S44, S48
Total	49	100	

quando um sistema que envia um alerta automático para o idoso que esqueceu de realizar alguma tarefa da sua rotina diária.

Tabela 6 – Distribuição dos artigos selecionados por escopo.

Escopo	Número de artigos	%	Id do artigo
Detecção	15	30,61	S2, S3, S5, S7, S10, S11, S15, S18, S19, S31, S34, S35, S44, S48, S49
Notificação	12	24,48	S6, S8, S13, S14, S16, S20, S23, S26, S28, S36, S40, S43
Somente monitoramento	9	18,36	S4, S12, S22, S24, S25, S30, S29, S45, S46
Atuação	9	18,36	S1, S9, S21, S27, S32, S33, S39, S41, S42
Notificação / Atuação	4	8,16	S17, S37, S38, S47
Total	49	100	

3.2.4.2 Quais técnicas e tecnologias estão sendo usadas para apoiar nos cuidados ubíquos em ambientes inteligentes? (QG2)

Esta questão geral objetiva discutir quais são as principais tecnologias empregadas nos artigos selecionados para prover ambientes inteligentes que suportam cuidados ubíquos. Classificou-se as tecnologias em três macro grupos: sensores de ambiente (*Ambient Sensor - AS*), *wearable* e robôs de serviço (*Service Robot - SR*).

Sensores de ambiente são dispositivos e sensores instalados no ambiente para coletar dados, tais como luminosidade, temperatura, presença, pressão e umidade. Neste sentido, o ambiente inteligente usa um conjunto de sensores domésticos para monitorar as condições do ambiente.

Adicionalmente, verificou-se trabalhos que abordam: (a) uma toalete inteligente (HUANG; YU; SYU, 2012); (b) uma cozinha inteligente (OLIVIER et al., 2009); e (c) uma cama inteligente (HUANG et al., 2013). Além disso, identificou-se uma proposta que usa um conjunto

de sensores infravermelhos que detectam a presença de pessoas em cômodos de uma casa, sua postura e seus movimentos (MEHDI; BERNNS, 2011). As tecnologias mais frequentemente citadas foram: (a) Sensor infravermelho de presença (*PIR*); (b) *RFID*; (c) *beacons*; (d) sensor de pressão; (e) sensor de temperatura; (f) sensor de luminosidade; (g) sensor de umidade; (h) sensores de movimentos; (i) *SmartTV*; (j) sensores acústicos; (k) reconhecimento de voz; (l) reconhecimento de imagens; (m) câmera IP; (n) projetores; (o) *smartphonetablet*; (p) computadores *desktop*; (q) *laptop*; (r) sensores embarcados em *smartphonetablet*, tais como acelerômetro; (s) sensor de chuveiro; (t) sensor de banheiro; (u) sensor de cama; e (v) sensor de quarto. Pela perspectiva da comunicação, os principais protocolos citados foram: (a) *Bluetooth (BT)*; (b) *Bluetooth Low Energy (BLE)*; (c) *WiFi*; (d) *3G/4G/5G*; e (e) *ZigBee*.

Wearables são dispositivos *IoT* que podem medir dados fisiológicos, como, pulsação, detecção de postura e queda durante atividades. Os sensores mais citados nesta linha foram: (a) *ECG*; (b) *EEG*, (c) *EMG*; (d) temperatura do sangue; (e) temperatura da pele; (f) temperatura do corpo; (g) taxa de pulsação; (h) respiração; e (i) pressão sanguínea. Os artigos selecionados citam o uso de *gadgets* e dispositivos para cuidados da saúde, que trabalham de modo isolado ou formando uma *BSN/BAN* (CHEN et al., 2015): roupas inteligentes/relógio inteligente (PHAM et al., 2018) e cadeira de rodas inteligente (JARVIS et al., 2009).

Service robots são robôs de serviço, assistivos ou robôs sociais que colaboram com o ambiente inteligente, provendo serviços adicionais para o usuário. Os robôs normalmente agregam ações ao ambiente, além do sensoriamento, tornando-o mais inteligente. Os artigos selecionados apresentaram um braço robótico manipulador para apoiar na coleta de objetos (JARVIS et al., 2009); robôs de serviço especializados com detecção visual de movimentos humanos, reconhecimento de voz e gerenciamento de diálogo (MEHDI; BERNNS, 2011); robôs assistentes para apoiar na caminhada e para o uso do banheiro (PAPAGEORGIOU et al., 2017); e o robô *KuBo* (MANZI et al., 2017).

A Tabela 7 apresenta os dados obtidos na pesquisa de tecnologias e técnicas usadas. Os resultados mostraram que a maioria dos artigos selecionados adota somente os sensores de ambiente (36,73%, 18/49) para apoiar os cuidados ubíquos nos ambientes inteligentes. Além disso, somente dois artigos abordam a solução completa: sensores de ambiente + *wearable* + robôs de serviço (4,08%, 2/49).

A Tabela 8 apresenta a distribuição de tecnologias dos artigos selecionados agrupadas por seu respectivo Fator de Impacto (FI). A Tabela 8 mostra cinco grupos de fatores de impacto. Os resultados indicam que 40,80% dos artigos selecionados foram publicados em veículos com indicador de FI inferior a 1. Além disso, mais de 40% tinham FI maior que dois. Robôs de serviços e *wearables* são as tecnologias predominantes em veículos com maior fator de impacto, cuja métrica é maior que 4, resultando em 8,16% dos artigos selecionados.

Tabela 7 – Distribuição dos artigos selecionados por tecnologia.

Tecnologia	Número de artigos	%	Id do artigo
Sensores de ambiente	18	36,73	S1, S5, S8, S11, S12, S13, S19, S24, S25, S26, S29, S30, S36, S38, S44, S45, S46, S49
Sensores de ambiente / <i>Wearable</i>	15	30,61	S2, S3, S4, S10, S14, S15, S16, S17, S20, S22, S28, S34, S37, S40, S47
Robôs de serviço	5	10,20	S32, S33, S35, S39, S48
<i>Wearable</i>	4	8,16	S6, S23, S31, S43
Sensores de ambiente / Robôs de serviço	3	6,12	S9, S27, S42
Sensores de ambiente / <i>Wearable</i> / Robôs de serviço	2	4,08	S7, S41
<i>Wearable</i> / Robôs de serviço	2	4,08	S18, S21
Total	49	100	

3.2.4.3 Há algum modelo para ambiente inteligente para suportar os cuidados ubíquos de saúde? (QG3)

Analisando os trabalhos que abordam ambientes inteligentes, foi possível entender como os ambientes inteligentes estão sendo modelados. A Tabela 9 apresenta que 46,94% (23/49) dos artigos selecionados abordam algum modelo para suporte aos cuidados ubíquos. Os outros 53,06% (26/49) não citam o uso de um modelo que endereçe os cuidados ubíquos em ambientes inteligentes.

3.2.4.4 Quais são as doenças mais comuns endereçadas pelos ambientes inteligentes voltados para os cuidados ubíquos? (QF1)

Esta questão objetivou identificar as doenças mais frequentemente citadas. Como apresentado na Tabela 10, Demência, *Alzheimer* e Diabetes são as mais citadas. Doenças crônicas em geral, problemas do sono, estresse mental, obesidade e autismo também foram citados pelo menos uma vez. Aproximadamente 70% dos artigos selecionados não nomeiam uma doença específica.

3.2.4.5 Qual é o grupo de pessoas mais frequentemente suportado pelos ambientes inteligentes voltados para os cuidados ubíquos? (QF2)

Esta questão teve por objetivo identificar os usuários-alvo da revisão sistemática conduzida. A Tabela 11 apresenta os idosos como os mais citados. PCD e crianças também são tratados

Tabela 8 – Distribuição das tecnologias em % dos artigos selecionados por grupo de fator de impacto (FI).

Tecnologia / FI	0 to 0,99	1 to 1,99	2 to 2,99	3 to 3,99	4+	Total
Sensores de ambiente	22,44	4,08	2,04	8,16	0,00	36,73
Sensores de ambiente/ <i>Wearable</i>	8,16	10,20	4,08	6,12	2,04	30,61
Robôs de serviço	4,08	0,00	0,00	6,12	0,00	10,20
<i>Wearable</i>	2,04	2,04	2,04	0,00	2,04	8,16
Sensores de ambiente/Robôs de serviço	2,04	0,00	0,00	4,08	0,00	6,12
Sensores de ambiente/ <i>Wearable</i> / Robôs de serviço	2,04	0,00	0,00	0,00	2,04	4,08
<i>Wearable</i> /Robôs de serviço	0,00	2,04	0,00	0,00	2,04	4,08
Total	40,80	18,36	8,16	24,48	8,16	100

em alguns artigos dada sua vulnerabilidade.

3.2.4.6 Como a computação preditiva vem sendo usada em ambientes inteligentes para apoiar nos cuidados ubíquos? (QF3)

Esta questão investigou quais artigos abordaram modelos preditivos. O objetivo foi identificar projetos que não somente monitorassem e notificassem, mas especialmente antecipassem riscos e eventos, favorecendo a prevenção de acidentes e cuidados de saúde. Dentre os 49 artigos selecionados, somente 3 (6,12%) focaram em algum aspecto preditivo dos cuidados ubíquos em ambientes inteligentes.

ALKHOMSAN et al. (2017) relatam que o sucesso do provimento de serviços para cuidados ubíquos em *Ambient Assisted Living (AAL)* depende largamente da efetiva predição de situações no ambiente. Aqueles autores ainda complementam que a sensibilidade situacional no *AAL* determina a “inteligência” do ambiente. A percepção de informações relacionadas no entorno e mudanças nos comportamentos humanos. No *AAL*, há muitas formas de coletar dados sobre seus habitantes, tais como câmeras, microfones e outros sensores. De acordo com Alkhomsan e sua equipe (ALKHOMSAN et al., 2017), os dados coletados são complexos para um processamento eficiente da percepção de contexto. O artigo de ALKHOMSAN et al. (2017) apresenta

Tabela 9 – Distribuição dos artigos selecionados por uso de modelo.

Modelo	Número de artigos	%	Id do artigo
Não	26	53,06	S2, S4, S5, S7, S8, S12, S13, S14, S15, S19, S24, S25, S27, S30, S31, S32, S35, S36, S37, S39, S40, S42, S43, S44, S46, S48
Sim	23	46,94	S1, S3, S6, S9, S10, S11, S16, S17, S18, S20, S21, S22, S23, S26, S28, S29, S33, S34, S38, S41, S45, S47, S49
Total	49	100	

Tabela 10 – Distribuição dos artigos selecionados por doença.

Doença	Numero de artigos	%	Id do artigo
Não específico	33	67,34	S1, S3, S4, S6, S7, S8, S9, S10, S11, S14, S15, S16, S17, S18, S19, S20, S21, S22, S27, S30, S32, S33, S34, S35, S36, S39, S41, S42, S44, S45, S47, S48, S49
Demência	3	6,12	S5, S26, S38
<i>Alzheimer</i>	3	6,12	S12, S13, S31
Diabetes	2	4,08	S23, S43
Autismo	1	2,04	S46
Obesidade	1	2,04	S24
Estresse	1	2,04	S28
Doenças crônicas	1	2,04	S40
Distúrbios do sono	1	2,04	S25
Cognitivo	1	2,04	S37
Asma	1	2,04	S29
Epilepsia	1	2,04	S2
Total	49	100	

um *overview* sobre os resultados de pesquisa existentes para a análise de dados multimodal em *AALs*, visando melhorar a vida de idosos em sua moradia, e estuda a eficiência no processamento *real-time* de eventos complexos para sensibilidade situacional. Finalmente, o artigo trata de sensoriamento multimodal para detecção de situações cotidianas também para predição de eventos usando árvore de decisão e outros algoritmos de análise. Para ilustrar a abordagem proposta, eles consideraram o reconhecimento de atividades de idosos em um ambiente assistido.

JUNG; YOON (2017) publicaram o artigo que mede mudanças fisiológicas humanas a partir de diferentes partes do corpo para quantificar o nível de estresse mental usando biosensores multimodais. Para integrar estas respostas fisiológicas, eles geraram o bio-índice e regras para a predição do estado mental, tais como, "tenso", "normal" e "relaxado". Eles também desenvolveram um *middleware* como serviço de inspeção para analisar parâmetros de saúde como eletroencefalograma (*EEG*), eletrocardiograma (*ECG*), saturação de oxigênio (*SpO2*), pressão

Tabela 11 – Distribuição dos artigos selecionados por grupo.

Grupo	Número de artigos	%	Id do artigo
Idosos	26	53,06	S3, S4, S6, S7, S8, S9, S10, S11, S13, S15, S17, S18, S19, S21, S22, S26, S30, S33, S34, S35, S38, S39, S41, S44, S45, S47
Não específico	17	34,69	S2, S5, S12, S14, S16, S23, S24, S25, S28, S29, S31, S36, S37, S40, S43, S48, S49
Idosos e PCD	5	10,20	S1, S20, S27, S32, S42
Crianças	1	2,04	S46
Total	49	100	

sanguínea (*BP*) e taxa de respiração (*RR*). Neste *middleware* de serviço, eles usam o modelo de avaliação multinível para estresse mental que consiste em três etapas, como segue: classificação, inferência e tomada de decisão. A classificação de *datasets* de biosensores é possível por lógica *Fuzzy* e algoritmo de *machine learning SVM*. A inferência usa a árvore de decisão e algoritmo *Random Forest* para classificar o nível de estresse mental a partir de parâmetros de saúde. Finalmente, eles propõem um modelo preditivo para tomada de decisão para o bem-estar por *Expectation Maximization (EM)*.

LIN et al. (2009) escreveram o artigo que apresenta um ambiente inteligente como um espaço doméstico inteligente baseado em computação pervasiva para apoiar idosos e PCD. Eles destacam que, ao contrário dos sensores, que somente podem prover monitoramento passivo, um robô pode ser um elemento ativo para agregar qualidade de vida às pessoas. Foi proposto um serviço de robotização ativo para ambientes assistivos, para ajudar as pessoas em caso de ocorrências de situação de emergência. Ele funciona em uma hierarquia parcialmente observável por processo de decisão de *Markov (POMDP)*. A observação de séries multimodais é usada na decisão e processo de avaliação. É aplicado um sistema de resposta à emergência (ERS) para lidar com situações de emergência, tais como uma queda de idoso ou doenças emergenciais.

A proposta de observações multimodais é garantir a precisão do reporte para a emergência. Quatro fontes de observação foram apresentadas no artigo: o reconhecimento por imagem, o reconhecimento de voz, dispositivos de sensoriamento físico e outros sistemas. De acordo com Lin e colegas (2009), para cada fonte de observação, há duas séries de observação. Múltiplas fontes de informação oferecem ao agente mais oportunidades de aprender sobre o mundo real, assim como realizar previsões, avaliações e decisões mais assertivas.

3.2.4.7 Em quais veículos os pesquisadores têm publicado? (QE1)

Esta questão procurou revelar onde os artigos selecionados têm sido publicados, de modo que possam servir de base para futuras pesquisas na área. A Tabela 12 apresenta a distribuição dos artigos selecionados por local de publicação. Há a predominância de publicação em periódicos

cos (59,18%, 29/49). O restante dos estudos foi publicado em conferências (40,82%, 20/49). Em particular, pesquisadores têm escolhido o *PETRA* como o principal evento para publicar seus trabalhos. Logo, os trabalhos restantes têm sido publicados em periódicos (13/49, 26,53%).

3.2.4.8 Qual é o número de publicações por ano? (QE2)

A distribuição de publicações foi agrupada de acordo com o ano de cada publicação. A Figura 4 apresenta a distribuição dos artigos selecionados anualmente.

Desde a década iniciada em 2010, o número de publicações sobre ambientes inteligentes aplicados aos cuidados ubíquos tem uma média de 4,6 por ano, com viés de crescimento. Pode-se destacar o *PETRA* como a conferência com o maior número de publicações no ano de 2009 (14,28%, 7/49). Embora 49 trabalhos tenham sido publicados até agora, o número de estudos ainda é pequeno. Somente dois artigos foram publicados em 2013 e 2018, enquanto nenhum foi publicado em 2009 e 2010. Observa-se uma tendência de crescimento nos períodos 2010-2012, 2013-2015 e 2016-2017. A maioria dos trabalhos (83,67%, 41/49) foi publicada durante o período entre 2011 e 2016. Foi observado um pico de 8 artigos em 2009. Em 2010, ocorreu o contrário: o total caiu de 8 para 0 artigos publicados, apresentando uma expressiva queda.

3.3 Discussão sobre o Mapeamento Sistemático

Este mapeamento sistemático teve como foco a aplicação de ambientes inteligentes aos cuidados ubíquos. Esta pesquisa pode orientar trabalhos futuros sobre o uso da tecnologia como suporte para a melhoria da saúde das pessoas e para a promoção do bem-estar humano com vistas à saúde integral.

A partir da análise dos 49 artigos selecionados, constatou-se que tecnologias como *wearables*, sensores do ambiente e robôs de serviço são usados para auxiliar nos cuidados de saúde. Alguns dos trabalhos pesquisados utilizaram *smartphones* e *tablets* como recurso integrado de acompanhamento das pessoas devido à variedade de sensores e sua comunicação com *wearables*. Na maioria dos casos, os *smartphones* geralmente foram usados para registrar biodados dos usuários ou para se comunicar com a nuvem.

Este estudo apresentou as diferentes formas que a tecnologia está sendo usada para apoiar nos cuidados de saúde, como por exemplo, o monitoramento, a detecção, a notificação, e a atuação, ou apenas atuação no ambiente. Os trabalhos pesquisados em que a atuação no ambiente era o escopo principal estiveram associados ao uso de robôs sociais que interagem com o ambiente, auxiliando as pessoas em caso de emergência, como apresentado por MEHDI; BERNIS (2011) ou melhorando a experiência e bem-estar do usuário como apresentado por (JARVIS et al., 2009) e (PAPAGEORGIOU et al., 2017). No entanto, observou-se um fluxo de suporte aos cuidados de saúde que segue o padrão: monitoramento, detecção e notificação.

Embora os estudos não tenham apontado nenhuma doença específica como a mais citada

nos 49 artigos pesquisados, onze artigos foram categorizados de acordo com a classificação de doenças, tais como, como demência, diabetes, *Alzheimer*, autismo, obesidade, estresse mental, distúrbios do sono e doenças crônicas. O ambiente inteligente se apresentou como uma solução adequada para monitorar e auxiliar no tratamento de doenças que requerem monitoramento contínuo.

O grupo de pessoas mais estudado foi o de idosos. Cerca de 53% dos casos pesquisados se concentram nessa faixa etária. DOUKAS et al. 2009 propôs um modelo para atender os idosos em caso de queda acidental. VALERO et al. 2014 discutiu uma proposta que auxilia os idosos nas Atividades da Vida Cotidiana (AVDs). O segundo grupo mais citado foi o de PCD. O AAL foi proposto para reduzir as dificuldades enfrentadas pelos PCD na vida cotidiana. Por exemplo, PAPAGEORGIOU et al. 2017 apresentou um modelo para apoiar pessoas com deficiência motora no uso do banheiro. HUANG; YU; SYU 2012 estudou a leitura de dados fisiológicos para monitoramento da saúde. Por fim, as crianças também foram relatadas por TENTORI; ESCOBEDO; BALDERAS 2015 como grupo auxiliado com aplicação de casas inteligentes que auxiliam no monitoramento de indicadores de saúde infantil.

Analisando o processo de filtragem apresentada na Figura 2 e a QE1 apresentado na Figura 4, o banco de dados mais preciso realizando a *query string* foi o da ACM, e os bancos de dados menos precisos foram os da JMIR e da Wiley. Além disso, as bibliotecas ACM, Springer, PMC e IEEE contribuíram com cerca de 83,65% dos artigos selecionados.

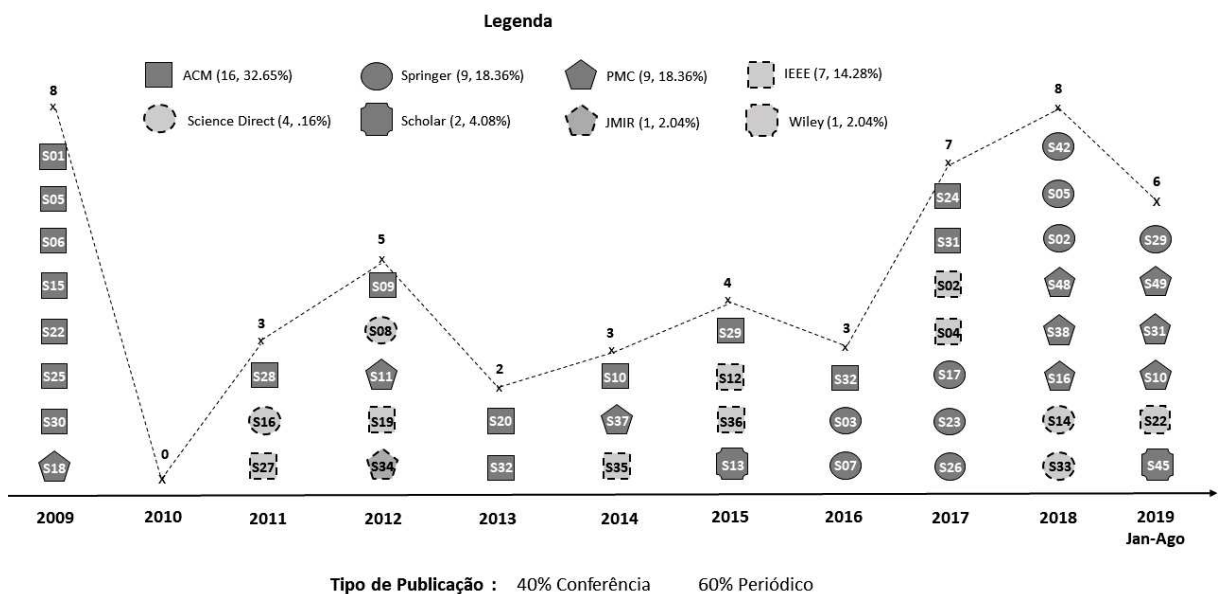


Figura 4 – Distribuição dos artigos selecionados por ano e local de publicação.

Fonte: Elaborado pelo autor.

Identificou-se algumas características técnicas como o uso de monitoramento de vídeo com reconhecimento de imagem. Esse recurso geralmente vem sendo usado para reconhecimento

de quedas em ambientes internos. Outra realidade observada nos trabalhos selecionados é a utilização de sensores embarcados em *smartphones* devido ao seu baixo custo e uso imediato e generalizado. No ambiente, recomenda-se o uso de sensores sem contato ou sensores não invasivos. O uso de Sistemas de Lembretes Digitais (SLD) são citados pela funcionalidade, principalmente lembretes de atividades.

Na perspectiva de oportunidades gerais envolvendo motivações econômicas e técnicas, seguem sete razões para a utilização da abordagem de ambientes inteligentes aplicada aos cuidados ubíquos: (a) o envelhecimento acelerado da população global; (b) o aumento e a multiplicidade de doenças crônicas; (c) a crescente demanda por serviços de saúde; (d) a possibilidade de prestação de serviços de suporte contínuo; (e) o apoio de serviços de cuidados de saúde especializados e personalizados; (f) a interconexão entre hospitais, serviços de emergência, cuidadores e robôs de serviço; e (g) redução da quantidade e tempo de hospitalização, além da diminuição dos custos médicos.

Os critérios gerais e técnicos indicam dez desafios: (a) a fusão de dados de sensoriamento multimodal ainda é um desafio significativo que precisa ser superado; (b) os métodos de detecção e de classificação de eventos apresentam lacunas que podem ser resolvidas; (c) a interface humano-computador (HCI) precisa ser melhorada em muitos aspectos para ser mais natural e não intrusiva; (d) muitos aspectos de segurança devem ser abordados para reduzir a quantidade de vulnerabilidades de segurança; (e) modelos preventivos e preditivos prevendo rotinas e hábitos são abordagens que podem melhorar efetivamente ambientes inteligentes; (f) a detecção de atividades e comportamentos humanos genéricos continua sendo um desafio; (g) muitas estratégias de localização em ambientes internos evoluíram, como por imagem, por acústica, campo magnético e sinal sem fio, mas ainda não são totalmente satisfatórias; (h) lidar com grandes volumes de dados (*big data*) e a capacidade de processamento em tempo real continuam sendo outros grandes desafios; (i) a aplicação de técnicas de inteligência artificial podem ser aprimoradas; e (j) as questões éticas e sociais, assim como os fatores humanos e suas particularidades, precisam ser mais discutidas e aprofundadas.

A principal tendência identificada para ambientes inteligentes foi a agregação de robôs assistivos ou robôs de serviço para suporte em ambientes inteligentes. Esses robôs sociais podem atuar para a prevenção ou apoio a pessoas em circunstâncias específicas ou em caso de emergência. Adicionalmente, identificou-se uma oportunidade de implementação de autoaprendizagem em sistemas, além de alertas/notificações, conforme proposto inicialmente. Por fim, o uso de dados fisiológicos, além dos dados padrão, pode contribuir para o desenvolvimento de soluções preventivas e preditivas mais precisas para cuidados ubíquos.

3.4 Estado da Arte

A partir do mapeamento sistemático realizado, considerando-se a seleção de 49 trabalhos que responderam às questões de pesquisa elaboradas, foram filtrados os trabalhos que apre-

sentaram a abordagem de ambientes inteligentes orientados aos cuidados ubíquos. Deste total, três artigos (LIN et al., 2009; ALKHOMSAN et al., 2017; JUNG; YOON, 2017) apresentaram estudos com foco em predição em ambientes inteligentes aplicados aos cuidados ubíquos.

Foram agregados, ainda, por conveniência e aderência ao tema da pesquisa, dois artigos (SOTO-MENDOZA et al., 2015; LIOUANE et al., 2018) que abordam a predição de eventos em ambientes inteligentes aplicados aos cuidados ubíquos. Além disso, foram agregados três artigos (SPOLADORE et al., 2021) (NEVES et al., 2020) (GARCIA-CONSTANTINO et al., 2020) publicados recentemente em periódicos de referência com alto fator de impacto na área da computação. A metodologia adotada para a filtragem destes três trabalhos relacionados foi a utilização da mesma *string* de busca e bases de dados pesquisadas, ambas utilizadas na Seção 3.2.2 do mapeamento sistemático realizado. Entretanto, foram filtradas somente as publicações cujo ano de publicação era igual ou superior a 2020. Por fim, foram adotados os mesmos critérios do processo de seleção da apresentados na Seção 3.2.3, realizando-se uma seleção final baseada no *three-pass-method* (KESHAV, 2007).

Portanto, os oito trabalhos relacionados mais relevantes para esta tese são apresentados nas subseções a seguir e comparados entre si, na Tabela 13.

3.4.1 *Situation Awareness in Ambient Assisted Living for Smart Healthcare*

O trabalho apresentado por ALKHOMSAN et al. (2017) trata de sensoriamento multimodal para detecção de situações cotidianas e para a predição de eventos, usando árvores de decisão e outros algoritmos. Para ilustrar a abordagem proposta, eles consideraram o reconhecimento de atividades de idosos em um ambiente assistido.

ALKHOMSAN et al. (2017) afirmam que o sucesso do fornecimento de serviços de saúde inteligentes em *Assistive Ambient Living (AAL)* depende de uma previsão eficaz de situações no ambiente. No ambiente *AAL*, há diversas maneiras de coletar dados sobre seus habitantes, tais como, através de câmeras, microfones e outros sensores.

O estudo de ALKHOMSAN et al. (2017) apresenta ainda uma visão geral dos resultados da pesquisa a partir da análise de dados multimodais em *AAL* para melhorar o ambiente de vida dos idosos, além de analisar a eficiência no processamento de eventos complexos para a consciência situacional em tempo real. Considerou também a detecção multimodal de situações atuais bem como para prever situações futuras usando algoritmos de análise de árvore de decisão.

3.4.2 *Multi-level Assessment Model for Wellness Service Based on Human Mental Stress Level*

O modelo descrito por JUNG; YOON (2017) mede mudanças fisiológicas humanas a partir de diferentes partes do corpo para quantificar o nível de estresse mental usando biosensores multimodais. Para integrar estas respostas fisiológicas, eles geraram o bio-índice e regras para a predição do estado mental, tais como "tenso", "normal" e "relaxado". Eles também desen-

volveram um *middleware* como serviço de inspeção para analisar parâmetros de saúde como eletroencefalograma (*EEG*), eletrocardiograma (*ECG*), saturação de oxigênio (*SpO2*), pressão sanguínea (*BP*) e taxa de respiração (*RR*). Finalmente, eles propõem um modelo preditivo para tomada de decisão para o bem-estar por *Expectation Maximization (EM)*.

3.4.3 *Decision Making in Assistive Environments Using Multimodal Observations*

LIN et al. (2009) apresentaram um ambiente inteligente como um espaço doméstico inteligente baseado em computação pervasiva para apoiar idosos e PCD. Os autores destacam que, ao contrário dos sensores que somente podem prover monitoramento passivo, um robô pode ser um elemento ativo para agregar qualidade de vida às pessoas. Foi proposto um serviço de robotização ativo para ambientes assistivos para ajudar as pessoas em caso de ocorrências de emergência. Ele funciona por processo de decisão de *Markov (POMDP)*.

No artigo de LIN et al. (2009) é aplicado um sistema de resposta à emergência (*Emergency Response System ERS*) para lidar com situações como uma queda de idoso ou doenças emergenciais. A proposta de observações multimodais é garantir a precisão do reporte para a emergência. Quatro fontes de observação foram apresentadas no artigo: (a) reconhecimento por imagem; (b) reconhecimento de voz; (c) dispositivos de sensoriamento físico; e (d) outros sistemas.

3.4.4 *An Improved Extreme Learning Machine Model for the Prediction of Human Scenarios in Smart Homes*

LIOUANE et al. (2018) apresentaram um modelo preditivo para hábitos simples de humanos em casas inteligentes. Os autores afirmam que um dos principais objetivos das casas inteligentes seria o acompanhamento e assistência à saúde, especialmente para idosos e pessoas com deficiência. Portanto, uma previsão precisa do comportamento dos habitantes seria útil para o fornecimento da assistência adequada.

O foco do artigo de LIOUANE et al. (2018) é a performance da fase de aprendizagem do modelo. Para tanto, os autores propuseram melhorar o modelo de *Extreme Machine Learning (EML)* definindo uma forma recorrente de aprendizado de máquina, garantindo o relacionamento temporal de entradas entre observações em diferentes etapas de tempo.

Os dados de entrada são baseados nos dados reais que representam as atividades das pessoas que pertencem ao perfil do primeiro nível, conforme medido pelo modelo de dependência do Sistema de Medição de Autonomia Funcional (SMAF) usado no domínio geriátrico. Os resultados experimentais revelaram que o modelo *RELM* proposto requer um tempo mínimo durante a fase de aprendizagem com um melhor desempenho em comparação aos modelos semelhantes existentes.

3.4.5 *Design of a Predictive Scheduling System to Improve Assisted Living Services for Elders*

SOTO-MENDOZA et al. (2015) desenvolveram um sistema preditivo de eventos para apoio nos cuidados de saúde de idosos, especialmente para suportar casos de esquecimento, como, por exemplo, de consumo de uma medicação. Os autores propõem ainda um cronograma preditivo que dispara em tempo real alertas de situações de risco (por exemplo, quedas, entrar em áreas fora dos limites, como a enfermaria ou a cozinha) e, informa aos cuidadores as tarefas rotineiras que precisam ser realizadas (por exemplo, administração de medicação, trocar fralda, entre outros). Além disso, o sistema auxilia os cuidadores a registrarem as tarefas de cuidado (como medicamentos) e avaliações de bem-estar (como o humor), que são difíceis de automatizar.

A solução proposta por SOTO-MENDOZA et al. (2015) facilita a transferência de turno do cuidador e pode ajudar a treinar novos cuidadores sugerindo tarefas de rotina e enviando lembretes e informações oportunas sobre os moradores. O sistema proposto por SOTO-MENDOZA et al. (2015) pode ser visto como uma ferramenta para a redução da carga de trabalho dos cuidadores e da equipe médica com tarefas repetitivas.

3.4.6 *DOMUS: A Domestic Ontology Managed Ubiquitous System*

SPOLADORE et al. (2021) propuseram um sistema ubíquo para ambientes domésticos que segue o paradigma de casas inteligentes para suporte a PAR, principalmente idosos com fragilidades físicas ou cognitivas. DOMUS engloba uma modelagem ontológica considerando domínios de conhecimento relacionados ao gerenciamento do conforto *indoor*, suportando os habitantes em atividades da vida cotidiana.

O sistema DOMUS possibilita a interação dos usuários e acesso às funcionalidades complexas via uma interface ubíqua adaptativa. Testes preliminares de inferência relacionados a inferências produzidas por ontologias, a avaliação de usabilidade do sistema e a aceitação pelos usuários finais são apresentados. Os resultados apontam para um bom nível de usabilidade do DOMUS usando a interface especial proposta, enquanto o nível de aceitação foi positivo e algumas sugestões de melhorias são apresentadas (SPOLADORE et al., 2021).

3.4.7 *Heath-PRIOR: An Intelligent Ensemble Architecture to Identify Risk Cases in Health-care*

NEVES et al. (2020) enfocaram na temática dos ambientes em cidades inteligentes aplicadas aos cuidados de saúde, visando a melhoria da qualidade de vida às pessoas, permitindo, por exemplo, a prevenção de doenças e o acompanhamento dos tratamentos. A arquitetura proposta por NEVES et al. (2020), chamada de Health-PRIOR elabora um sistema de recomendação que integra dados gerados em ambientes inteligentes com modelos preditivos e recomendação de ações, conteúdo ou serviços.

Os dados produzidos por dispositivos inteligentes são assertivos e confiáveis para a predição e a tomada de decisão, segundo os autores do Health-PRIOR. A arquitetura proposta utiliza algoritmos de *machine learning* para a realização de predições de acidentes. A avaliação da arquitetura Health-PRIOR demonstrou a sua viabilidade para predições considerando *data sets* com maior qualidade e com menor quantidade de valores ausentes (NEVES et al., 2020).

3.4.8 *Ambient and Wearable Sensor Fusion for Abnormal Behaviour Detection in Activities of Daily Living*

O artigo apresentado por GARCIA-CONSTANTINO et al. (2020) aborda a detecção de comportamentos fora do padrão de pessoas em atividades da vida diária. Estes comportamentos podem ser considerados indicadores de um problema de saúde progressivo ou a ocorrência de um acidente. É apresentada uma abordagem inicial de fusão de dados coletados do ambiente (via sensores de contato e térmico) e um *wearable* (acelerômetro) em um ambiente inteligente. Após, são processados os principais passos para o reconhecimento dos principais segmentos de AVDs.

De acordo com GARCIA-CONSTANTINO et al. (2020), a maior acurácia no reconhecimento das etapas da AVDs podem auxiliar na detecção de comportamentos diferentes dos padrões na forma de desvios das etapas esperadas. Os autores realizaram os experimentos considerando uma cozinha inteligente e as AVDs consideradas foram: (a) preparar e beber um chá, e (b) preparar e beber café. Os resultados mostraram que a abordagem inicial proposta aprimorou o reconhecimento das etapas principais das AVDs comparado com os resultados obtidos utilizando apenas dados provenientes de sensores vestíveis (GARCIA-CONSTANTINO et al., 2020).

3.4.9 Comparativo

Esta seção apresenta um comparativo entre os trabalhos relacionados, observando 12 quesitos. A Tabela 13 apresenta os quesitos que foram utilizados para comparação, tendo como primeiro item os históricos de contextos como base para a detecção de riscos. Foi realizada uma avaliação dos trabalhos relacionados para verificar como a predição é realizada e se foram baseados em históricos de contextos. Além disso, o comparativo mostra se o trabalho relacionado utiliza robôs de serviço. São comparados ainda os quesitos de histórico de saúde e do uso de dados fisiológicos, capturados por *wearables*. Avaliou-se também se foi proposta uma ontologia e se há a promoção da educação sobre riscos e acidentes aos usuários. Adicionalmente, avaliou-se a integração com serviços de notificação. Por fim, investigou-se se a implementação considerou uma interface de usuário adaptativa e acessível.

Tabela 12 – Conferências (C) e *Journals* (J) onde os artigos têm sido publicados.

Veículo	Tipo	Número de artigos	%	Id do artigo
<i>Pervasive Technologies Related to Assistive Environments (PETRA)</i>	C	13	26,53	S1, S7, S8, S12, S13, S19, S25, S27, S32, S35, S36, S37, S39
<i>Sensors</i>	J	7	14,28	S10, S14, S16, S38, S47, S48, S49
<i>Autonomous Robots</i>	J	2	4,08	S21, S33
<i>Journal of Ambient Intelligence and Humanized Computing</i>	J	2	4,08	S5, S42
<i>Applied Computing</i>	C	1	2,04	S40
<i>Digital Medicine</i>	J	1	2,04	S31
<i>Computer Systems and Applications</i>	C	1	2,04	S06
<i>Fuzzy Systems</i>	C	1	2,04	S34
<i>Pervasive and Ubiquitous Computing</i>	C	1	2,04	S26
<i>Pervasive and Ubiquitous Computing and Wearable Computers</i>	C	1	2,04	S30
<i>Systems, Man, and Cybernetics</i>	C	1	2,04	S15
<i>Ubiquitous Intelligence and Computing and Autonomic and Trusted Computing</i>	C	1	2,04	S24
<i>Diabetes Science and Technology</i>	C	1	2,04	S23
<i>Expert Systems with Applications</i>	J	1	2,04	S11
<i>Future Generation Computer Systems</i>	J	1	2,04	S41
<i>IEEE Access</i>	J	1	2,04	S3
<i>Intelligent Systems</i>	J	1	2,04	S44
<i>Medical Research</i>	J	1	2,04	S43
<i>Multimedia Tools and Applications</i>	J	1	2,04	S28
<i>Personal and Ubiquitous Computing</i>	J	1	2,04	S17
<i>Pervasive Computing</i>	J	1	2,04	S46
<i>Telematics and Informatics</i>	J	1	2,04	S20
<i>Robotics and Autonomous Systems</i>	J	1	2,04	S18
<i>SpringerPlus</i>	J	1	2,04	S4
<i>Social Robotics</i>	J	1	2,04	S9
<i>Mobile Networks and Applications</i>	J	1	2,04	S2
<i>Wireless Personal Communications</i>	J	1	2,04	S45
<i>Environmental Science and Pollution Research</i>	J	1	2,04	S29
<i>International Journal of Communication Systems</i>	J	1	2,04	S22
Total		49	100	

Tabela 13 – Comparativo entre os trabalhos relacionados.

Quesito	Alkhomsan et al. (2017)	Jung e Yoon (2017)	Lin et al. (2009)	Liouane et al. (2018))	Soto-Mendoza et al. (2015))	Spoladore et al. (2021)	Neves et al. (2020)	Garcia-Constantino et al. (2020)
Históricos de Contextos	Não	Não	Não	Não	Não	Não	Não	Não
Predição de Contextos	Não	Não	Não	Não	Não	Não	Sim	Não
Suporte a PAR	Parcial, idosos	Parcial, geral	Parcial, idosos	Parcial, idosos	Parcial, idosos	Parcial, idosos	Parcial, geral	Parcial, geral
Histórico de Saúde	Não	Não	Não	Não	Não	Não	Sim	Não
Dados Fisiológicos	Sim	Sim	Sim	Não	Não	Não	Não	Não
Fusão de Dados	Não	Não	Não	Não	Não	Não	Sim	Sim
Ontologia	Não	Não	Não	Não	Não	Sim	Não	Não
Objetos Inteligentes	Não	Não	Não	Não	Não	Não	Não	Não
Robôs de Serviço	Não	Não	Sim	Não	Não	Não	Não	Não
IHC Adaptativa e Acessível	Não	Não	Parcial	Não	Não	Sim	Não	Não
Notificações e Ações	Não	Não	Sim	Não	Não	Não	Sim	Não
Aprendizado Ubíquo	Não	Não	Não	Não	Não	Não	Não	Não

Em geral, os trabalhos relacionados se enquadram em *AALs* que visam identificar atividades da vida diária de idosos em ambientes assistivos *indoor*. Para isso, alguns trabalhos utilizam sensores no ambiente e *wearables* para coleta de dados vitais. Apenas o trabalho de LIN et al. (2009) adota um robô de serviço assistivo para auxiliar idosos, em casos de emergência.

Considerando o resultado do comparativo entre os trabalhos relacionados, constatou-se a inexistência de um modelo que considere concomitantemente os seguintes aspectos:

- A utilização de históricos de contextos de PAR em ambientes inteligentes que englobam histórico de saúde, AVDs, riscos e acidentes;
- A predição de contextos que envolvam acidentes, baseando-se nos históricos de contextos;
- O suporte a PAR com suas necessidades especiais;
- O histórico de saúde das PAR, englobando quedas anteriores ou comorbidades, por exemplo;
- A utilização de dados fisiológicos relevantes, tais como variação da taxa de batimentos cardíacos;
- A fusão de dados de múltiplas fontes, considerando a integração de dados fisiológicos, sensores e atuadores do ambiente;
- A utilização de uma ontologia para a formalização do domínio dos cuidados ubíquos aplicada à prevenção de acidentes por causas externas em ambientes inteligentes;
- A consideração de objetos físicos do ambiente e objetos inteligentes que podem ser físicos ou virtuais. Por exemplo uma cama inteligente que pode monitorar as condições de sono da pessoa com autonomia reduzida ou um relógio inteligente que pode monitorar o estado de equilíbrio de um idoso;
- A integração de robôs de serviço para apoiarem especialmente como atuadores no ambiente inteligente, podendo ainda auxiliar como interface assistiva, com reconhecimento de voz ou imagem, por exemplo;
- A integração de interfaces adaptativas e acessíveis, possibilitando a melhor experiência de usabilidade para o usuário de acordo com seu grau de autonomia ou deficiência.
- A integração aos serviços de urgência e emergência, além de notificar contatos de preferência;
- A educação dos usuários a partir de recomendações, alertas e objetos de aprendizagem adequados ao contexto e perfil do usuário, aplicando os conceitos de *U-Learning*.

4 MODELO APOLLO

Este capítulo descreve o modelo computacional proposto para identificação de riscos à saúde das Pessoas com Autonomia Reduzida (PAR) e Predição de Acidentes por causas externas acidentais em ambientes inteligentes. O capítulo está dividido em cinco seções principais. A Seção 4.1 traz os principais conceitos envolvidos no trabalho. A Seção 4.2 apresenta a visão geral do modelo. A Seção 4.3 especifica a arquitetura proposta, os requisitos fundamentais e seus elementos principais. Na Seção 4.4, são descritos os componentes do modelo, seus relacionamentos e as estratégias utilizadas para a identificação de riscos e predição de acidentes. Por fim, na Seção 4.5, é detalhada a ontologia ApolloOnto.

4.1 Conceitos Envolvidos no Trabalho

Este trabalho se baseia em seis conceitos principais: (a) *Risco*, que é uma condição de exposição à saúde indesejada, portanto, busca-se evitar que manifeste-se; (b) *Acidente*, que é um evento externo não-intencional relacionado à saúde, portanto objetiva-se a prevenção; (c) *Pessoa com Autonomia Reduzida (PAR)*, que é a representação de todas as pessoas com autonomia reduzida, portanto, com maior probabilidade de se envolverem com *Risco* e *Acidente*; (d) *Ambiente Inteligente (AI)*, que é o local físico dotado de sensores, atuadores e inteligência computacional para suportar os cuidados ubíquos para as PAR; (e) *Contexto*, que é um registro semântico do conjunto de atributos do AI e da PAR em um dado momento; e (f) *Ontologia*, que é um modelo de representação do conhecimento, cujo escopo permite a modelagem das classes, atributos, instâncias e relações de um domínio.

4.1.1 Risco

O termo *Risco* tem sua origem nas palavras *risicu* ou *riscu*, do latim, e tem o sentido de arriscar, ousar. Para o modelo Apollo, o risco é a probabilidade de uma circunstância ocorrer, mais especificamente uma ação que pode resultar em um acidente, com consequências que podem causar danos à saúde da PAR.

O Apollo considera que os riscos são prévios aos acidentes, ou seja, podem ser mapeados com base em uma sequência lógica de fatos e eventos anteriores ao acidente. Este histórico de risco-acidente está registrado pela literatura médica e formalizado em padrões internacionais, com possibilidade de ser modelado heurísticamente e validado por especialistas. Esta foi a estratégia adotada para o levantamento de riscos à saúde por causas externas acidentais a PAR considerados pelo Apollo.

4.1.2 Acidente

Para o modelo Apollo, um acidente é a concretização de um risco que se materializa em um evento negativo para a saúde da PAR. Os acidentes por causas externas não-intencionais são categorizados pela CID-10, em geral descritos como "lesões".

O Apollo considera a cardinalidade de “muitos para muitos” entre risco e acidente. Logo, cada risco pode estar associado a um ou muitos acidentes e cada acidente, relacionado a um ou mais riscos, de acordo com o perfil da PAR e o seu contexto.

4.1.3 Pessoa com Autonomia Reduzida (PAR)

No Apollo o perfil de usuário representa a entidade que possui um histórico de saúde, preferências ou necessidades especiais. A Pessoa com Autonomia Reduzida (PAR) pode ser uma Pessoa com Deficiência (PCD), idoso, criança, gestante, entre outras.

Uma PAR pode ser tanto uma consumidora de recursos de cuidados ubíquos, quando assistida pelo AI, quanto fornecedora de dados a partir de dados de seus hábitos e contextos, a partir de *wearables* que utiliza.

4.1.4 Ambiente Inteligente (AI)

O objetivo dos Ambientes Inteligentes é permitir que usuários interajam com dispositivos em rede e com serviços em seus ambientes de forma natural e universal, utilizando tecnologias, tais como, a interação por linguagem natural e *wearables* (ZIMMERMANN et al., 2004).

O modelo Apollo considera que os ambientes inteligentes podem sensoriar diversos fatores das Atividades da Vida Diária (AVDs) das PAR. Além do provisionamento de dados oriundos destes ambientes assistivos, soma-se ainda o uso de dispositivos vestíveis. Esta integração permitiu o enriquecimento da obtenção de dados de contexto, integrando a PAR ao seu espaço de modo natural e espontâneo, porém, com inteligência computacional agregada.

4.1.5 Contexto

Contextos são fragmentos de informação que podem ser usados para caracterizar a situação de um participante em uma interação (DEY, 2001). No modelo Apollo, um contexto é uma parte de um ambiente inteligente (por exemplo, um quarto de uma residência), que contém recursos para sensoriamento e atuação, além de PAR que possuem recursos para monitoramento de fatores intrínsecos e extrínsecos de saúde. O objetivo é buscar a prevenção de acidentes.

Os contextos podem ser genéricos (servem a todos os usuários) ou exclusivos (atendem somente a determinados perfis de usuários). Além disso, determinados objetos dentro de um contexto também podem ser genéricos ou exclusivos. Um tapete, por exemplo, é um objeto que

pode apresentar maior probabilidade de risco para PAR idosos do que para não-PAR.

Já os históricos de contextos são justamente o registro das atividades de um usuário dentro desses contextos performados, mantendo, assim, um histórico de seus deslocamentos e de sua atuação em cada contexto (MACHADO et al., 2021; ARANDA et al., 2021a).

Neste sentido, o Apollo gerencia os históricos de contextos, armazenando-os ao longo do tempo. Com o registro dos deslocamentos e hábitos dos usuários, o modelo pode oferecer suporte para a detecção de riscos mais frequentes de acordo com o perfil, baseando-se nestes históricos. Além disso, pode realizar inferências sobre estes históricos, visando prever acidentes futuros.

4.1.6 Ontologia

Introduzido por Aristóteles, o termo Ontologia é originário da filosofia e representa um ramo da filosofia que lida com a natureza e a organização do ser. Uma Ontologia define um domínio, ou, mais formalmente, especifica uma conceitualização acerca dele.

Alguns componentes comuns às Ontologias podem ser referenciados: classes (organizadas em uma taxonomia), relações (representam o tipo de interação entre os conceitos do domínio), axiomas (usados para modelar sentenças sempre verdadeiras) e instâncias (utilizadas para representar elementos específicos, ou seja, os próprios dados). Pode-se considerar Ontologias como a materialização do nível de conhecimento, pois, idealmente, não refletem nenhum formalismo específico e representam com frequência um vocabulário comum entre usuários e sistema (SEMPREBOM TIAGO; CAMADA, 2007).

Uma Ontologia fornece um conjunto de conceitos e termos para descrever um domínio específico, enquanto a base de conhecimento usa esses termos para descrever uma determinada realidade. Existem três características fundamentais referentes ao uso de uma Ontologia: é formal, explícita e compartilhada. É formal porque deve ser passível de ser processada por uma máquina. É explícita porque os tipos de conceitos usados e as limitações de uso desses conceitos devem estar definidos de forma explícita. E a Ontologia é compartilhada, pois o conhecimento não deve ser restrito a alguns indivíduos, mas, sim, compartilhado por grupos de pessoas (SEMPREBOM TIAGO; CAMADA, 2007).

O Apollo possui uma ontologia chamada ApolloOnto, especificamente modelada para contemplar as particularidades de saúde das PAR em ambientes inteligentes. A ApolloOnto formaliza o contexto, que é processado pelo modelo, possibilitando a identificação de riscos e predição de acidentes com base a padrões internacionais.

4.2 Visão Geral

O modelo Apollo se concentra na área de ambientes inteligentes com suporte aos cuidados ubíquos. O principal objetivo do modelo é a prevenção de acidentes por causas externas de PAR

em ambientes inteligentes nos vários contextos de suas Atividades da Vida Cotidiana (AVD). Baseando-se no perfil do usuário (SPARREMBERGER et al., 2019), sensibilidade ao contexto (DEY, 2001; BALDAUF; DUSTDAR; ROSENBERG, 2007) e gerenciamento de históricos de contextos (MACHADO et al., 2021). O Apollo busca proporcionar maior segurança, suporte e autonomia aos usuários de modo transparente, empregando para isso procedimentos disparados automaticamente a partir de seu perfil e de um conjunto de mecanismos para sensibilidade ao contexto.

A arquitetura do modelo Apollo é orientada a camadas. Os componentes foram definidos de acordo com os conceitos descritos na Seção 4.1. A Figura 5 apresenta uma visão geral do modelo Apollo composta por três camadas principais: (a) Camada de Consumo, que engloba os atores, contendo os três componentes e suas respectivas interfaces: Pessoa com Autonomia Reduzida (PAR), Cuidador e o ApolloBot; (b) Camada Servidor, que engloba o bloco principal, composto de módulos que se comunicam entre si via acessos e concentram funções específicas realizadas por componentes internos; e, (c) Camada de Provisionamento que engloba os componentes Dispositivos da PAR e Dispositivos do Ambiente Inteligente (AI), que representam genericamente os dispositivos e que provisionam dados para a geração de contextos pelo modelo Apollo.

O modelo Apollo foi projetado de modo a possibilitar a escalabilidade e customização dos serviços de cuidados ubíquos de acordo com as condições do ambiente inteligente e do perfil da PAR. A escalabilidade é possível devido à modularização, segmentação em camadas e desacoplamento dos componentes. Logo, novos PAR, Cuidador ou ApolloBot podem ser agregados ao ambiente inteligente de acordo com a demanda. A personalização pode acontecer pela perspectiva das interfaces de consumo por parte dos atores, que podem ter acesso ao resultado dos processamentos em interfaces especiais adaptativas ao seu perfil, de modo a promover a melhor experiência para o usuário *User Experience (UX)*. Além disso, pode haver personalização dos dispositivos de entrada acoplados no AI. Ou seja, novos sensores, dispositivos de *IoT* ou *IoHT* podem ser agregados ou removidos de acordo com as necessidades das PAR e a infraestrutura do ambiente. Por fim, a Camada Servidor também pode ser escalada sob demanda, pois foi projetada para ser implantada em nuvem, de modo a automaticamente beneficiar-se desta e de outras vantagens deste paradigma.

4.3 Arquitetura

A arquitetura do modelo Apollo foi projetada utilizando-se a linguagem de modelagem *Unified Modeling Language (UML)* (UML, 2005). A arquitetura do Apollo consiste de três camadas compostas de módulos, com seus respectivos componentes e acessos. A Figura 6 apresenta o diagrama da arquitetura com as três camadas principais: (a) Camada de Consumo; (b) Camada de Provisionamento; e, (c) Camada Servidor.

A Camada de Consumo considera os atores PAR, Cuidador e ApolloBot como

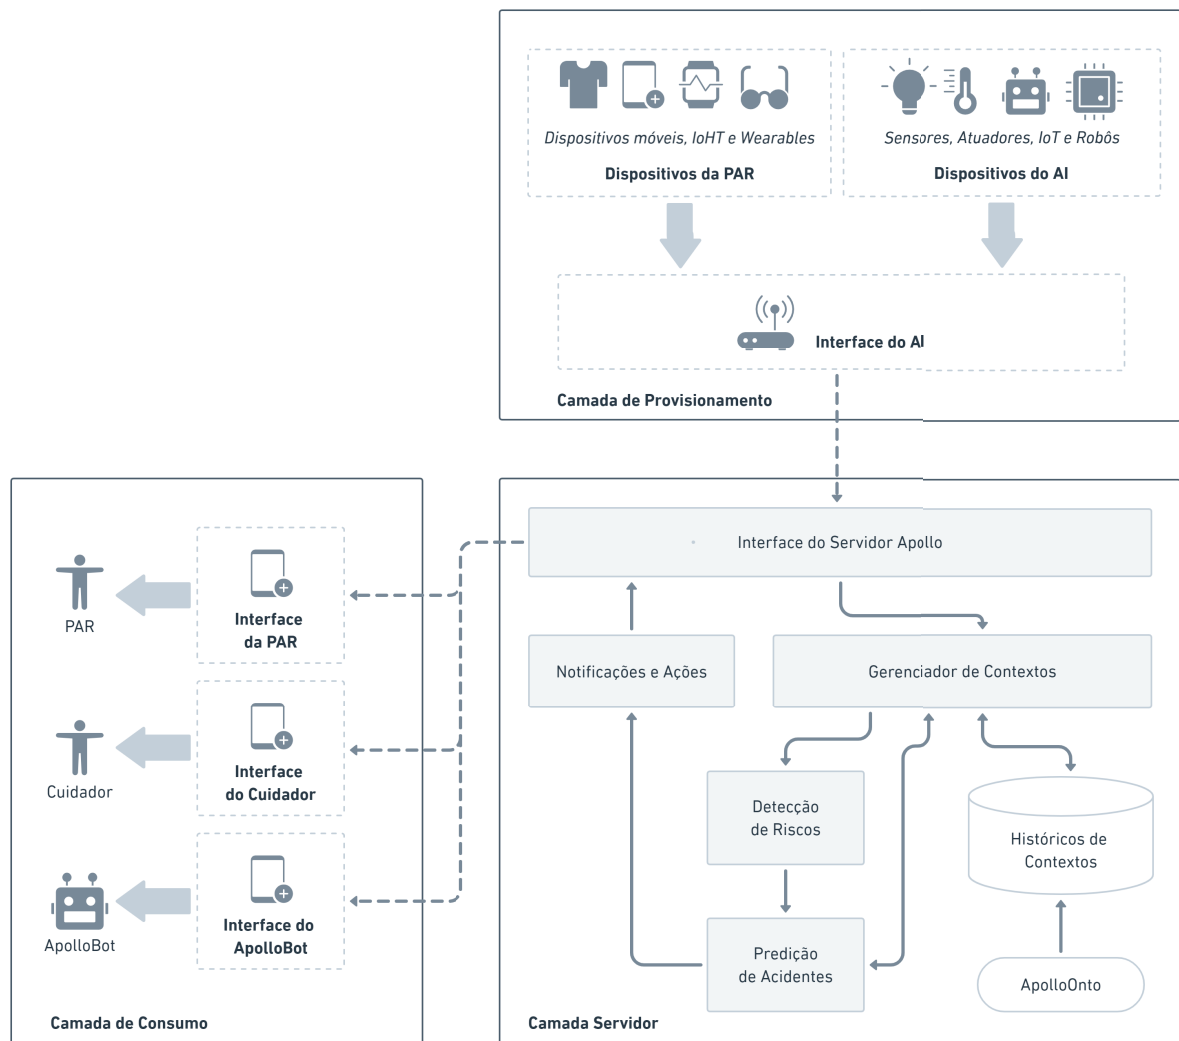


Figura 5 – Visão Geral do modelo Apollo.

Fonte: Elaborado pelo autor.

consumidores de notificações e instruções para ações robotizadas. Esta camada está organizada a partir de três agentes que compõe um Sistema Multiagentes (SMA), um para cada tipo de ator, que se comunicam com um servidor de aplicação de nuvem em borda. O servidor de aplicação de nuvem em borda centraliza e gerencia as interfaces do PAR, Cuidador e ApolloBot e comunica-se periodicamente com a Camada Servidor para coletar mensagens a serem disponibilizadas aos *endpoints* consumidores.

A Camada de Provisionamento considera dois grupos de dispositivos: (a) Dispositivos da PAR e (b) Dispositivos do AI. Os Dispositivos da PAR são *wearables* e outros recursos de *IoT* ou *IoHT* que coletam dados de estado e saúde da PAR. Os Dispositivos do AI são sensores, atuadores, câmeras, *IoT* e outros recursos computacionais, implementados em diferentes linguagens e plataformas, que coletam dados do ambiente, sejam dados ambientais, dos objetos ou das pessoas presentes. Esta camada está organizada com um servidor *Broker* para o qual convergem os dados assíncronos recebidos dos sinais e indicadores dos diversos dis-

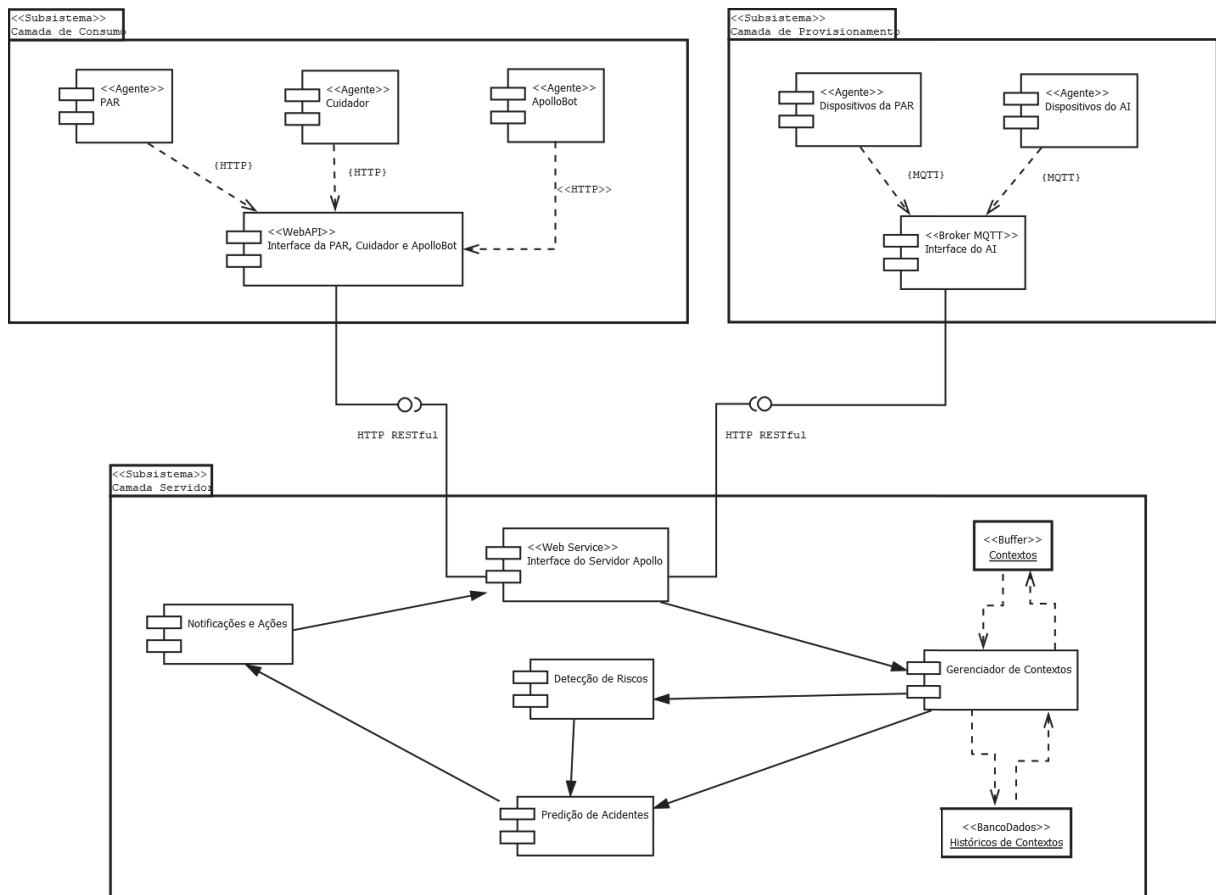


Figura 6 – Arquitetura do modelo Apollo.
Fonte: Elaborado pelo autor.

positivos do AI. O servidor *Broker* comunica-se com a Camada Servidor periodicamente fornecendo a coleta de dados de contexto agrupados.

A Camada Servidor é a camada central que recebe os dados coletados do ambiente, processando-os de modo a gerar contextos semânticos. Além disso, esta camada realiza a computação central de detecção de riscos e predição de acidentes, comunicando aos consumidores os eventos críticos via mensagens de notificação. Estas mensagens são gerenciadas via um servidor de fila de mensagens. A interface externa da Camada Servidor implementa um módulo de *Web Service* que abstrai a complexidade interna desta camada para a Camada de Consumo e Camada de Provisionamento. O armazenamento dos dados de contexto é realizado em um banco de dados relacional, que possibilita o registro acumulado dos históricos de contextos.

A arquitetura do modelo Apollo está detalhada nas próximas seções, de modo que os módulos e componentes internos de cada uma das três camadas, com seus respectivos acessos, estratégias e tecnologias utilizadas são detalhadas.

4.4 Componentes do Modelo

O padrão arquitetural de Arquitetura Limpa (ROBERT, 2017) foi adotado para o projeto do modelo Apollo visando a separação em camadas independentes, com alta coesão e baixo acoplamento das rotinas. As próximas seções detalham as três camadas da arquitetura do modelo Apollo que são segmentadas em módulos e componentes que de modo integrado realizam a detecção de riscos e a predição de acidentes.

4.4.1 Camada Servidor

A estrutura presente na Camada Servidor apresenta cinco componentes, um banco de dados e uma ontologia. A base do modelo Apollo consiste de quatro módulos que ficam abstraídos por uma camada de *Web Service*: Gerenciamento de Contextos, Detecção de Riscos, Predição de Acidentes e Notificações e Ações.

4.4.1.1 Interface do Servidor Apollo

A Interface do Servidor Apollo representa a comunicação entre a camada central do modelo e as aplicações de provisionamento de dados, que são aplicações de projeto externos que disponibilizam os dados da Pessoa com Autonomia Reduzida (PAR) e do Ambiente Inteligente (AI), coletados a partir de sensores, dispositivos móveis, *IoHT* e *wearables*. O Apollo recebe requisições que provisionam dados para o modelo via uma *API*, sendo que esta comunicação é realizada por meio do módulo interno *Web Service*, que tem a responsabilidade de realizar a interface entre os módulos internos e as camadas externas de provisionamento e interfaceamento com os consumidores. Após o recebimento dos dados da PAR e do AI via *Web Service*, o componente Gerenciador de Contextos realiza as operações de processamento de dados, gerando os contextos de modo padronizado e orientado à ontologia ApolloOnto, armazenando-os no componente de banco de dados Históricos de Contextos. Simultaneamente ao armazenamento do contexto no banco de dados, ocorre a comunicação dele para o módulo Identificação de Riscos.

4.4.1.2 Gerenciador de Contextos

O módulo interno Gerenciador de Contextos é responsável por seis tarefas principais: (a) Recepção de dados brutos oriundos da Camada de Provisionamento; (b) Persistência temporária em memória para tratamento dos dados; (c) Transformação dos dados brutos em um registro de contexto baseando-se na tabela de fuzzificação; (d) Armazenamento do contexto no banco de dados, tanto no formato de dados brutos quanto normalizados pela tabela de fuzzificação; (e) Submissão do contexto normalizado para o módulo Detecção de Riscos para

classificação entre *risco* e *não-risco*; e, (f) Consulta ao banco de dados para obtenção de históricos de contextos normalizados para provisionamento ao módulo *Predição de Acidentes*.

O módulo *Gerenciador de Contextos* expõe uma *API* com um método para recepção de dados brutos recebidos da Interface do Servidor *Apollo*. O fluxo dos dados brutos que chegam ao módulo *Gerenciador de Contextos* inicia-se no *endpoint* de sensoriamento que coleta os dados do *AI* ou da *PAR*, enviando na sequência para o Servidor *Broker*, ambos na Camada de Provisionamento. O Servidor *Broker* periodicamente submete para o *Web Service* do módulo Interface do Servidor *Apollo*, na Camada Servidor, os pacotes coletados.

O *Gerenciador de Contextos* utiliza um banco de dados em memória para armazenar os dados brutos recebidos do Módulo de Provisionamento para serem tratados pelas rotinas internas de fuzzificação. O armazenamento temporário em memória possibilita a persistência e recuperação mais rápida dos registros. A lógica Fuzzy foi adotada em detrimento à lógica binária por conta da capacidade de representação de níveis de diferentes estados que os tipos de coleta podem assumir. No caso do modelo *Apollo*, que considera aproximadamente 30 diferentes grupos de dados, esta abordagem demonstrou ser mais indicada para evitar a perda de representação das informações. Após a fuzzificação dos valores dos atributos considerados, o registro dos dados brutos consolidados em memória são armazenados no banco de dados relacional em disco, juntamente com o registro correspondente Fuzzificado. A partir desta etapa os contextos são tratados semanticamente pelos módulos *Deteção de Riscos* e *Predição de Acidentes*. Todavia, optou-se por manter armazenados os valores dos dados brutos coletados para eventuais re-normalizações da mesma base de acordo com limiares atualizados.

Considerando-se que diferentes tipos de sensores e escalas são utilizados para diversos tipos diferentes de coleta, faz-se necessário o tratamento individualizado dos dados de acordo com o tipo de medida. Por isso, a rotina de parametrização fuzzificada do módulo *Gerenciador de Contextos* possibilita transformar os dados brutos em estados. Por exemplo, o atributo `att_6 EstadoMovimentoEquilibrio`, um dos atributos do *dataset* detalhado na Tabela 23 (Apêndice A), possui uma escala em lógica Fuzzy que converte métricas do teste de mobilidade funcional *Timed Up and Go (TUG)* (PODSIADLO; RICHARDSON, 1991) inferiores a 20 segundos em `Normal` e valores superiores a 20 segundos em `Anormal`. Portanto esta rotina cria a abstração necessária para permitir diferentes sensores e tipos de medida gerem uma saída padronizada para a composição do contexto semântico. Os primeiros 27 atributos da Tabela 23, no Apêndice A, atributos `att_0` a `att_26`, são transformados pela rotina de fuzzificação antes da geração final do contexto, que será armazenado e processado pelo módulo de *Deteção de Riscos*.

Tendo o contexto sido gerado após a fuzzificação dos atributos individuais, o seu registro é armazenado no banco de dados relacional do repositório de *Históricos de Contextos*. Os contexto armazenado pode ser recuperado posteriormente pelo módulo *Predição de*

Acidentes abordando a predição de contextos.

A Figura 7 expande a visão interna do módulo Gerenciador de Contextos, detalhando o tratamento dos dados brutos de coleta, que resultam em dois registros armazenados no banco de dados de Históricos de Contextos: (a) registro do contexto original, com dados brutos, e (b) registro do contexto normalização de acordo com a tabela de Fuzzificação. O registro de contexto normalizado para a ser considerado o contexto semântico para os módulos adjacentes de Detecção de Riscos e Predição de Acidentes.

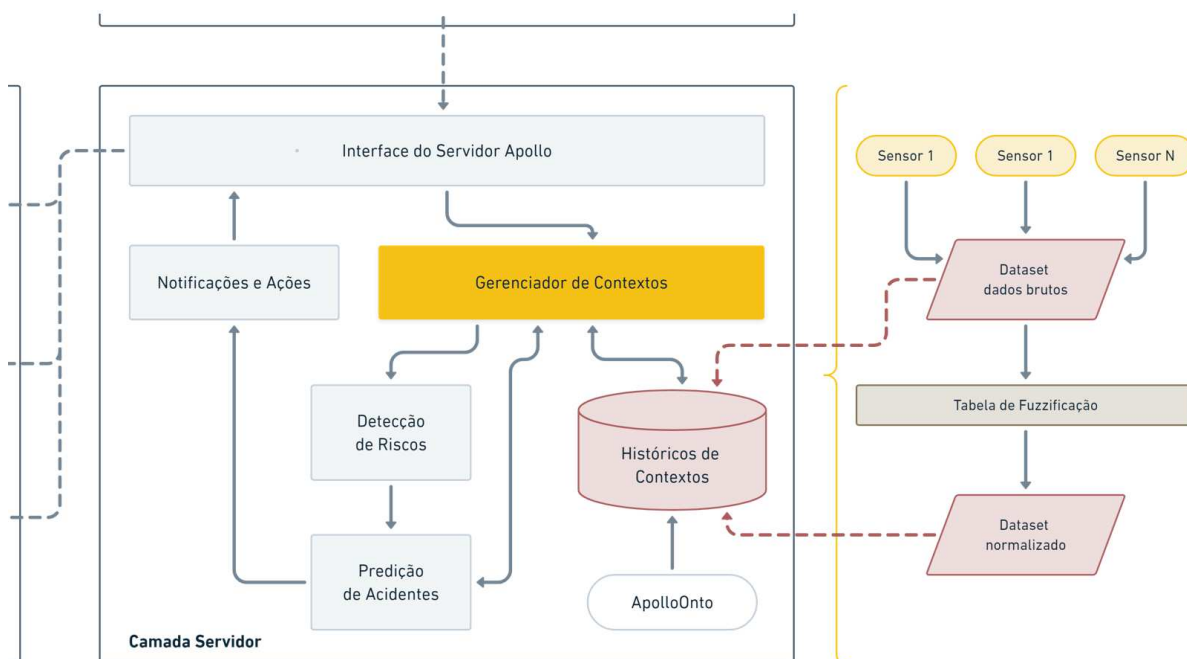


Figura 7 – Rotinas de aglutinação e fuzzificação dos dados de sensoriamento no módulo Gerenciador de Contextos.

Fonte: Elaborado pelo autor.

Além do armazenamento no banco de dados de Históricos de Contextos o contexto gerado é submetido para a API do módulo Detecção de Riscos que aplica o modelo de *machine learning* supervisionado que classifica o contexto entre risco e não-risco. O modelo de *machine learning* foi treinado inicialmente considerando-se o *dataset* gerado pelo Apollo Simulator. Entretanto, periodicamente o modelo é re-treinado para aprimoramento de sua performance, considerando a evolução dos históricos de contextos. Para os casos em que o registro de contexto é classificado como risco, o módulo Detecção de Riscos realiza uma requisição ao módulo Predição de Acidentes para que seja realizado o processamento preditivo verificando se o contexto em análise trata-se de um caso isolado ou de um contexto em uma provável sequência que pode resultar em um acidente.

Para que o módulo Predição de Acidentes possa realizar o processamento preditivo ele demanda, além de receber o contexto de risco do módulo Detecção de Riscos, realizar requisições periódicas ao módulo Gerenciador de Contextos para re-treinar o modelo oculto de Markov que processa as predições. Portanto, o Gerenciador de Contextos responsabiliza-

se pela consulta dos históricos de contextos para provisionamento ao módulo de Predição de Acidentes.

4.4.1.3 Detecção de Riscos

O módulo de Detecção de Riscos classifica os contextos recebidos pelo módulo Gerenciador de Contextos em graus relativos de risco. Esta classificação é realizada de acordo com o histórico de contextos e utilizando-se modelos de *machine learning (ML)* treinados tomando por base as heurísticas para identificação de riscos relativos a causas externas acidentais. Após a classificação do contexto de acordo com seu grau de risco, o contexto é encaminhado para o módulo Predição de Acidentes contendo o rótulo de risco associado, caso a classificação do contexto tenha sido de risco.

O treinamento inicial do módulo Detecção de Riscos baseou-se no *dataset* gerado pelo *Apollo Simulator*. Entretanto, para que o modelo de *machine learning* possa continuamente aprender sobre o ambiente e as PAR, periodicamente ele é re-treinado com os históricos de contextos acumulados.

4.4.1.4 Predição de Acidentes

O módulo Predição de Acidentes é responsável pela computação preditiva de acidentes baseando-se no provisionamento dos contextos com suas classificações prévias de risco associadas, obtidas pelo módulo de Gerenciador de Contextos. A predição é realizada aplicando-se o método *Hidden Markov Model (HMM)* cotejando-se os históricos de contextos recentes processados pelo módulo Detecção de Riscos com os históricos de contextos armazenados no banco de dados Históricos de Contextos. Este módulo é central para o modelo Apollo, pois viabiliza a predição de acidentes, permitindo a antecipação aos incidentes via comunicação com o módulo Notificações e Ações. O objetivo principal deste módulo portanto é auxiliar a PAR e cuidadores, prevenindo acidentes que coloquem a saúde e a integridade das PAR em risco.

Ao final de cada fluxo de processamento de identificação de riscos e predição de acidentes, o Apollo utiliza o componente Notificações e Ações para centralizar as mensagens a serem comunicadas à PAR, Cuidadores ou para o ApolloBot sobre riscos presentes e possíveis acidentes. O componente Notificações e Ações é construído com base na arquitetura de filas de mensagens. Fila de mensagens é um tipo componente de engenharia de software utilizado para a comunicação entre processos ou *threads* de um mesmo processo. Deste modo, quando os resultados das análises realizadas pelos módulos de Identificação de Riscos e Predição de Acidentes são finalizadas, estas informações são enviadas para a fila de mensagens para que a aplicação da PAR, do Cuidador ou ApolloBot possam coletar via *API* do módulo Web Service. A aplicação consumidora, construída externa-

mente, que é utilizada pelos atores externos, realiza a requisição dos dados para o Apollo via *API* disponibilizada para acesso pelo componente *Web Service*. A aplicação consumidora recebe os dados processados pelo Apollo, e então, se encarrega de realizar as notificações da *PAR* e *Cuidador* ou as ações a serem realizadas pelo *ApolloBot*.

A *Predição de Acidentes* é realizada pelo método de *Hidden Markov Model (HMM)* treinado pelo *dataset* de históricos de contextos do modelo Apollo. Portanto, o mesmo *dataset* gerado pelo *Apollo Simulator* para o treinamento do modelo de *machine learning* para a identificação de riscos é utilizado para o treinamento do *HMM* que atua na predição de acidentes, baseando-se no mapeamento da transição de estados dos históricos de contextos armazenados.

Quando o módulo de *Predição de Acidentes* computa contextos com probabilidade de ocorrência de acidente, o módulo *Notificações e Ações* recebe entradas para sua fila de mensagens com prioridade proporcional à gravidade do acidente predito.

A *Interface da PAR*, *Interface do Cuidador* ou a *Interface do ApolloBot* coletam as respectivas mensagens armazenadas no módulo *Interface da Notificações e Ações* para notificar ou atuar no ambiente de acordo com o acidente predito.

4.4.1.5 Notificações e Ações

O módulo de *Notificações e Ações* é responsável por armazenar os registros de notificações por ordem de prioridade nas filas de mensagens da *PAR*, *Cuidador* e *ApolloBot*, para a posterior coleta pelos atores da *Camada de Consumo*. Basicamente a *API* do módulo *Notificações e Ações* possui um método para armazenamento da mensagem contendo o objeto relativo ao risco ou acidente e outro método para a coleta destas mensagens.

A *Camada de Consumo* requisita periodicamente as mensagens armazenadas para os agentes *PAR*, *Cuidador* e *ApolloBot*. Três filas de mensagens com priorização são implementadas. Deste modo os agentes *PAR*, *Cuidador* e *ApolloBot* requisitam por intermédio do módulo *Interface do Servidor Apollo* as suas respectivas mensagens. As mensagens coletadas pelos agentes são excluídas da fila pelo módulo *Notificações e Ações*. A mensagem armazenada na fila contém um objeto no *format JSON* contendo os atributos a serem renderizados pelos agentes clientes, de acordo com a interface de usuário do respectivo endpoint.

4.4.1.6 Históricos de Contextos

O módulo de *Históricos de Contextos* encapsula os métodos de acesso ao banco de dados relacional do modelo Apollo. Quatro métodos são expostos para consumo pelo módulo *Gerenciador de Contextos*: (a) Armazenamento de contexto; (b) Consulta de Contexto por perfil; (c) Consulta de contexto por ambiente; e, (d) Consulta de históricos de contextos, parametrizável por perfil, ambiente e período.

As tabelas e relacionamentos do banco de dados relacional do módulo *Históricos de*

Contextos são padronizadas tomando por base a ontologia do modelo Apollo, a ApolloOnto.

4.4.2 Camada de Consumo

A Camada de Consumo considera a PAR como a entidade principal que deve receber as notificações em forma de alertas ou recomendações, de acordo com o seu perfil e contexto de risco. Para isso, o componente *Interface* da PAR é implementado como um *Web API* orientado ao *Design Pattern Micro API* baseado no padrão arquitetural de Arquitetura Limpa. Neste caso, uma arquitetura de nuvem em borda que recebe requisições de notificações do Sistema Multi-Agente (SMA) (PADGHAM; WINIKOFF, 2004) implantado no *endpoint* do cliente. Por sua vez, a *Interface* da PAR realiza requisições para a *Interface* do Servidor Apollo, que implementa um *Web Service* contendo em sua *API* métodos para coleta de mensagens na fila armazenada no módulo *Notificações e Ações*.

A PAR utiliza um dispositivo que implementa a *Interface* da PAR como um agente do SMA da Camada de Consumo. O agente *Assistente PAR* pode ser implementado como aplicativo para *smartphone*, aplicativo para *smartglass*, aplicativo para *smartwatch*, assistente pessoal por comando de voz ou outras formas de interação que sejam mais adequadas de acordo com o grau de limitação ou necessidade da PAR.

O *Cuidador* é a entidade que representa a rede de apoio à PAR, podendo concretizar-se como pais, filhos, cuidadores ou profissionais da área da saúde. A *Interface* do *Cuidador* segue o mesmo padrão arquitetural e tecnológico da *Interface* da PAR. Neste caso, o *Cuidador* utiliza um dispositivo que implementa a *Interface* do *Cuidador* como o segundo agente do SMA da Camada de Consumo, chamado agente *Assistente Cuidador*.

O *ApolloBot* é a abstração do ator não humano que atua como entidade inteligente automatizada de apoio no ambiente inteligente. Esta entidade pode ser concretizada como dispositivos inteligentes de *IoT* do *Aml*, ou especialmente robôs de serviço móveis que podem executar ações físicas de atuação no ambiente ou de comunicação com a PAR. Como ações físicas o *ApolloBot* pode remover obstáculos do ambiente, desativar terminais elétricos ou eliminar focos de umidade, por exemplo. Como ações virtuais o *ApolloBot* pode realizar ações como realizar diálogos com o PAR validando seu estado de saúde, apoiando em sua educação, comunicando algum artigo ou notícia relevante conforme sua necessidade ou ainda acionando o *Cuidador* ou os serviços de emergência em situações de alto risco ou acidentais. A *Interface* do *ApolloBot* segue o mesmo padrão arquitetural e tecnológico da *Interface* da PAR e *Interface* do *Cuidador*. Neste caso, o *ApolloBot* implementa a *Interface* *ApolloBot* como o terceiro agente do SMA da Camada de Consumo, nomeado agente *Assistente ApolloBot*.

A metodologia para desenvolvimento de Sistema Multi-Agente (SMA) Prometheus (PADGHAM; WINIKOFF, 2004) foi adotada para a modelagem dos agentes de software do Apollo, abrangendo desde a modelagem até a implementação. É composta por três fases, onde os artefatos produzi-

dos são utilizados tanto na geração do esqueleto do código, como também para depuração e teste. A especificação do sistema compreende duas atividades: determinar o ambiente do sistema e determinar os objetivos e funcionalidades do sistema. O ambiente do sistema é definido em termos de percepções (informações provenientes do ambiente) e ações. Ela foi idealizada para se obter um processo que possa ser utilizado para desenvolver agentes inteligentes do tipo *Belief – Desire – Intention (BDI)* (PADGHAM; WINIKOFF, 2004).

A Figura 8 apresenta o diagrama do Sistema Multiagente contendo os cinco agentes que estão presentes na Camada de Consumo e Camada de Provisionamento do modelo Apollo. Os agentes PAR e Cuidador possuem a percepção Detecta Notificações que realiza requisições periódicas para a *Web API* Interface da PAR e Interface do Cuidador, respectivamente, consumindo notificações disponíveis coletadas da fila de mensagens do módulo Notificações e Ações da Camada Servidor. O retorno para esta requisição é um objeto no formato *JSON* que é entregue pelo agente à rotina interna da aplicação da PAR e Cuidador para que a notificação seja reproduzida de acordo com as preferências de interface do usuário.

O agente ApolloBot possui a percepção Detecta Ações e a ação Aciona Atuadores. A percepção Detecta Ações realiza requisições periódicas para a *Web API* Interface do ApolloBot consumindo ações disponíveis coletadas da fila de mensagens do módulo Notificações e Ações da Camada Servidor. O retorno para esta requisição é um objeto no formato *Unified Robotic Description Format (URDF)* compatível com *Robot Operating System (ROS)* e Gazebo. O *URDF* é um arquivo no formato *XML* usado no sistema operacional ROS que descreve todos os elementos do robô. O arquivo *URDF* é entregue pelo agente à rotina interna da aplicação do ApolloBot para que a ação seja reproduzida de acordo com as preferências de interface do usuário. Se a ação recebido demandar o uso de atuadores, como por exemplo um braço mecânico ou o deslocamento do robô de serviço pelo ambiente inteligente, a ação Aciona Atuadores do agente ApolloBot encaminha os dados de localização ou movimentação do braço mecânico de acordo com as coordenadas recebidas.

Por fim, a percepção Verifica Link Internet presente nos três agentes da Camada de Consumo, realizam periodicamente a verificação de acesso à internet, gerando notificações locais específicas quando o acesso apresenta-se em estado de falha. Quando o link está operando normalmente, não ocorrem notificações para o usuário PAR, Cuidador ou ApolloBot.

4.4.3 Camada de Provisionamento

Os Dispositivos da PAR e os Dispositivos do AI compõem a Camada de Provisionamento de dados de contexto e consideram os componentes físicos de coleta de dados das pessoas e do ambiente com seus objetos, respectivamente. *Smartphones*, *smart-watches*, dispositivos *IoHT*, *wearables* e outros sensores podem ser utilizados para a coleta de dados das PAR de acordo com seu perfil e necessidades. Do ambiente inteligente podem ser



Figura 8 – Diagrama SMA dos agentes do modelo Apollo.

Fonte: Elaborado pelo autor.

coletados dados oriundos de sensores, dispositivos *IoT*, câmeras, eletrodomésticos conectados e outros dispositivos que possam captar dados do ambiente colaborando para a composição do contexto, de acordo com a disponibilidade de recursos do ambiente.

Seguindo o mesmo padrão da Camada de Consumo, a Camada de Provisionamento implementa um SMA com dois agentes: (a) agente Assistente de Provisionamento PAR e (b) agente Assistente de Provisionamento AI. Ambos podem ser implementados em diferentes linguagens e em diferentes dispositivos. A função principal destes agentes é a comunicação com o Servidor Broker submetendo dados coletados dos respectivos sensores e fontes de dados.

A Camada de Provisionamento implementa ainda um Servidor de Broker que gerencia os dispositivos inscritos via método *publish-subscribe* por mensagens assíncronas de acordo com o padrão *MQTT*. O Servidor Broker é responsável pela autorização de inclusão e exclusão de Dispositivos da PAR e Dispositivos do AI, bem como o gerenciamento do recebimento das mensagens de coleta de dados enviados pelos agentes Assistente de Provisionamento PAR e Assistente de Provisionamento AI. Por fim, o Servidor Broker comunica-se com a Interface do Servidor Apollo para a submissão do conjunto de dados coletados, que são processados pelo módulo Gerenciador de Contexto da Camada Servidor para obtenção de contextos semânticos.

Na Figura 8 visualizam-se as ações, percepções e envio de alertas dos agentes Dispositivo da PAR e Dispositivo do AI que estão presentes na Camada de Provisionamento do modelo Apollo. Os agentes Dispositivo da PAR e Dispositivo do AI possuem

a ação `Coleta Dados do Sensor` que periodicamente, de acordo com a configuração do dispositivo e sensor, coletam os dados de sinais processados. Os dados sensorizados são armazenados em memória interna do dispositivo para envio ao `Servidor Broker`. Para isso, estes agentes possuem o recurso de envio de alerta ou mensagem `Envia Broker Dados Sensores` que envia o pacote de dados coletados do ambiente inteligente, considerando dados de objetos e dos usuários, para o `Servidor Broker`.

Por fim, a percepção `Verifica Link Broker` presente nos dois agentes da Camada de Provisionamento, realiza periodicamente a verificação de comunicação com o `Broker`, gerando notificações locais específicas quando o acesso apresenta-se em estado de falha. Quando o link está operando normalmente, não ocorrem notificações para o ambiente inteligente.

Alguns recursos tecnológicos podem assumir a função de provedor e consumidor de dados concomitantemente. Em geral, *smartphones* podem ter um agente `Assistente PAR` e um agente `Assistente de Provisionamento PAR` executando em paralelo. Sendo que o primeiro agente auxiliar na notificação da PAR e o segundo agente coleta dados de sensores do dispositivo móvel.

4.5 ApolloOnto

A arquitetura do modelo Apollo considera a ontologia `ApolloOnto`, modelada especificamente para a representação do domínio de ambientes inteligentes que suportam os cuidados ubíquos. Neste sentido, as principais classes, subclasses, relacionamentos, regras e instâncias foram mapeadas e modeladas em uma estrutura ordenada que favorece a padronização da representação e armazenamento dos históricos de contextos do modelo Apollo.

Objetivando a padronização do acesso à informação, projetou-se uma ontologia, apresentada na Figura 9. A razão principal para o desenvolvimento da ontologia para os cuidados ubíquos em ambientes inteligentes, além da padronização e formalização do domínio, é a possibilidade de interoperabilidade do modelo Apollo com outros sistemas e soluções.

A ontologia `ApolloOnto` foi projetada para contemplar as entidades pertencentes ao domínio do modelo. A Figura 10 mostra em uma representação gráfica, a hierárquica das superclasses da ontologia `ApolloOnto`.

Esta ontologia foi implementada através da ferramenta `Protégé IDE` (PROTÉGÉ, 2022). O objetivo do Apollo é suportar os cuidados ubíquos em ambientes inteligentes a PAR a qualquer tempo e em qualquer lugar de acordo com seu perfil e contexto. Para satisfazer estes requisitos, a ontologia provê oito classes principais: (a) `PAR`; (b) `Cuidador`; (c) `ApolloBot`; (d) `Risco`; (e) `Acidente`; (f) `Doença`; (g) `Ambiente Inteligente`; e (h) `Contexto`.

A classe `PAR` caracteriza as instâncias das pessoas com autonomia reduzida que são os usuários centrais do modelo Apollo. No mesmo sentido, a classe `Cuidador` representa as pessoas de apoio que suportam os cuidados ubíquos das PAR. São familiares, enfermeiros, terapeutas e outros profissionais da saúde que interagem com as PAR. Finalmente a classe `ApolloBot`

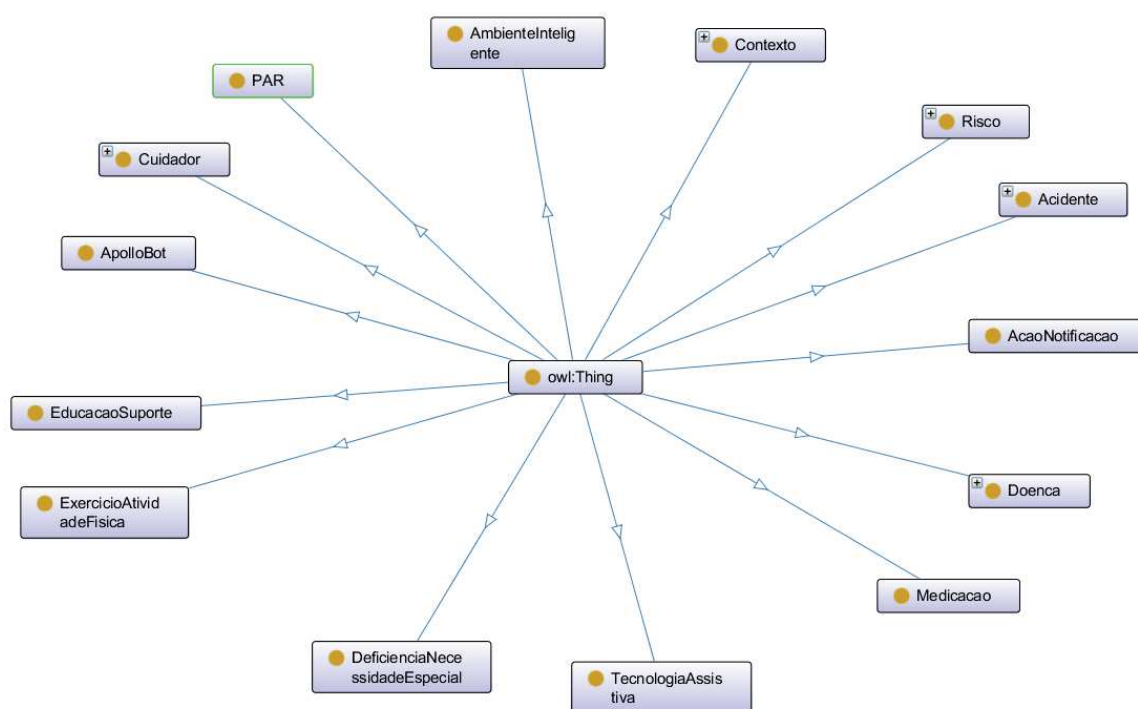


Figura 9 – ApolloOnto - Visão das superclasses no modo ramificado.

Fonte: Elaborado pelo autor.

modela o agente robotizado que pode apoiar as PAR de modo análogo à classe *Cuidador*, entretanto de modo automatizado.

As classes *Risco* e *Acidente* foram modeladas com base no domínio formalizado pela CID-10, que estabelece nos capítulos XIX as definições de acidentes por causas externas e suas consequências. Logo, a classe *Acidente* considerou 18 diferentes tipos de acidentes relacionados a causas externas acidentais. A classe *Risco* considerou 13 entradas da CID-10, em seu capítulo XX, relacionadas a riscos externos. A classe *Acidente* considerou 18 entradas da CID-10, em seu capítulo XIX, relacionadas a acidentes por causas externas. Finalmente, a classe *Doenca* caracteriza as principais doenças relacionadas às PAR e acidentes por causas externas. Considerando a similaridade entre os rótulos dos riscos e acidentes registrados na CID-10 e CID-11 e alterando somente a codificação adotada em geral para o subgrupo específico de ABCD utilizado como base para a ApolloOnto, optou-se por utilizar a codificação adotada na CID-10 dada sua ampla aplicação, conhecimento pela área médica e facilidade de mapeamento de prontuários históricos. Por fim, observou-se que as categorias escolhidas são as que mais estão relacionadas aos perfis de PAR utilizados neste trabalho e que ambas estão presentes em ambas as classificações, com pequenas diferenças em sua descrição ou código. Portanto, para fins de modelagem do domínio, não houve prejuízo em termos de cobertura técnica dos acidentes.

As classes *Risco*, *Acidente* e *Doenca* da ApolloOnto foram implementadas para es-



Figura 10 – ApolloOnto - Visão geral da hierarquia estruturada.

Fonte: Elaborado pelo autor.

trutar o domínio da aplicação da identificação de riscos e predição de acidentes das PAR em ambientes inteligentes, baseando-se nas referências oficiais de classificações internacionais CID-10 (WHO, 2019a) e a CICEL (WHO, 2022d).

A Figura 11 detalha as instâncias das classes Risco e Acidente, considerando a descrição e o código oficial obtidos da CID-10.

O Ambiente Inteligente é representado pela classe AI. Esta classe, juntamente com a PAR e a Contexto, são as principais da ApolloOnto.

A classe Contexto é central no que diz respeito aos atributos que representam a situação que é avaliada quanto a riscos e acidentes. Existem 7 subclasses que a especializam: (a) Objeto; (b) AmbienteFisico; (c) Atividade; (d) LocalizacaoSemantica; (e) PeriodoDia; (f) Saude; e, Supervisao.

A Figura 12 detalha a classe Contexto com suas subclasses e especializações.

A subclasse Atividade, em especial, representa as ações das PAR no AI. A Atividade possui Risco. A PAR possui um perfil que engloba DeficienciaNecessidadeEspecial

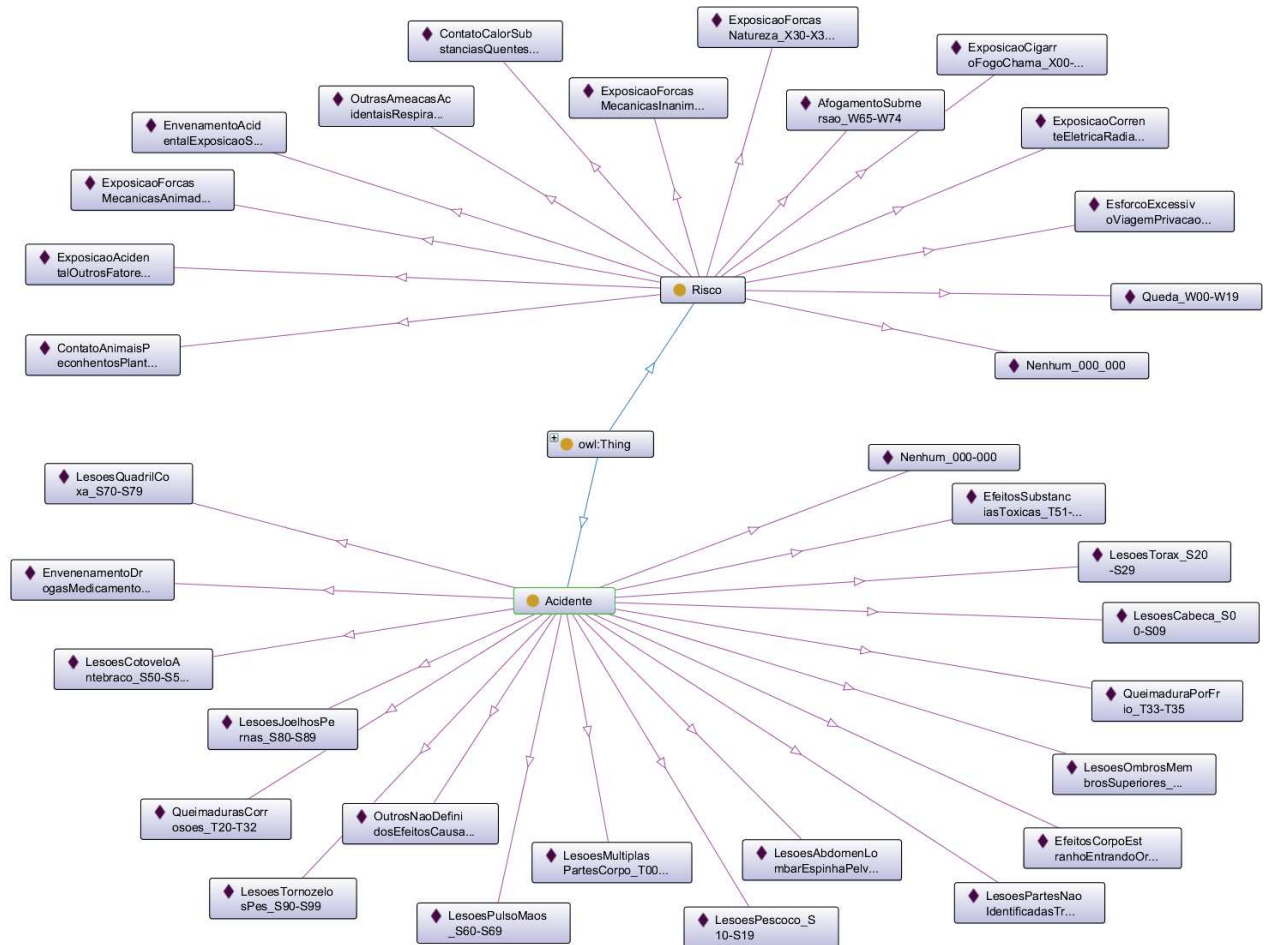


Figura 11 – ApolloOnto - Visão ramificada das classes Risco e Acidente com suas respectivas instâncias.

Fonte: Elaborado pelo autor.

e possíveis doenças prévias ou adquiridas, modeladas na classe Doença. O Risco pode ter uma categoria e um nível. O AI é composto por Objetos (estáticos ou inteligentes), modelados na subclasse Objeto.

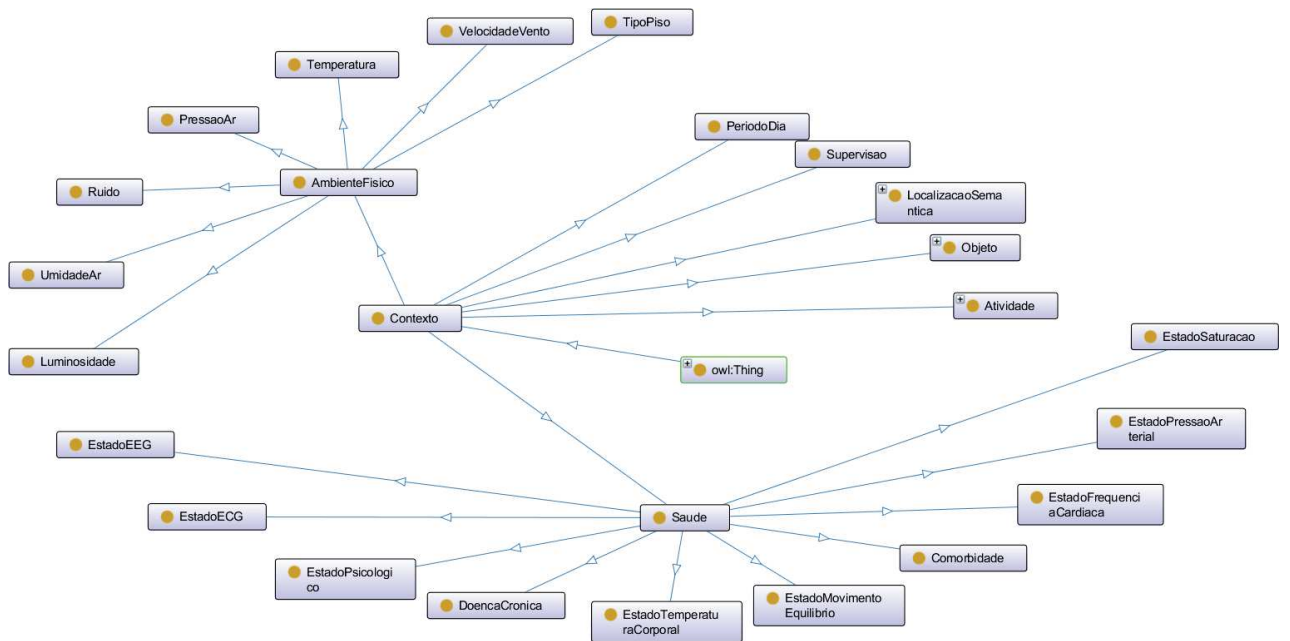


Figura 12 – ApolloOnto - Visão ramificada da classe Contexto e suas subclasses.
 Fonte: Elaborado pelo autor.

5 ASPECTOS DE IMPLEMENTAÇÃO E AVALIAÇÃO

Este capítulo engloba os aspectos de implementação e avaliação do modelo Apollo. O capítulo está dividido em três seções principais. A Seção 5.1 detalha as decisões de projeto em termos de implementação dos artefatos de *software* que compõem o modelo. São apresentadas as tecnologias e as estratégias adotadas em cada camada do Apollo. A Seção 5.2 expõe a metodologia de avaliação aplicada para mensurar a acurácia e a efetividade do modelo Apollo na detecção de riscos e na predição de acidentes, baseando-se em cenários compostos de contextos gerados pelo Apollo *Simulator*. Por fim, a Seção 5.3 traz os resultados da avaliação de acurácia para a detecção de riscos e predição de acidentes.

5.1 Artefatos de *Software*

Esta seção especifica os artefatos de *software* empregados na implementação dos módulos e componentes do modelo Apollo. A implantação do Apollo orientou-se pela arquitetura Cliente-Servidor, de modo que o módulo *Servidor Apollo* engloba os módulos disponibilizados no servidor de aplicação. Enquanto isso, as interfaces de provisionamento e consumo foram desenvolvidas seguindo as perspectivas de clientes. Além disso, os módulos foram programados tendo em vista o *design pattern Model-View-Controller (MVC)* e segmentando as camadas da aplicação. As próximas subseções detalham os módulos, componentes e tecnologias utilizadas.

5.1.1 Servidor Apollo

A Camada *Servidor*, que materializa-se como *Servidor Apollo*, foi implementada em *cloud*, utilizando-se a plataforma *Microsoft Azure* com suporte às linguagens de programação Java e Python, predominantemente usadas neste projeto. Além disso, possui suporte para o SGBDR PostgreSQL. O uso do paradigma de *cloud computing* foi adotado com vistas à escalabilidade e à maior performance para a realização dos experimentos. Outras tecnologias complementares utilizadas para a prototipação estão descritas nas subseções seguintes.

5.1.1.1 *Web Services*

A Interface do *Servidor Apollo* foi implementada como um *web service*, com *API RESTful*, em linguagem Java, utilizando-se o *framework Spring*, com servidor de aplicação web GlassFish. Estes artefatos foram hospedados em uma máquina virtual em conta particular na plataforma *Microsoft Azure*.

5.1.1.2 Sistema Multiagentes

O Sistema Multiagentes do Apollo foi modelado, utilizando-se o *Prometheus Design Tool (PDT)* (PDT, 2022), que é uma ferramenta gráfica desenvolvida como um *plugin* para o *Eclipse IDE 2021-09* (ECLIPSE, 2022), que permite o projeto de SMA, seguindo a metodologia Prometheus. O *PDT* emprega uma versão modificada da notação *Agent UML (AUML)* (PADGHAM; WINIKOFF, 2004) para exibir os protocolos de interação do sistema.

Adotou-se essa metodologia porque ela permite a criação de diversos diagramas em suas diferentes fases, possibilitando detalhar com profundidade o sistema que se pretende construir. Além disso, permite um entendimento adequado e relevante dos objetivos do sistema que se deseja implementar, adotando um padrão semelhante à UML (BOOCH GRADY; JACOBSON, 1996).

A implementação dos agentes na Camada de Consumo foi realizada na plataforma *Android*. Na Camada de Provisionamento, a materialização dos agentes aconteceu nas plataformas Arduino e ESP.

5.1.1.3 Fila de Mensagens

A Fila de Mensagens presente no módulo *Notificações e Ações da Camada Servidor* foi implementada como *gateway* de fila de mensagens assíncronas, utilizando a ferramenta *RabbitMQ 3.9*, compatível com MQTT 3.1.1, e implantada na *cloud* da *Microsoft Azure*.

5.1.1.4 Banco de Dados

O banco de dados relacional principal do modelo Apollo, que armazena os *Históricos de Contextos* padronizados pela ontologia *ApolloOnto*, foi implantado utilizando o *SGBDR PostgreSQL*. Este SGBD foi utilizado dada sua ampla utilização na indústria, vasta documentação e disponibilidade de *drivers* de conexão com as linguagens e plataformas utilizadas neste projeto.

5.1.2 Interfaces de Provisionamento

As implementações dos *Dispositivos de AI* da Camada de Provisionamento foram através das plataformas de *hardware* de baixo custo Arduino, Raspberry Pi, Bitalino e ESP. A decisão pela adoção destes dispositivos de *IoT* ocorreu dada sua ampla documentação e comunidades ativas. Além disso, possibilitam a programação nas linguagens de programação que o pesquisador domina: Java, Python e C. Estas linguagens se alinham também com as utilizadas nos demais artefatos de *software* adotados para o modelo Apollo. Por fim, estes dispositivos a comunicação *wireless* e os sensores necessários para a prototipação dos cenários

avaliados.

O Servidor Broker da Camada de Provisionamento foi implementado em servidor em *cloud* utilizando o *Broker Eclipse Mosquitto*, versão 2.0.14, compatível com *MQTT* 3.1.1 (MOSQUITTO, 2022).

5.1.3 Interfaces de Consumo

A interface de usuário da PAR e Cuidador da Camada de Consumo foi implementada utilizando o *Android Studio Bumblebee 2021.1.1*. Foram gerados aplicativos para os perfis de idosos e de surdos, tendo em vista padrões de *design* de interface priorizando a acessibilidade e *UX*.

Para o *ApolloBot*, foi implementado um modelo virtual de robô de serviço utilizando a plataforma *open source* para simulação de robôs Gazebo (ROSANSWERS, 2012). A Figura 13 apresenta a tela do simulador Gazebo com um robô de serviço executando ações em um mapa virtual.

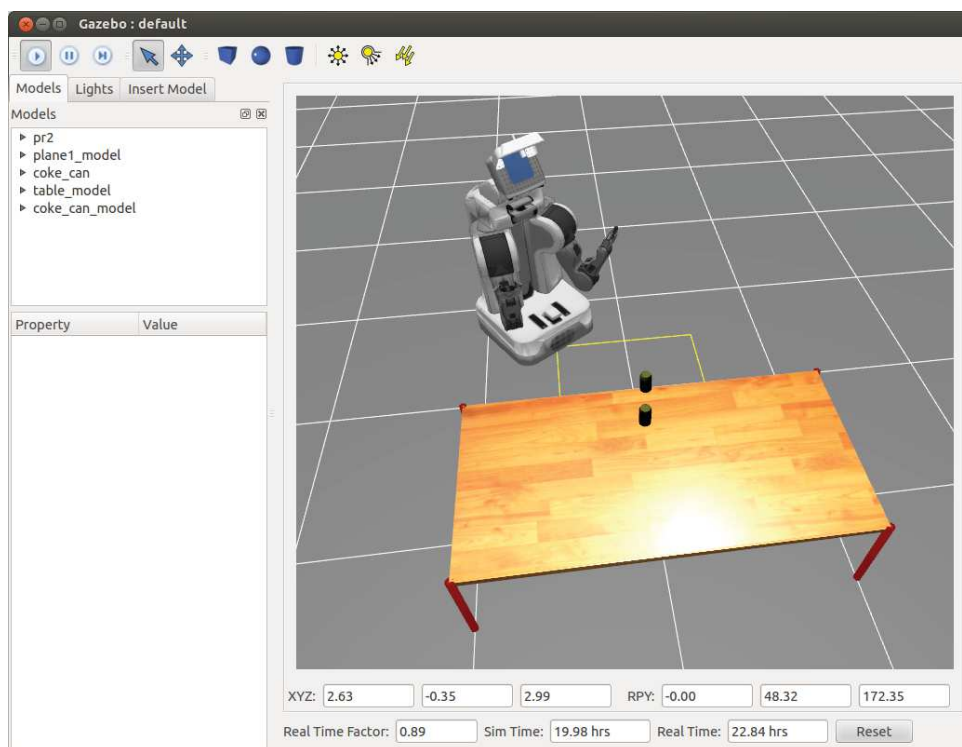


Figura 13 – Tela do simulador Gazebo utilizado para modelagem e simulação do *ApolloBot*.
Fonte: (ROSANSWERS, 2012).

O Gazebo é uma plataforma robusta mantida pela *Open Source Robotics Foundation (OSRF)*. Para validação da efetividade do *ApolloBot* de se deslocar em um ambiente *indoor*, foi implementado um cenário virtual em que ocorre a aproximação de um robô de serviço simulado a um obstáculo virtual, implementado na versão em *cloud* Gazebo *gzweb*.

5.1.4 ApolloOnto

A ontologia ApolloOnto foi projetada utilizando a IDE Protégé Desktop 5.5 (PROTÉGÉ, 2022), um editor de ontologias construído por Mark Musen, em 1987, e, desde então, mantido por um laboratório da Universidade de Stanford. Para a geração dos diagramas de visualização das classes e subclasses ramificados, foi utilizado o plugin *OntoGraf*.

Após a conclusão da modelagem, foi realizada a exportação da ApolloOnto, em linguagem OWL, para o formato XML/RDF, permitindo sua integração no banco de dados de Históricos de Contextos do modelo Apollo.

5.1.5 Apollo Simulator

O Apollo *Simulator*, é um simulador gerador de contextos de risco de PAR em ambientes inteligentes que possibilita a criação de *datasets* sintéticos, evitando a exposição de PAR aos riscos de saúde inerentes aos contextos experimentados nesta pesquisa. Para a geração de amostras de contextos simulados, similares aos reais, o Apollo *Simulator* se baseou em heurísticas, parâmetros específicos por perfil e de riscos pesquisados no estado da arte e, então, validados por especialistas da área da saúde.

O Apollo *Simulator* agrega, além da vantagem da não exposição das PAR a situações de risco, a escalabilidade na geração de amostras e a customização de *datasets* de acordo com ambientes, perfis ou necessidades específicas.

O *software* do Apollo *Simulator* foi implementado utilizando a linguagem Java Versão 8, JDK 12. A interface de usuário que permite a seleção visual dos estados dos atributos do contexto foi desenvolvida com uso da biblioteca Java Swing.

A Figura 14 mostra a tela principal do Apollo *Simulator*, contendo na parte superior 30 listas de seleção, correspondentes aos 30 atributos de contexto mapeados (`att_0` a `att_29`). O mapeamento se deu a partir da Tabela 22, cuja estrutura de dicionário está organizada na Tabela 23, ambas situadas no Apêndice A.

Além disso, esta interface apresenta na parte inferior: (a) uma área de texto, para exibição dos contextos gerados pelo simulador; (b) uma caixa de texto, para definição da quantidade de amostras a serem geradas automaticamente pelo simulador; (c) um botão `Gerar Aleatórios`, para gerar a quantidade randomizada de contextos de não-risco especificada na caixa de texto; e, (d) um botão `Gravar Contexto`, para gerar uma amostra única baseada na seleção de estados dos 30 atributos das listas realizada pelo modelador.

O Apollo *Simulator* foi projetado para automatizar e facilitar a gestão de contextos de riscos, possibilitando a geração de *datasets* com amostras supervisionadas. Neste sentido, os contextos gerados pelo Apollo *Simulator* podem ser de dois tipos: (a) gerado manualmente; ou, (b) gerado aleatoriamente.

A geração manual de um contexto demanda do usuário a escolha de uma opção para cada

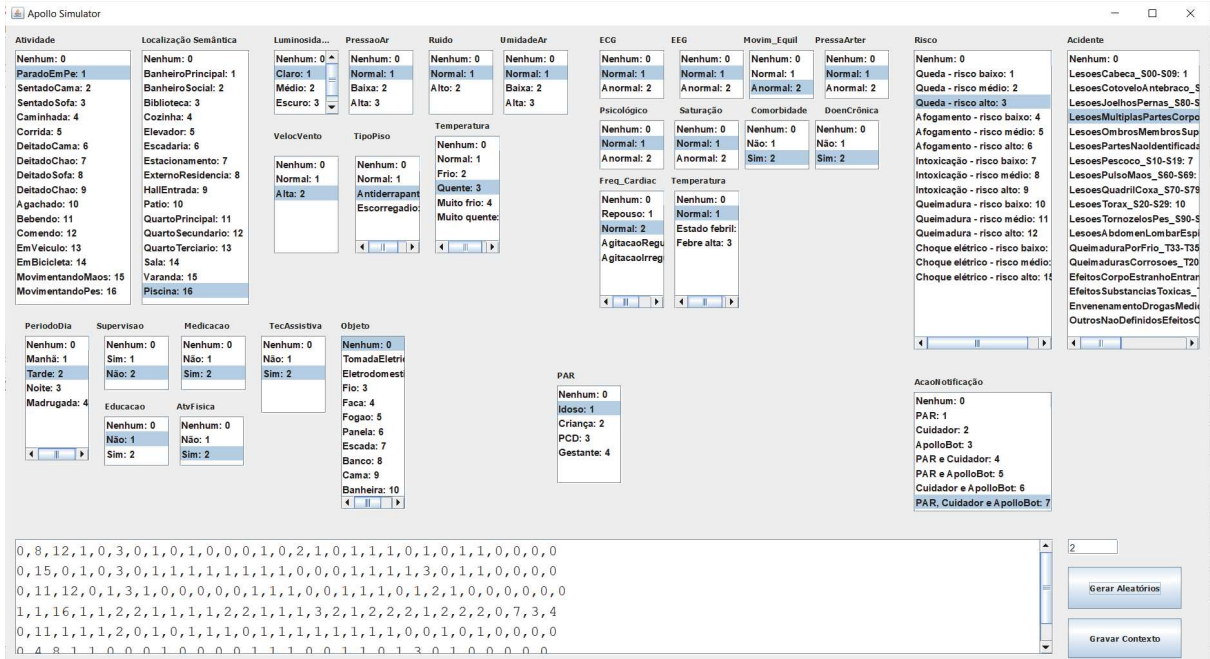


Figura 14 – Tela principal do Apollo Simulator.

Fonte: Elaborado pelo autor.

uma das 30 listas disponíveis na interface principal, de modo que a combinação das seleções realizadas reflitam um contexto modelado da realidade. Os contextos gerados de forma manual podem ser classificados como *risco* ou *não-risco*, a critério do modelador.

O processamento aleatório de contextos gera apenas contextos classificados como *não-risco*, visando garantir que as amostras geradas em lote não contenham contextos de *risco* e que tenham sido devidamente rotuladas e validadas pelo modelador. Logo, a automação na geração aleatória de amostras de contexto de *não-risco* potencializa a escalabilidade dos testes, demandando um mínimo esforço por parte do operador. Deste modo, para controlar a geração de instâncias de *não-risco* apenas pelo modo randômico, foram estabelecidos previamente estados ordenados na modelagem dos atributos do dicionário da classe *Risco* da ontologia *ApolloOnto*. Partiu-se do valor *nenhum*: 0, que representa um estado indiferente, progredindo-se para estados mais severos ou críticos, especificamente mapeados para cada atributo, conforme apresentado na Tabela 23 no Apêndice A. Esta estratégia possibilitou a definição de limiares de *não-risco* para os 30 atributos, com estabelecimento dos estados ordenados do menos crítico ao mais severo.

Cada sessão de modelagem de contextos realizada no *Apollo Simulator* pode contemplar tanto contextos de *risco* quanto de *não-risco*. Inclusive, permite na geração combinar amostras geradas de modo manual e aleatório. O simulador concatena os contextos sequencialmente, conforme a ordem cronológica de geração. Após cada sessão de geração de contextos, o conjunto de contextos é armazenado na base de dados de históricos de contextos. Após o armazenamento no BD, para fins de geração de *datasets* para a concepção do modelo de *machine learning*, foi realizada uma seleção de atributos considerando todos os 30 campos armazenados,

excetuando os atributos `att_27` e `att_29`.

O atributo `att_27` `AcaoNotificacao` serve de referência para o modelo Apollo identificar qual o tipo de notificação ou ação a ser realizada quando a amostra detectada é de risco. O atributo `att_29` `Acidente` é o atributo que correlaciona o risco ao possível acidente associado. Estes atributos foram removidos da camada de *machine learning*, pois experimentos realizados demonstraram que poderiam contribuir para um viés no modelo de aprendizado de máquina, sendo, portanto, atributos ignorados nesta fase.

A Figura 15 apresenta um exemplo de *dataset* de classificação multiclasse, gerado a partir do Apollo *Simulator*, compreendendo os 30 atributos de contexto representados no modelo *Comma-separated values (CSV)*, de acordo com o formato regulamentado pela RFC 4180 (IETF, 2005). Este formato foi adotado por ser um padrão aberto e seguindo boas práticas de desacoplamento de *software*. Além do armazenamento no banco de dados de históricos de contextos do modelo Apollo, este arquivo CSV pode ser integrado com outros sistemas.

```

1 att_0,att_1,att_2,att_3,att_4,att_5,att_6,att_7,att_8,att_9,att_10,att_11,att_12,att_13,att_14,att_15
,att_16,att_17,att_18,att_19,att_20,att_21,att_22,att_23,att_24,att_25,att_26,att_27,att_28,att_29
2 0,8,12,1,0,3,0,1,0,1,0,0,0,1,0,2,1,0,1,1,1,0,1,0,1,1,0,0,0,0,0
3 0,15,0,1,0,3,0,1,1,1,1,1,1,1,1,0,0,0,1,1,1,1,3,0,1,1,0,0,0,0
4 0,11,12,0,1,3,1,0,0,0,0,0,1,1,1,0,0,1,1,1,0,1,2,1,0,0,0,0,0,0
5 1,1,16,1,1,2,2,1,1,1,1,2,2,1,1,1,3,2,1,2,2,2,1,2,2,0,7,3,4
6 0,11,1,1,1,2,0,1,0,1,1,1,0,1,1,1,1,1,1,1,1,1,0,0,1,0,1,0,0,0
7 0,4,8,1,1,0,0,0,1,0,0,0,0,1,1,1,0,0,1,1,0,1,3,0,1,0,0,0,0,0
8 2,5,16,1,1,2,1,1,1,1,1,1,1,1,1,3,3,1,1,2,2,1,1,1,1,0,4,5,18
9 0,15,0,1,0,3,0,1,1,1,1,1,1,1,1,0,0,0,1,1,1,1,3,0,1,1,0,0,0,0
10 0,11,12,0,1,3,1,0,0,0,0,0,1,1,1,0,0,1,1,1,0,1,2,1,0,0,0,0,0,0
11

```

Figura 15 – Recorte de parte de *dataset* de classificação multiclasse gerado pelo Apollo *Simulator*.

Fonte: Elaborado pelo autor.

5.2 Avaliação da Acurácia de Detecção de Riscos e Predição de Acidentes Baseada em Contextos Sintéticos

A metodologia utilizada para a avaliação da acurácia dos módulos de Detecção de Riscos e Predição de Acidentes para detectar contextos de risco e acidentes, respectivamente, consistiu em um fluxo composto de onze etapas, conforme apresentado na Figura 16.

A Etapa 1 consistiu na realização de uma pesquisa bibliográfica, com consulta à literatura especializada da área médica e bases de dados que tratassem do tema de acidentes por causas externas (DATASUS, 2019; CELINO et al., 2021; SPSP, 2017; WHO, 2021). Os cinco acidentes mais citados foram: (a) Queda; (b) Afogamento; (c) Choque elétrico; (d) Queimadura; e, (e) Consumo indevido de medicamento ou envenenamento.

O livro *The Second Fifty Years: Promoting Health and Preventing Disability* organizado pelo *Institute of Medicine (US) Division of Health Promotion and Disease Prevention* (ROBERT L. BERG JOSEPH S. CASSELLS, 1992) e o relatório da OMS *WHO Global Report on Falls*

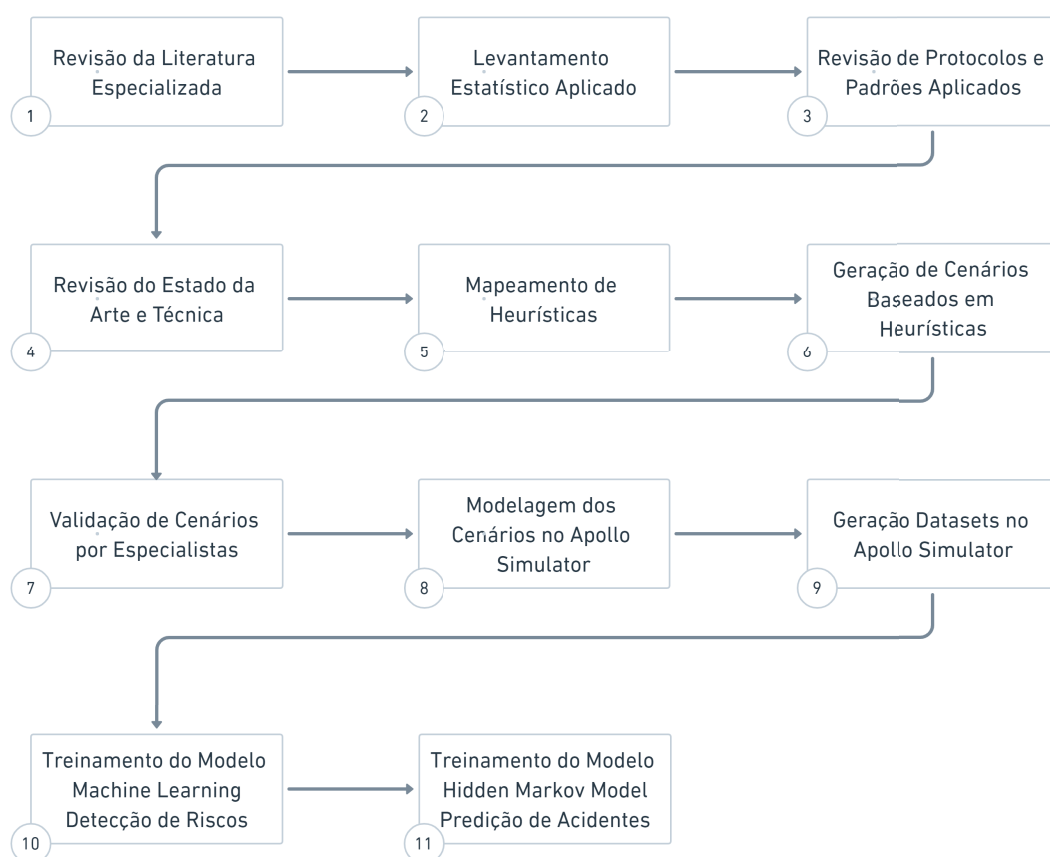


Figura 16 – Metodologia de avaliação de contextos de riscos e acidentes do modelo Apollo.

Fonte: Elaborado pelo autor.

Prevention in Older Age (WHO, 2008), serviram de base para a extração de fatores, atributos e parâmetros relativos a quedas.

Para o acidente de afogamento foram identificadas pesquisas e iniciativas visando a prevenção e a conscientização quanto aos riscos, de modo que foi possível levantar as principais causas e riscos (RICHARDS, 2021; CBMPB, 2021; UN, 2021).

Para o acidente choque elétrico, foram selecionadas publicações com informações relevantes para o mapeamento dos atributos e parâmetros relacionados a contextos acidentais por choque elétrico sofridos por crianças e adultos (ENGEHALL, 2022; EDERALDO LUIZ BELINE, 2018; SERRA et al., 2011; RUNDE, 2020).

Por fim, para o acidente queimadura foram investigadas fontes científicas, órgãos governamentais da área da saúde e organizações internacionais que dedicam-se à prevenção e cuidados das pessoas (WHO, 2018; SBP, 2014; BVSMS, 2014; BRODZKA; THORNHILL; HOWARD, 1985; CRUZ; CORDOVIL; BATISTA, 2012).

Na Etapa 2, realizou-se a pesquisa por estatísticas globais acerca dos acidentes por causas externas reportados com maior frequência. As bases de dados, relatórios e publicações da OMS (OMS, 2021) e TabNet do DATASUS (DATASUS, 2021), foram as principais fontes de pesquisa. Os cinco acidentes com maior frequência foram: (a) Queda de idosos; (b) Afoga-

mento infantil; (c) Choque elétrico infantil; (d) Queimadura de pessoas em geral; e, (e) Sufocação de bebês.

A revisão de protocolos e padrões da área médica aplicados aos acidentes por causas externas foram pesquisados na Etapa 3, afim de estabelecer de um marco técnico na definição da terminologia e projeto da Ontologia. CID-10 (WHO, 2019a), CID-11 (WHO, 2022a) e CICEL (WHO, 2022d) foram as principais referências encontradas.

A Etapa 4 consistiu na pesquisa de artigos científicos e tecnologias aplicadas aos cuidados ubíquos de PAR que corroborassem com o levantamento dos acidentes mais frequentes. Portanto, o objetivo desta etapa foi validar se já existiam iniciativas científicas para endereçar os acidentes mapeados e qual estratégia estes estudos estavam aplicando.

Na Etapa 5, foram mapeadas as heurísticas para os quatro tipos de acidentes mais frequentes: (a) queda; (b) afogamento; (c) choque elétrico; e (d) queimadura. Ou seja, foram definidas as etapas e os atributos mais relevantes para a caracterização destes acidentes, identificando a sequência de riscos associados a cada incidente.

A geração de 15 cenários-base orientados às heurísticas mapeadas foi realizada na Etapa 6. Os cenários-base foram registrados para a posterior validação por especialistas. A Tabela 19 (Apêndice A), apresenta a relação dos cenários-base com suas respectivas descrições.

Na Etapa 7, os 15 cenários gerados foram validados por cinco participantes, sendo 3 especialistas da área da saúde e 2 familiares de PAR. A Tabela 20 (Apêndice A), mostra a relação de especialistas que colaboraram com este estudo voluntariamente para a validação dos cenários gerados. A Tabela 21 (Apêndice A) apresenta a relação de cenários validados por cada especialista.

A técnica de entrevista foi utilizada para a validação dos cenários por parte dos especialistas. Esta técnica foi escolhida levando em consideração a grande abrangência de possíveis situações em que a PAR possa se encontrar e buscando checar se estes e os atributos definidos estavam coerentes com a realidade da prática profissional. Isso porque há uma série de possíveis situações em que a PAR pode se encontrar. De acordo com Ribeiro (2012), recorre-se à entrevista sempre que se tem necessidade de obter dados que não podem ser encontrados em registros e fontes documentais, podendo estes serem fornecidos por determinadas pessoas. Ainda, segundo Ribeiro (2012), a entrevista é a técnica mais pertinente quando o pesquisador deseja obter informações a respeito do seu objeto, que permitam conhecer sobre atitudes, sentimentos e valores subjacentes ao comportamento, o que significa que se pode ir além das descrições das ações, incorporando novas fontes para a interpretação dos resultados pelos próprios entrevistadores.

As entrevistas foram realizadas com os voluntários que se encaixam nas posições de cuidador, sendo um familiar ou um profissional da saúde. As entrevistas foram realizadas, via vídeochamada por um aplicativo para *smartphone*, e foram gravadas e salvas para posterior análise, de acordo com o consentimento dos entrevistados. O perfil dos cinco entrevistados é diverso e é composto por cuidadores que possuem experiência entre 8 e 19 anos atuando no cuidado de PAR. No que diz respeito à ocupação, 60% dos entrevistados têm como profissão a área da saúde, cuidador

de idosos e/ou cuidador de crianças, ou possuem relação cotidiana com surdos, sendo os outros 40% dos entrevistados familiares de PAR. A Tabela 20 (Apêndice A) detalha o perfil cinco dos entrevistados.

Por meio das entrevistas realizadas, foi possível construir a síntese dos dados e identificar atividades em comum realizadas por PAR que podem ser identificados como perigosas à saúde e à segurança. Como resultado das entrevistas, os cenários identificados anteriormente com base na literatura foram validados.

Após a validação dos cenários, foi realizada a modelagem, com uso do *Apollo Simulator*, na Etapa 8, ou seja, os atributos relacionados a cada cenário foram definidos na interface do simulador para a geração das amostras categorizadas referentes a cada cenário validado. A Tabela 22 (Apêndice A) apresenta os 30 atributos mapeados com sua respectiva classe ontológica e descrição. A Tabela 23 (Apêndice A) apresenta os valores dos estados dos 30 atributos mapeados de modo a caracterizar a estrutura do dicionário da estrutura de dados do modelo *Apollo*.

A Tabela 24 (Apêndice A) mostra os 15 cenários-base utilizados para a geração de instâncias de contextos. Do cenário CE1 ao CE3 apresentam-se os cenários modelos de contextos de não-risco. Entre os cenários CE4 e CE15 encontram-se os modelos de contextos classificados como risco. Todos os cenários-base e as instâncias de cenários derivadas destes, foram modelados no *Apollo Simulator* e deram origem ao *dataset* de treinamento dos modelos de *machine learning* e *HMM*.

Na Etapa 9 foi gerado o *dataset* contendo as amostras que foram utilizadas para a modelagem dos algoritmos de *machine learning* e modelo *HMM*. As amostras do *dataset* foram segmentadas e rotuladas entre *risco* e *não-risco*. As amostras de *risco* foram geradas com base nos cenários validados e considerados como *ground-truth* para esta pesquisa. As amostras de *não-risco* foram geradas majoritariamente pela rotina de geração aleatória de amostras do *Apollo Simulator*. O *dataset* criado englobou 1.152 instâncias por amostragem não-estatística geradas por conveniência para a pesquisa.

A sequência dos 12 contextos dos cenários-base de treinamento com desfecho de risco elaborados, seguem o padrão: *nao_risco* - *risco_baixo* - *risco_medio* - *risco_alto* até a ocorrência do acidente. Os 3 contextos dos cenários de treinamento com desfecho de não-risco seguem o padrão: *nao_risco* - *nao_risco* - *nao_risco* - *nao_risco*, sem a ocorrência de acidente.

A Etapa 10 consistiu no preparo do modelo de classificação supervisionado de *machine learning*, treinado com base no *dataset* gerado pelo *Apollo Simulator*. Nesta etapa, avaliou-se a acurácia do modelo de aprendizado de máquina em detectar amostras contendo contextos de risco.

Por fim, na Etapa 11, o modelo *Hidden Markov Model (HMM)* foi treinado com base nas transições de estados dos contextos de riscos que resultaram em acidentes, baseando-se no *dataset* de base gerado. Nesta etapa, avaliou-se a acurácia do modelo *HMM* em prever as sequências de amostras contendo contextos de acidente.

As próximas seções tratam especificamente da abordagem da avaliação dos módulos de Detecção de Riscos e de Predição de Acidentes.

5.2.1 Detecção de Riscos

A avaliação da acurácia do módulo Detecção de Riscos utilizando técnicas de aprendizado de máquina, considerou o *dataset* gerado pelo *Apollo Simulator*, conforme descrito na Seção 5.3.

A Tabela 14 sintetiza a distribuição não-balanceada das amostras utilizadas para o treinamento dos algoritmos de aprendizado de máquina, sendo 96,4% de cenários de não-*risco* e 3,6% de cenários de *risco*.

Tabela 14 – Síntese do *dataset* gerado pelo *Apollo Simulator* para treinamento dos modelos de *machine learning*.

Descrição	Quantidade	%
Amostras de cenários de não- <i>risco</i>	1.110	96,4
Amostras de cenários de <i>risco</i>	42	3,6
Total de amostras	1.152	100,0

As 42 amostras, ou 3,6% do total foram cenários de baixo, médio ou alto risco, que foram gerados pelo *Apollo Simulator* e rotulados manualmente de acordo com os valores definidos para o atributo *att_28* da Tabela 23 (Apêndice A). Estas amostras são consideradas como verdadeiros positivos para a avaliação da acurácia do módulo Detecção de Riscos.

A 42 amostras de risco são resultado da composição de 15 cenários de risco distintos. Sendo que deste, 12 cenários de risco originaram-se diretamente dos 12 cenários-base mapeados na Tabela 24 (Apêndice A) e mais 3 cenários foram derivações dos cenários-base, e, portanto, repetem este padrão, com variações nos atributos. Esta estratégia foi adotada para a geração de cenários que contemplem contextos semelhantes com variações de atributos do contexto ou perfil da PAR. Além disso, estas variações possibilitam o mapeamento de diferentes sequências de contextos que oportunizam uma maior similaridade com a realidade e favorecem, portanto, o treinamento de um modelo *HMM* mais realista. O *dataset* completo gerado pelo *Apollo Simulator* com comentários sobre todos os cenários gerados encontra-se disponível no Google Drive ¹.

As 1.110 amostras de não-*risco*, ou os 96,4% remanescentes, foram rotuladas automaticamente pelo *Apollo Simulator* com o valor 0, equivalente ao estado Nenhum no atributo *att_28*, de modo análogo aos exemplares de risco. Estas amostras são consideradas como verdadeiros negativos para a avaliação da acurácia do módulo Detecção de Riscos.

A Tabela 15 mostra a distribuição das amostras de cenários por tipo de risco mapeado. Foram geradas 1.015 amostras, ou aproximadamente 88% do total de cenários ordinários rep-

¹https://drive.google.com/file/d/15lmv-k0o6i1Do4E6gIvGAXdaMlWJQY_p/view?usp=sharing

resentando AVDs. As 40 amostras, ou 3,4%, cobrem o cenário assistindo TV. Outras 55 amostras, ou 4,7% do total, foram modeladas em base ao cenário dormindo. Foram gerados ainda 14 cenários de queda (1,2%), 13 de afogamento (1,2%), 9 de queimadura (0,9%) e 6 de choque elétrico (0,6%).

Tabela 15 – Distribuição das amostras de cenários por tipo de risco mapeado presentes no *dataset* gerado pelo *Apollo Simulator* para treinamento dos modelos de *machine learning*.

Descrição	Quantidade	%
C1 - Atividade da Vida Diária (AVD) ordinária	1.015	88,0
C2 - Assistindo TV	40	3,4
C3 - Dormindo	55	4,7
C4 - Queda - Risco baixo	3	0,3
C5 - Queda - Risco médio	6	0,5
C6 - Queda - Risco alto	5	0,4
C7 - Afogamento - Risco baixo	4	0,4
C8 - Afogamento - Risco médio	4	0,4
C9 - Afogamento - Risco alto	5	0,4
C10 - Queimadura - Risco baixo	3	0,3
C11 - Queimadura - Risco médio	3	0,3
C12 - Queimadura - Risco alto	3	0,3
C13 - Choque elétrico - Risco baixo	2	0,2
C14 - Choque elétrico - Risco médio	2	0,2
C15 - Choque elétrico - Risco alto	2	0,2
Total de cenários	1.152	100,0

Na Tabela 16, visualiza-se que a distribuição das amostras por perfil seguiu um padrão de distribuição balanceado. Cerca de 81% das amostras foram geradas relacionadas a PAR, sendo 20,7%, Idoso, 21,8% Criança, 19,5% PCD e 19,0% Gestante. Os 19,0% restantes foram modelados para o perfil genérico Nenhum.

Tabela 16 – Distribuição das amostras de cenários por perfil mapeado no *dataset* gerado pelo *Apollo Simulator* para treinamento dos modelos de *machine learning*.

Descrição	Quantidade	%
Nenhum	219	19,0
Idoso	239	20,7
Criança	250	21,8
PCD	225	19,5
Gestante	219	19,0
Total de amostras	1.152	100,0

O *dataset* gerado pelo *Apollo Simulator* utilizado para a modelagem do modelo de aprendizado de máquina está publicamente disponível no repositório Drive do pesquisador². Utilizou-

²https://drive.google.com/file/d/1lLiMSZ_ztOPzdoqcCmsuPaQWHhM1FOLA/view?usp=sharing

se o *framework* PyCaret (PYCARET, 2022) executando em um *notebook* hospedado no ambiente de desenvolvimento em *cloud* Google Colaboratory (Colab) (GOOGLE, 2022). O *notebook* desenvolvido para automação dos experimentos de modelagem de *machine learning* também está disponível publicamente³. A Figura 17 mostra a síntese dos 28 atributos utilizados na fase de preparação do modelo de aprendizado de máquina.

```
<class 'pandas.core.frame.DataFrame'>
RangeIndex: 1152 entries, 0 to 1151
Data columns (total 28 columns):
#   Column   Non-Null Count  Dtype
---  -
0   att_0    1152 non-null    int64
1   att_1    1152 non-null    int64
2   att_2    1152 non-null    int64
3   att_3    1152 non-null    int64
4   att_4    1152 non-null    int64
5   att_5    1152 non-null    int64
6   att_6    1152 non-null    int64
7   att_7    1152 non-null    int64
8   att_8    1152 non-null    int64
9   att_9    1152 non-null    int64
10  att_10   1152 non-null    int64
11  att_11   1152 non-null    int64
12  att_12   1152 non-null    int64
13  att_13   1152 non-null    int64
14  att_14   1152 non-null    int64
15  att_15   1152 non-null    int64
16  att_16   1152 non-null    int64
17  att_17   1152 non-null    int64
18  att_18   1152 non-null    int64
19  att_19   1152 non-null    int64
20  att_20   1152 non-null    int64
21  att_21   1152 non-null    int64
22  att_22   1152 non-null    int64
23  att_23   1152 non-null    int64
24  att_24   1152 non-null    int64
25  att_25   1152 non-null    int64
26  att_26   1152 non-null    int64
27  att_28   1152 non-null    int64
dtypes: int64(28)
memory usage: 252.1 KB
```

Figura 17 – Resumo da lista dos 28 atributos relativos às 1.152 amostras utilizadas para os modelos de *machine learning*.

Fonte: Elaborado pelo autor.

A Figura 18 apresenta a síntese da preparação do *dataset* com categorização binária para o processamento dos modelos de *machine learning* via Pycaret. Foram realizados originalmente experimentos utilizando o *dataset* gerado pelo *Apollo Simulator*, contendo amostras de contextos de risco com atributos *target* multiclasse. Em um segundo experimento, realizou-se a

³<https://colab.research.google.com/drive/1PjG4Afh-D1tirKLIY80vTnuo0PCXWWIF?usp=sharing>

substituição dos valores multiclasse por valores binários para a coluna de categorização.

Os modelos de *machine learning* testados aplicaram o método *Stratified K-fold cross-validation* com 10 segmentos. Foi processada ainda a otimização dos hiperparâmetros, visando a otimização da performance dos modelos.

5.2.2 Predição de Acidentes

A avaliação da acurácia do módulo `Predição de Acidentes` utilizou como estratégia central a aplicação de um modelo oculto de *Markov* (*Hidden Markov Model - HMM*), que faz uso dos históricos de contextos do modelo `Apollo` para realizar a predição de contextos de acidentes. A modelagem do *HMM* do `Apollo` se baseou nos dados pré-processados obtidos a partir do *dataset* gerado pelo *Apollo Simulator*, seguindo o *workflow* descrito na Seção 5.3.

A decisão pelo uso de *HMM* para a predição de contextos considerou que os modelos ocultos de *Markov* têm sido amplamente utilizados em pesquisas científicas que aplicam a computação preditiva (WHORISKEY et al., 2022). Além disso, *HMM* é um método probabilístico explicável com aderência direta à modelagem e implementação de projetos envolvendo estados e transições (GIRDHAR et al., 2021).

A implementação e avaliação do modelo *HMM* do `Apollo` consistiu em um fluxo de 5 etapas principais: (a) Definição dos estados ocultos e dos eventos observáveis do modelo `Apollo`; (b) Pré-processamento dos dados de contexto do *dataset* gerados pelo *Apollo Simulator* para normalização da base de acordo com o padrão estabelecido na estrutura de dicionário do *Apollo Simulator*, detalhado na Tabela 23 (Apêndice A); (c) Pré-processamento das probabilidades de transição entre estados e eventos observáveis dos históricos de contextos do modelo `Apollo`; (d) Treinamento do modelo *HMM* se baseando nas probabilidades de transições pré-processadas no item anterior; (e) Avaliação da acurácia do modelo *HMM* para predição de contextos, utilizando contextos novos criados especificamente para os testes, diferentes dos utilizados para o treinamento.

Os estados `AVD` e `acidente` foram definidos como os dois estados ocultos do modelo *HMM* `Apollo`. Logo, aplicou-se uma normalização binária para o atributo `att_29` do dicionário de dados de contexto estruturado na Tabela 23 (Apêndice A). Os eventos observáveis foram categorizados como `nao_risco`, `risco_baixo`, `risco_medio` e `risco_alto`, aplicando a normalização multiclasse sobre o atributo `att_28` do dicionário de dados de contexto estruturado na Tabela 23 (Apêndice A). A Tabela 17 apresenta a síntese da normalização aplicada sobre os atributos utilizados como base para a definição dos estados ocultos e dos eventos observáveis do modelo *HMM* do `Apollo`.

A partir da definição dos componentes principais do modelo *HMM*, realizou-se o pré-processamento da base de dados de históricos de contextos do `Apollo`, inferindo-se as probabilidades de transição entre os estados e eventos observáveis. O pré-processamento do *dataset* gerado pelo *Apollo Simulator* considerou a classificação multiclasse contendo 1.152 amostras,

Tabela 17 – Normalização dos Estados Ocultos e Eventos Observáveis do *HMM* do modelo Apollo.

Estado Oculto / Evento Observável	Valor normalizado	Valor relativo ao atributo base na Tabela 23 (Apêndice A)
AVD	0	att_29 == 0
acidente	1	att_29 > 0
nao_risco	0	att_28 == 0
risco_baixo	1	att_28 IN {1, 4, 7, 10, 13}
risco_medio	2	att_28 IN {2, 5, 8, 11, 14}
risco_alto	3	att_28 IN {3, 6, 9, 12, 15}

das quais 57 são de sequências de contextos que continham riscos que resultaram em acidentes. Destas 57 amostras, 42 eram de instâncias de risco baixo, médio ou alto. As demais 15 instâncias eram de contextos de não-risco interpoladas nestas sequências. Este *dataset* foi utilizado para os cálculos das probabilidades de transição entre os estados ocultos e os eventos observáveis do modelo *HMM* do Apollo.

A Figura 19 apresenta o diagrama de transição com dois estados ocultos e quatro eventos observáveis, compondo a estrutura do *HMM* do Apollo com as probabilidades computadas a partir dos dados de treinamento obtidos do *dataset* principal gerado pelo *Apollo Simulator*.

A implementação do modelo *HMM* do Apollo foi realizada utilizando o pacote *Pomegranate* para a linguagem *Python*, utilizando-se como plataforma o Google Colab. O *Pomegranate* é um pacote *Python* que implementa modelos probabilísticos rápidos e flexíveis, cobrindo desde distribuições probabilísticas individuais até modelos compostos, tais como redes *Bayesianas* e modelos ocultos de *Markov*. A Figura 20 apresenta o código-fonte do programa em *Python*, utilizando o pacote *Pomegranate* para o treinamento do modelo *HMM* para predição de acidentes do modelo Apollo. Utilizou-se o algoritmo *Viterbi* de programação dinâmica para obter a estimativa de probabilidade máxima *a posteriori* da sequência mais provável de estados ocultos, de acordo com a sequência de eventos observáveis provisionados. O código-fonte do *notebook* do projeto se encontra disponível no *Google Colab* do autor desta tese ⁴.

Por fim, a Tabela 25 (Apêndice A) apresenta 5 novos cenários modelados, utilizando o *Apollo Simulator* e normalizados conforme a estrutura de dados apresentada na Tabela 17. Os 5 cenários de teste contém 5 amostras de contextos cada e estão distribuídos entre 4 cenários, com desfechos classificados como acidente, e 1, com desfecho classificado como AVD. Este *dataset* de teste foi usado no provisionamento do modelo *HMM* do Apollo para a avaliação da acurácia na predição de acidentes. A última coluna da Tabela 25 (Apêndice A) especifica a sequência de eventos observáveis considerados como *input* utilizado para a avaliação do modelo *HMM* do Apollo.

⁴<https://colab.research.google.com/drive/1GlmqckDL7ImNh7ISZhbVM8Q3S1XozHs2?usp=sharing>

A sequência dos 4 contextos dos cenários de teste elaborados com desfecho de acidente seguiram o padrão: `nao_risco (0) - nao_risco (0) - risco_baixo (1) - risco_medio (2) - risco_alto (3)`. O contexto do cenário de teste com desfecho de AVD seguiu o padrão: `nao_risco (0) - nao_risco (0) - nao_risco (0) - nao_risco (0) - nao_risco (0)`.

As métricas de performance utilizadas para a avaliação de acurácia da predição de acidentes foram a precisão, o *recall* e o *F1-score*. Os parâmetros utilizados para os cálculos das métricas foram: (a) Verdadeiros Positivos (VP), contextos classificados manualmente como acidente e preditos como acidente pelo modelo *HMM*; (b) Verdadeiros Negativos (VN), contextos classificados como AVD e preditos como AVD pelo modelo *HMM*; (c) Falso Positivo (FP), contextos definidos como AVD e preditos como acidente pelo modelo *HMM*; e, (d) Falso Negativo (FN), contextos categorizados como acidente e predito como AVD pelo modelo *HMM*. A Figura 21 apresenta as equações dos cálculos das referidas métricas.

A granularidade da avaliação da predição de acidentes considerou o nível de conjunto de contextos que compõem um cenário de acidente ou AVD, composto de 5 contextos unitários sequenciais neste experimento. Logo, a assertividade do modelo *HMM* foi mensurada no escopo mais amplo, pois a avaliação no escopo mais restrito do contexto unitário foi realizada pelo modelo de *machine learning* para detecção de riscos.

Os resultados finais das métricas de precisão, *recall* e *F1-score* do módulo `Predição de Acidentes` foram calculados pelo acúmulo dos 5 experimentos individuais realizados com os 5 cenários de teste (CT1 a CT5) relacionados na Tabela 25 (Apêndice A).

5.3 Resultados

Esta seção apresenta os resultados obtidos para os experimentos realizados relativamente à avaliação de acurácia do módulo de identificação de riscos se baseando na geração de *dataset* de contextos sintéticos e a avaliação de acurácia na predição de acidentes.

5.3.1 Avaliação da Acurácia de Detecção de Riscos e Predição de Acidentes Baseada em Contextos Sintéticos

Os resultados da avaliação de acurácia dos módulos `Detecção de Riscos` e `Predição de Acidentes` mensuram a capacidade dos modelos de *machine learning* supervisionado e de *Markov* oculto, respectivamente, de detectar riscos e acidentes de modo assertivo, de acordo com as amostras de cenários manualmente rotuladas e validadas por especialistas.

5.3.1.1 Detecção de Riscos

Após o pré-processamento do *dataset* gerado pelo *Apollo Simulator* com classificação binária contendo 1.152 amostras, realizou-se a computação de 14 algoritmos de *machine learning*, que resultaram nos escores sintetizados da Figura 22. Observa-se que o modelo com melhor performance global foi o *Quadratic Discrimant Analysis*, obtendo 100% em todas as métricas de performance.

Um procedimento análogo foi realizado para a versão do mesmo *dataset*, porém considerando a classificação multiclasse para o atributo *target*. Na Figura 23, observa-se que o modelo com melhor performance global foi o *Decision Tree Classifier*, seguido do *Random Forest*, ambos com acurácia média superior a 98%.

Considerando que o algoritmo *Quadratic Discrimant Analysis* não foi computado para o experimento multiclasse e o *Random Forest (RF)* atingiu performance média geral superior na avaliação dos dois experimentos, optou-se pelo *RF* como o algoritmo de referência para a continuidade dos experimentos.

A Figura 24 apresenta os melhores valores computados para os hiperparâmetros do modelo binário do *Random Forest*.

Do mesmo modo, a Figura 25 apresenta o melhores valores computados para os hiperparâmetros do modelo multiclasse do *Random Forest*.

Tomando-se por base os melhores hiperparâmetros computados para o modelo *RF* com classificação binária, a Figura 26 apresenta as métricas de performance média otimizadas para este caso. Observa-se que a acurácia média para 10 *folds* foi de aproximadamente 98,7%, com desvio padrão médio de 1%. A métrica de AUC média foi de 96,3%, com desvio padrão médio de 6,5%. A precisão média atingiu 90,6% com desvio padrão médio de praticamente 15%. O *recall* foi de 80%, com desvio padrão de 22% em média. Por fim, o *F1-score* foi de 82% e desvio padrão médio de 15,3%.

Os melhores hiperparâmetros computados para o modelo *RF* com classificação multiclasse foram utilizados para a computação das métricas de performance média otimizadas apresentadas na Figura 27.

Observa-se, neste caso, que a acurácia média para 10 *folds* foi de aproximadamente 98,1%, com desvio padrão médio de menos de 1%. A precisão média atingiu 97,6%, com desvio padrão médio de praticamente 1%. O *recall* foi de 59,1%, com desvio padrão de 20,4% em média. Por fim, o *F1-score* foi de 97,9% e desvio padrão médio inferior a 1%.

Comparando-se os resultados obtidos para os modelos *RF* para o *dataset* multiclasse com o *dataset* binário, constata-se que o modelo binário atingiu métricas superiores de acurácia e *recall*. Todavia, o modelo baseado em multiclasse atingiu resultados superiores de performance da precisão e *F1-score*.

A Figura 28 apresenta o gráfico de importância dos atributos para a melhor performance do modelo *RF* com classificação binária. O atributo `att_6` (`EstadoMovimentoEquilibrio`)

é o mais significativo para o modelo *RF* baseado em *dataset* binário, seguido do atributo *att_21* (PeriodoDia), *att_20* (Supervisao) e *att_26* (Objeto).

A Figura 29 apresenta o gráfico de importância dos atributos para a melhor performance do modelo *RF* com classificação multiclasse. O atributo *att_21* (PeriodoDia) é o mais significativo para o modelo *RF* baseado em *dataset* multiclasse, seguido do atributo *att_6* (EstadoMovimentoEquilibrio), *att_26* (Objeto) e *att_20* (Supervisao).

Comparando os resultados obtidos para o quesito atributos mais importantes para os modelos *RF* do *dataset* multiclasse e *dataset* binário, constata-se que, embora em ordem distinta, os quatro atributos mais relevantes em ambos os casos coincidem, diferenciando-se apenas percentualmente.

A Figura 30 mostra a matriz de confusão normalizada resultante para o processamento do modelo *RF* para o *dataset* com classificação binária. Observa-se que 99% das amostras de não-risco foram corretamente classificadas, enquanto 1% foi classificado como sendo de risco incorretamente. Além disso, 12,5% das amostras de risco foram classificadas como sendo não-risco incorretamente, enquanto 87,5% das amostras de risco foram corretamente classificadas como risco.

A Figura 31 mostra a matriz de confusão normalizada resultante para o processamento do modelo *RF* para o *dataset* com classificação multiclasse. Observa-se que 99,4% das amostras de não-risco foram corretamente classificadas, enquanto 0,6% foram classificadas como sendo de risco incorretamente. Além disso, 37,5% das amostras de risco foram classificadas como sendo não-risco incorretamente, enquanto 62,5% das amostras de risco foram corretamente classificadas como risco.

A Figura 32 apresenta o gráfico da curva *ROC* para o processamento do modelo *RF* para o *dataset* com classificação binária. A métrica *AUC* média para a classe 0 (não-risco) e para a classe 1 (risco) foi de 100%.

A Figura 33 apresenta o gráfico do relatório de classificação resultante do modelo *RF* com classificação binária com a melhor performance média. Observa-se média superior a 99% para as métricas de precisão, *recall* e *F1-score* para a classe 0 (não-risco). Para a classe 1 (risco), a métrica de precisão foi de 70%, de *recall* 87,5% e *F1-score* de 77,8%.

A Figura 34 apresenta o gráfico do relatório de curva de precisão e *recall* resultante do modelo *Random Forest* com classificação binária com melhor performance média. Observa-se a métrica de precisão média de 95%.

A Figura 35 apresenta o gráfico do relatório de curva de precisão e *recall* resultante do modelo *Random Forest* com classificação multiclasse com melhor performance média. Observa-se a métrica de precisão média de 100%.

5.3.1.2 Predição de Acidentes

Após a realização dos experimentos de avaliação da acurácia do modelo *HMM* do módulo Predição de Acidentes do modelo Apollo, foram apuradas as métricas de precisão, *recall* e *F1-score* para avaliação da capacidade do modelo Apollo na predição de acidentes.

A Tabela 25 (Apêndice A) detalha os contextos que compõem os 5 cenários de testes (CT1 a CT5) avaliados pelo modelo *HMM* do Apollo. O cenário de teste 1 (CT1) foi predito corretamente pelo modelo *HMM*, conforme se visualiza na Figura 36.

O cenário de teste 2 (CT2) foi predito corretamente pelo modelo *HMM*, conforme se visualiza nos resultados do processamento apresentados na Figura 37.

O CT3 foi predito corretamente pelo modelo *HMM*, conforme se visualiza na Figura 38.

Para o CT4, a predição foi corretamente realizada pelo modelo *HMM*. A Figura 39 mostra o resultado deste processamento.

O quinto cenário, CT5, foi corretamente predito pelo modelo *HMM*, conforme se pode visualizar na Figura 40.

Por fim, a Figura 41 mostra a tabela de avaliação geral contendo os 5 cenários de teste, detalhados na Tabela 25 (Apêndice A). O modelo *HMM* do Apollo obteve precisão de 100%, *recall* de 100,00% e *F1-score* de 100% nas predições dos contextos experimentados.

index	Description	Value
0	session_id	123
1	Target	att_28
2	Target Type	Binary
3	Label Encoded	None
4	Original Data	1094,28
5	Missing Values	false
6	Numeric Features	0
7	Categorical Features	27
8	Ordinal Features	false
9	High Cardinality Features	false
10	High Cardinality Method	
11	Transformed Train Set	765,120
12	Transformed Test Set	329,120
13	Shuffle Train-Test	True
14	Stratify Train-Test	False
15	Fold Generator	StratifiedKFold
16	Fold Number	10
17	CPU Jobs	-1
18	Use GPU	false
19	Log Experiment	false
20	Experiment Name	cif-default-name
21	USI	5c29
22	Imputation Type	simple
23	Iterative Imputation Iteration	None
24	Numeric Imputer	mean
25	Iterative Imputation Numeric Model	None
26	Categorical Imputer	constant
27	Iterative Imputation Categorical Model	None
28	Unknown Categoricals Handling	least_frequent
29	Normalize	false
30	Normalize Method	None
31	Transformation	false
32	Transformation Method	None
33	PCA	false
34	PCA Method	None
35	PCA Components	None
36	Ignore Low Variance	false
37	Combine Rare Levels	false
38	Rare Level Threshold	None
39	Numeric Binning	false
40	Remove Outliers	false
41	Outliers Threshold	
42	Remove Multicollinearity	false
43	Multicollinearity Threshold	
44	Remove Perfect Collinearity	true
45	Clustering	false
46	Clustering Iteration	
47	Polynomial Features	false
48	Polynomial Degree	
49	Trigonometry Features	false
50	Polynomial Threshold	
51	Group Features	false
52	Feature Selection	false
53	Feature Selection Method	classic
54	Features Selection Threshold	
55	Feature Interaction	false
56	Feature Ratio	false
57	Interaction Threshold	
58	Fix Imbalance	false
59	Fix Imbalance Method	SMOTE

Figura 18 – Síntese da preparação do *dataset* com categorização binária para processamento dos modelos de *machine learning*.

Fonte: Elaborado pelo autor.

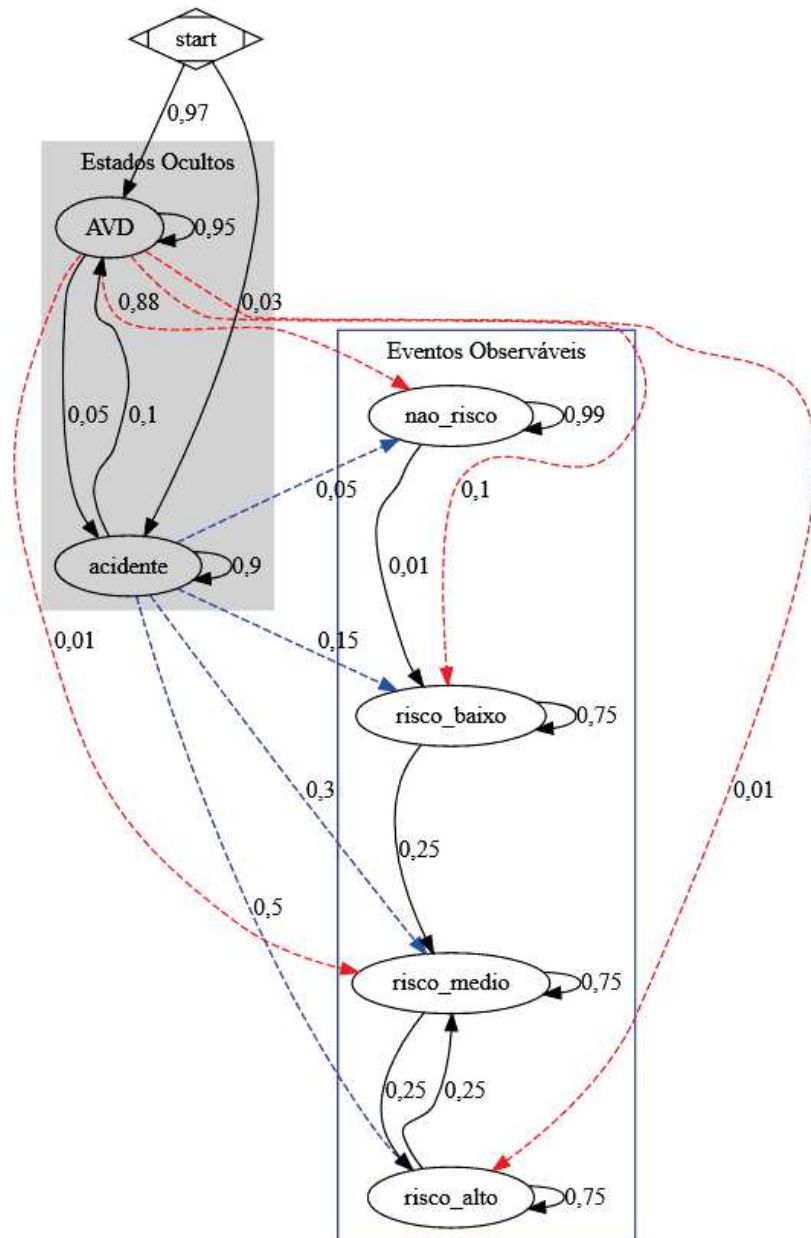


Figura 19 – Diagrama de transição de estados do modelo *HMM* elaborado baseando-se no *dataset* de históricos de contextos gerado pelo *Apollo Simulator*.

Fonte: Elaborado pelo autor.

```

from pomegranate import *
import numpy as np
model = HiddenMarkovModel()

[38] d1 = DiscreteDistribution({'0' : 0.88, '1' : 0.1, '2' : 0.01, '3' : 0.01})
d2 = DiscreteDistribution({'0' : 0.05, '1' : 0.15, '2' : 0.3, '3' : 0.5})

s1 = State(d1, name="AVD")
s2 = State(d2, name="acidente")

model = HiddenMarkovModel('ApolloHMM')
model.add_states([s1, s2])
model.add_transition(model.start, s1, 0.97)
model.add_transition(model.start, s2, 0.03)
model.add_transition(s1, s1, 0.95)
model.add_transition(s1, s2, 0.05)
model.add_transition(s2, s2, 0.9)
model.add_transition(s2, s1, 0.1)
#model.add_transition(s2, model.end, 0.1)
model.bake()

[59] test_sequence = list('00001')

[60] print(model.probability(test_sequence))

0.051392441102571504

[61] viterbi_likelihood, viterbi_path = model.viterbi(test_sequence)
print("A mais provável sequência para gerar estas observações é {} com {:.2f}%".format([s[1].name for s in viterbi_path[1:]], np.exp(viterbi_likelihood)*100))

A mais provável sequência para gerar estas observações é ['AVD', 'AVD', 'AVD', 'AVD', 'AVD'] com 4.74%.

[62] print(", ".join(state.name for i, state in model.viterbi(test_sequence)[1]))

ApolloHMM-start, AVD, AVD, AVD, AVD, AVD

```

Figura 20 – Código-fonte do modelo *HMM* do Apollo considerando os valores computados para o *dataset* de históricos de contextos.

Fonte: Elaborado pelo autor.

$$\text{precisão} = \frac{VP}{VP + FP} \quad \text{recall} = \frac{VP}{VP + FN} \quad F1 - \text{score} = 2 \frac{\text{precisão} \cdot \text{recall}}{\text{precisão} + \text{recall}}$$

Figura 21 – Equações utilizadas para o cálculo das métricas de *performance* do modelo *HMM* do Apollo.

Fonte: Elaborado pelo autor.

Index	Model	Accuracy	AUC	Recall	Prec.	F1	Kappa	MCC	TT (Sec)
qda	Quadratic Discriminant Analysis	1.0	1.0	1.0	1.0	1.0	1.0	1.0	0.029
knn	K Neighbors Classifier	0.9987	1.0	0.9667	1.0	0.98	0.9794	0.9811	0.124
lightgbm	Light Gradient Boosting Machine	0.9987	1.0	0.9667	1.0	0.98	0.9793	0.9811	0.1
lr	Logistic Regression	0.9974	1.0	0.9333	1.0	0.96	0.9587	0.9622	0.395
nb	Naive Bayes	0.9974	0.9667	0.9333	1.0	0.96	0.9587	0.9622	0.018
svm	SVM - Linear Kernel	0.9974	0.0	0.9417	1.0	0.9657	0.9644	0.9671	0.017
rf	Random Forest Classifier	0.9974	1.0	0.9333	1.0	0.96	0.9587	0.9622	0.516
ada	Ada Boost Classifier	0.9974	1.0	0.9333	1.0	0.96	0.9587	0.9622	0.146
et	Extra Trees Classifier	0.9974	1.0	0.9333	1.0	0.96	0.9587	0.9622	0.466
dt	Decision Tree Classifier	0.9935	0.9528	0.9083	0.96	0.9267	0.9233	0.9273	0.021
gbc	Gradient Boosting Classifier	0.9935	0.9804	0.8333	1.0	0.89	0.8871	0.9003	0.232
lda	Linear Discriminant Analysis	0.9922	0.9167	0.8	1.0	0.87	0.8664	0.8814	0.037
ridge	Ridge Classifier	0.9908	0.0	0.7667	1.0	0.84	0.8361	0.8572	0.018
dummy	Dummy Classifier	0.9582	0.5	0.0	0.0	0.0	0.0	0.0	0.014

Figura 22 – Síntese da comparação entre os algoritmos supervisionados de *machine learning* para classificação binária das amostras.

Fonte: Elaborado pelo autor.

index	Model	Accuracy	AUC	Recall	Prec.	F1	Kappa	MCC	TT (Sec)
dt	Decision Tree Classifier	0.983	0.0	0.615	0.9765	0.9795	0.774	0.7821	0.022
rf	Random Forest Classifier	0.9817	0.0	0.5912	0.9765	0.9789	0.7612	0.7675	0.517
lda	Linear Discriminant Analysis	0.9817	0.0	0.539	0.9804	0.981	0.7712	0.7744	0.034
et	Extra Trees Classifier	0.9817	0.0	0.62	0.9752	0.9782	0.7621	0.7699	0.466
lr	Logistic Regression	0.9804	0.0	0.5769	0.9746	0.9771	0.7496	0.7553	0.421
gbc	Gradient Boosting Classifier	0.9804	0.0	0.5845	0.9708	0.9754	0.7227	0.7401	3.238
lightgbm	Light Gradient Boosting Machine	0.9804	0.0	0.5836	0.9733	0.9763	0.7493	0.754	0.368
svm	SVM - Linear Kernel	0.9778	0.0	0.4979	0.9739	0.9754	0.7242	0.728	0.066
ridge	Ridge Classifier	0.9778	0.0	0.5336	0.9656	0.9715	0.6692	0.6929	0.018
nb	Naive Bayes	0.9765	0.0	0.5433	0.9598	0.9678	0.6267	0.6565	0.019
knn	K Neighbors Classifier	0.966	0.0	0.3219	0.9615	0.9636	0.567	0.5725	0.124
ada	Ada Boost Classifier	0.966	0.0	0.3761	0.9562	0.9606	0.5207	0.5292	0.159
dummy	Dummy Classifier	0.9582	0.0	0.24	0.9181	0.9377	0.0	0.0	0.012

Figura 23 – Síntese da comparação entre os algoritmos supervisionados de *machine learning* para classificação multiclasse das amostras.

Fonte: Elaborado pelo autor.

index	Parameters
bootstrap	False
ccp_alpha	0.0
class_weight	{}
criterion	entropy
max_depth	5
max_features	1.0
max_leaf_nodes	None
max_samples	None
min_impurity_decrease	0.0002
min_impurity_split	None
min_samples_leaf	5
min_samples_split	10
min_weight_fraction_leaf	0.0
n_estimators	150
n_jobs	-1
oob_score	False
random_state	123
verbose	0
warm_start	False

Figura 24 – Listagem dos hiperparâmetros processados para a obtenção do modelo de *machine learning Random Forest* para o *dataset* com classificação binária com melhor performance média geral.

Fonte: Elaborado pelo autor.

index	Parameters
bootstrap	False
ccp_alpha	0.0
class_weight	balanced_subsample
criterion	gini
max_depth	6
max_features	log2
max_leaf_nodes	None
max_samples	None
min_impurity_decrease	0.001
min_impurity_split	None
min_samples_leaf	6
min_samples_split	9
min_weight_fraction_leaf	0.0
n_estimators	190
n_jobs	-1
oob_score	False
random_state	123
verbose	0
warm_start	False

Figura 25 – Listagem dos hiperparâmetros processados para a obtenção do modelo de *machine learning Random Forest* para o *dataset* com classificação multiclasse com melhor performance média geral.

Fonte: Elaborado pelo autor.

Index	Accuracy	AUC	Recall	Prec.	F1	Kappa	MCC
0	1.0	1.0	1.0	1.0	1.0	1.0	1.0
1	0.974	0.991	0.3333	1.0	0.5	0.4901	0.5697
2	0.974	0.9932	0.6667	0.6667	0.6667	0.6532	0.6532
3	1.0	1.0	1.0	1.0	1.0	1.0	1.0
4	0.987	0.9966	1.0	0.8	0.8889	0.8821	0.8883
5	1.0	1.0	1.0	1.0	1.0	1.0	1.0
6	0.9868	0.8333	0.6667	1.0	0.8	0.7935	0.811
7	0.9868	0.9954	0.6667	1.0	0.8	0.7935	0.811
8	0.9737	0.9932	1.0	0.6	0.75	0.737	0.7639
9	0.9868	0.8311	0.6667	1.0	0.8	0.7935	0.811
Mean	0.9869	0.9634	0.8	0.9067	0.8206	0.8143	0.8308
SD	0.0101	0.0657	0.2211	0.1497	0.153	0.157	0.1395

Figura 26 – Métricas individuais, médias e desvios padrão obtidos para o processamento dos 10 segmentos do modelo *Random Forest* aplicado ao *dataset* de classificação binária aplicando os parâmetros de melhor performance média geral.

Fonte: Elaborado pelo autor.

Index	Accuracy	AUC	Recall	Prec.	F1	Kappa	MCC
0	0.987	0.0	0.75	0.9805	0.9827	0.8289	0.8307
1	1.0	0.0	1.0	1.0	1.0	1.0	1.0
2	0.974	0.0	0.4	0.9612	0.9676	0.5926	0.6076
3	0.974	0.0	0.4286	0.974	0.974	0.7425	0.745
4	0.974	0.0	0.5	0.974	0.974	0.7425	0.7462
5	0.9737	0.0	0.3333	0.9737	0.9737	0.6592	0.6622
6	0.9868	0.0	0.6	0.9868	0.9868	0.8292	0.8311
7	0.9868	0.0	0.75	0.9803	0.9825	0.8288	0.8307
8	0.9737	0.0	0.4	0.9607	0.9672	0.5925	0.6076
9	0.9868	0.0	0.75	0.9739	0.9803	0.7957	0.8138
Mean	0.9817	0.0	0.5912	0.9765	0.9789	0.7612	0.7675
SD	0.0086	0.0	0.2043	0.011	0.0094	0.1183	0.1146

Figura 27 – Métricas individuais, médias e desvios padrão obtidos para o processamento dos 10 segmentos do modelo *Random Forest* aplicado ao *dataset* de classificação multiclasse aplicando os parâmetros de melhor performance média geral.

Fonte: Elaborado pelo autor.




Figura 28 – Gráfico de relação dos atributos mais importantes para o modelo *Random Forest* com classificação binária com melhor performance média.

Fonte: Elaborado pelo autor.

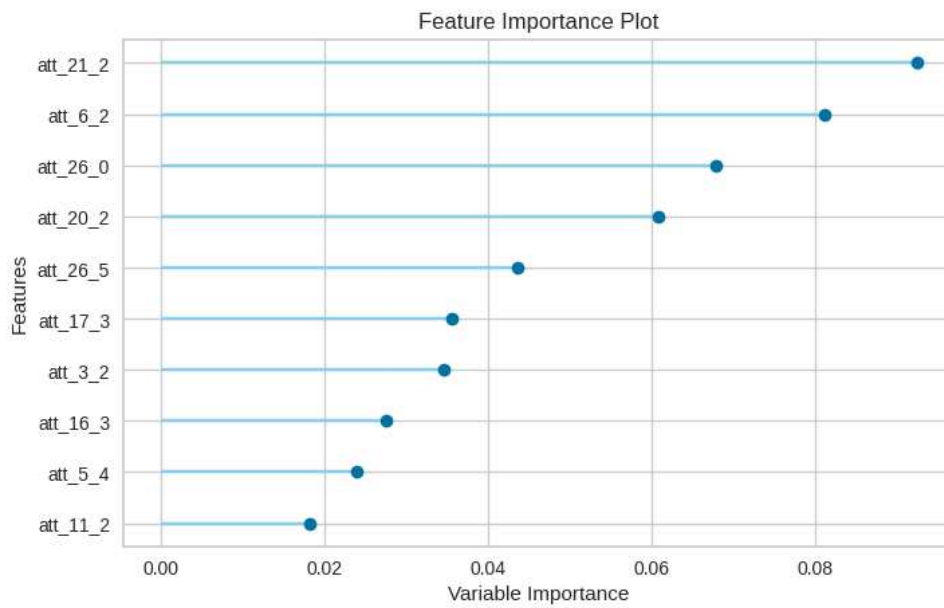


Figura 29 – Gráfico de relação dos atributos mais importantes para o modelo *Random Forest* com classificação multiclasse com melhor performance média.

Fonte: Elaborado pelo autor.

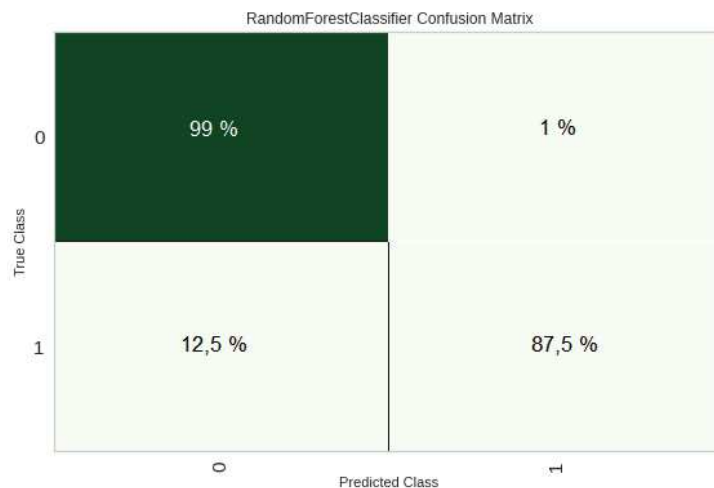


Figura 30 – Matriz de confusão resultante do processamento do modelo *Random Forest* com classificação binária com melhor performance média.

Fonte: Elaborado pelo autor.

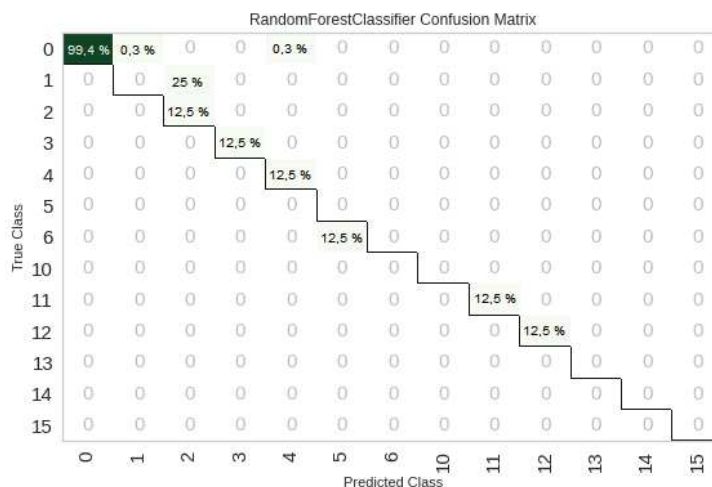


Figura 31 – Matriz de confusão resultante do processamento do modelo *Random Forest* com classificação multiclasse com melhor performance média.

Fonte: Elaborado pelo autor.




Figura 32 – Gráfico da curva ROC resultante do processamento do modelo *Random Forest* com classificação binária com melhor performance média.

Fonte: Elaborado pelo autor.

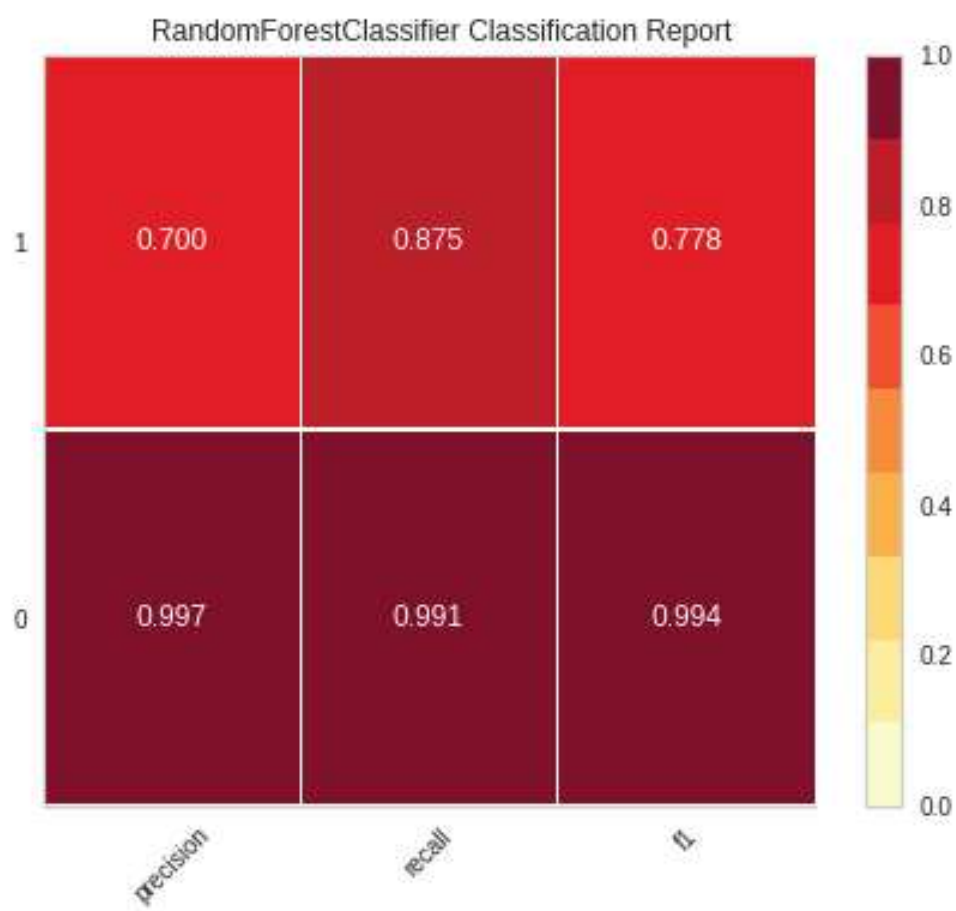


Figura 33 – Gráfico do relatório de classificação resultante do modelo *Random Forest* com classificação binária com a melhor performance média.

Fonte: Elaborado pelo autor.




Figura 34 – Gráfico do relatório de curva de precisão e *recall* resultante do modelo *Random Forest* com classificação binária com melhor performance média.

Fonte: Elaborado pelo autor.

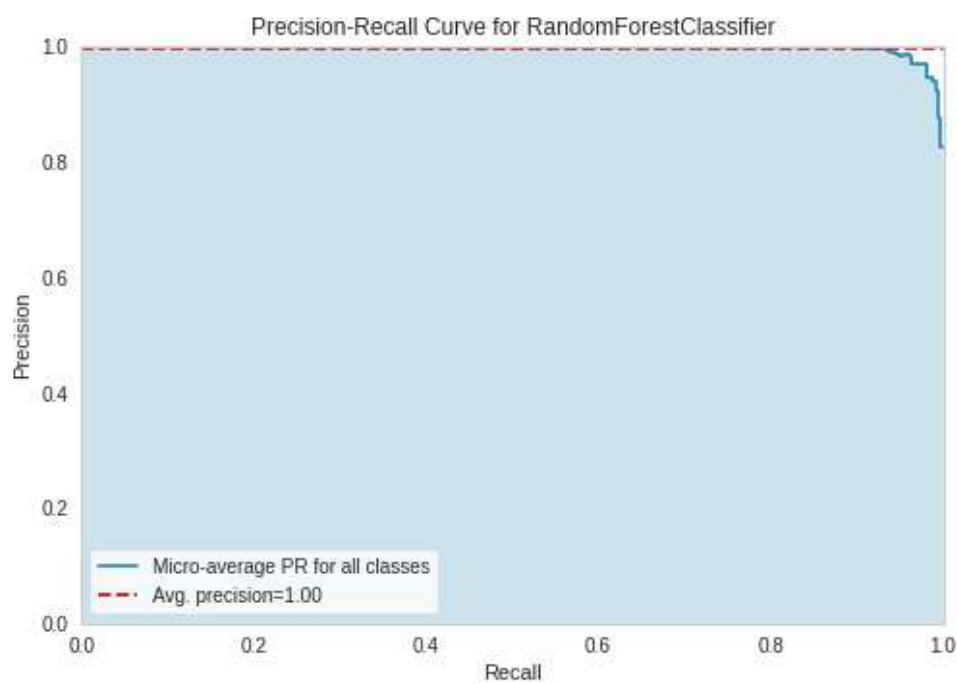


Figura 35 – Gráfico do relatório de curva de precisão e *recall* resultante do modelo *Random Forest* com classificação multiclasse com melhor performance média.

Fonte: Elaborado pelo autor.

```

[64] test_sequence = list('00000')
[65] print(model.probability(test_sequence))
0.4187544314374271
[66] viterbi_likelihood, viterbi_path = model.viterbi(test_sequence)
print("A mais provável sequencia para gerar estas observações é {} com {:.2f}%".format([s[1].name for s in viterbi_path[1:]], np.exp(viterbi_likelihood)*100))
A mais provável sequencia para gerar estas observações é ['AVD', 'AVD', 'AVD', 'AVD', 'AVD'] com 41.69%.
[67] print(", ".join(state.name for i, state in model.viterbi(test_sequence)[1]))
ApolloHMM-start, AVD, AVD, AVD, AVD, AVD

```

Figura 36 – Resultados do processamento do modelo preditivo *HMM* do Apollo para o cenário de teste 1 (CT1).

Fonte: Elaborado pelo autor.

```

[68] test_sequence = list('00123')
[69] print(model.probability(test_sequence))
0.0011693109088545012
[70] viterbi_likelihood, viterbi_path = model.viterbi(test_sequence)
print("A mais provável sequencia para gerar estas observações é {} com {:.2f}%".format([s[1].name for s in viterbi_path[1:]], np.exp(viterbi_likelihood)*100))
A mais provável sequencia para gerar estas observações é ['AVD', 'AVD', 'acidente', 'acidente', 'acidente'] com 0.07%.
[71] print(", ".join(state.name for i, state in model.viterbi(test_sequence)[1]))
ApolloHMM-start, AVD, AVD, acidente, acidente, acidente

```

Figura 37 – Resultados do processamento do modelo preditivo *HMM* do Apollo para o cenário de teste 2 (CT2).

Fonte: Elaborado pelo autor.

```

[96] test_sequence = list('01122')
[97] print(model.probability(test_sequence))
0.00014318388027249998
[98] viterbi_likelihood, viterbi_path = model.viterbi(test_sequence)
print("A mais provável sequencia para gerar estas observações é {} com {:.2f}%".format([s[1].name for s in viterbi_path[1:]], np.exp(viterbi_likelihood)*100))
A mais provável sequencia para gerar estas observações é ['AVD', 'acidente', 'acidente', 'acidente', 'acidente'] com 0.01%.
[99] print(", ".join(state.name for i, state in model.viterbi(test_sequence)[1]))
ApolloHMM-start, AVD, acidente, acidente, acidente, acidente

```

Figura 38 – Resultados do processamento do modelo preditivo *HMM* do Apollo para o cenário de teste 3 (CT3).

Fonte: Elaborado pelo autor.

```

[76] test_sequence = list('01022')
[77] print(model.probability(test_sequence))
0.00033050377060700014
[78] viterbi_likelihood, viterbi_path = model.viterbi(test_sequence)
print("A mais provável sequencia para gerar estas observações é {} com {:.2f}%".format([s[1].name for s in viterbi_path[1:]], np.exp(viterbi_likelihood)*100))
A mais provável sequencia para gerar estas observações é ['AVD', 'AVD', 'AVD', 'acidente', 'acidente'] com 0.03%.
[79] print(", ".join(state.name for i, state in model.viterbi(test_sequence)[1]))
ApolloHMM-start, AVD, AVD, AVD, acidente, acidente

```

Figura 39 – Resultados do processamento do modelo preditivo *HMM* do Apollo para o cenário de teste 4 (CT4).

Fonte: Elaborado pelo autor.

```

✓ [92] test_sequence = list('01213')
✓ [93] print(model.probability(test_sequence))
0.00018885460446000044
✓ [94] viterbi_likelihood, viterbi_path = model.viterbi(test_sequence)
print("A mais provável sequência para gerar estas observações é {} com {:.2f}%.".format([s[1].name for s in viterbi_path[1:]], np.exp(viterbi_likelihood)*100))
A mais provável sequência para gerar estas observações é ['AVD', 'acidente', 'acidente', 'acidente', 'acidente'] com 0.01%.
✓ [95] print(", ".join(state.name for i, state in model.viterbi(test_sequence)[1]))
ApolloHMM-start, AVD, acidente, acidente, acidente, acidente

```

Figura 40 – Resultados do processamento do modelo preditivo *HMM* do Apollo para o cenário de teste 5 (CT5).

Fonte: Elaborado pelo autor.

	VP	FP	VN	FN	
CT1	1	0	0	0	Precisão 100,0
CT2	1	0	0	0	
CT1	1	0	0	0	Recall 100,0
CT2	1	0	0	0	
CT1	1	0	0	0	F1-score 100,0

Figura 41 – Resultados da avaliação da acurácia do modelo *HMM* do Apollo.

Fonte: Elaborado pelo autor.

6 DISCUSSÃO

Este capítulo apresenta a análise e as discussões sobre os resultados da avaliação do modelo Apollo. O capítulo está dividido em três seções principais. A Seção 6.1 apresenta as contribuições do mapeamento sistemático para a investigação do estado da arte e identificação de lacunas e oportunidades de pesquisa. A Seção 6.2 detalha as contribuições do modelo Apollo, destacando os módulos de Detecção de Riscos e Predição de Acidentes, que baseiam-se em um *dataset* sintético gerado pelo *Apollo Simulator*. Por fim, na Seção 6.3 são apresentadas algumas limitações da presente pesquisa.

6.1 Contribuições do Mapeamento Sistemático da Literatura

Como qualquer outro estudo de mapeamento sistemático, o realizado nesta tese apresenta alguns riscos que podem ser afetados pelos resultados encontrados. Os riscos podem ocorrer como resultado de decisões tomadas durante o mapeamento sistemático. A fim de garantir melhores resultados de pesquisa, foram selecionadas oito bases de dados, conhecidas no mundo acadêmico por sua relevância nas áreas de informática e saúde, atenuando o risco dos efeitos das bases de dados sobre os resultados obtidos.

O processo de filtragem pode ter restringido os trabalhos de tal forma que trabalhos relevantes possam ter sido removidos. Para mitigar esse risco, o processo de filtragem foi baseado na técnica de Petersen (PETERSEN et al., 2008). Durante todo o processo de filtragem, os artigos foram analisados e selecionados sem um revisor, e isso pode ter afetado os resultados. Para mitigar esse risco, utilizou-se processos de revisão já utilizados por outros autores (GONÇALES et al., 2015), bem como *softwares* que suportariam esse processo de seleção, como a ferramenta *Mendeley*.

Artigos que tratam dos seguintes temas foram excluídos da análise: (a) aplicativos que se concentram apenas no monitoramento individual; (b) aplicativos para monitoramento ou controle de diabetes, depressão e insônia, por exemplo; (c) tele-monitorização passiva ou telemedicina, sem a abordagem de ambiente inteligente; (d) *smartphones/tablets* utilizados apenas como assistente de lembretes; (e) trabalhos que focam apenas questões de *HCI/UX*; (f) projetos relacionados à educação; (g) artigos que abordam somente a *cloud computing*; (h) projetos que lidam com segurança ou vigilância; e, (i) artigos que apresentam *gadgets* e soluções de *IoT* isoladas.

A análise dos 49 artigos permitiu concluir que as tecnologias como *wearables*, sensores de ambiente e robôs de serviço estão sendo usadas para ajudar nos cuidados ubíquos. Alguns trabalhos usaram *smartphones* e *tablets* como um recurso integrado devido à variedade de sensores e a integração com *wearables* é facilitada. Os *smartphones* geralmente são usados para registrar dados fisiológicos do usuário ou para se comunicar com a nuvem.

O mapeamento sistemático desenvolvido mostrou as muitas maneiras pelas quais a tecnolo-

gia é usada para apoiar os serviços de saúde, como monitoramento, detecção, somente notificação, notificação e atuação, ou somente atuação. Os trabalhos em que a atuação foi o escopo principal geralmente foram associados ao uso de robôs de serviço, que interagem com o ambiente, ajudando pessoas em caso de emergência, como apresentado por Mehdi e Berns (2011) ou melhorando a experiência do usuário e seu bem-estar, como apresentado por Jarvis et al. (2009) e Papageorgiou et al. (2017). No entanto, observou-se um fluxo de assistência médica padrão que segue a sequência: (a) monitoramento; (b) detecção; e, notificação.

Embora os estudos não indiquem uma doença específica como majoritária entre os 49 artigos pesquisados, foram categorizadas onze doenças conhecidas: demência, diabetes, Alzheimer, autismo, obesidade, estresse mental, distúrbios do sono e doenças crônicas. O uso de ambientes inteligentes provou ser uma solução adequada para monitorar e auxiliar no tratamento dessas doenças que exigem monitoramento contínuo.

Os idosos foi o grupo populacional mais assistido, praticamente 60% dos casos pesquisados se concentram nessa faixa etária. Doukas et al. (2009) propuseram um modelo para auxiliar os idosos em caso de queda acidental. Valero et al. (2014) mostrou uma proposta que ajuda idosos em atividades cotidianas. O segundo grupo mais citado foi o dos PCDs. AAL foram propostos a fim de reduzir as dificuldades enfrentadas pelos PCDs na vida cotidiana. Por exemplo, Papageorgiou et al. (2017) apresentou um modelo para apoiar pessoas com deficiência motora no uso do banheiro. Huang et al. (2012) escreveu um artigo relacionado à leitura de dados fisiológicos para monitoramento da saúde. Finalmente, neste tema, as crianças também foram relatadas por Tentori et al. (2015) no sentido de como uma aplicação de uma casa inteligente pode suportar o monitoramento de indicadores de saúde das crianças.

Analisando o processo de filtragem apresentado na Figura 2 e a QE1 apresentada na Figura 4, o banco de dados mais preciso que executou a *string* de consulta foi o *Science Direct* e o banco de dados menos preciso foi o *Springer Library*. Outro dado estatístico foi que as bibliotecas ACM e IEEE concentraram em torno de 62% dos trabalhos selecionados.

Identificou-se algumas características técnicas em trabalhos pesquisados como o uso de monitoramento de vídeo com reconhecimento de imagem. Esse recurso geralmente é usado para reconhecimento de quedas em ambientes internos. Outra realidade é o uso de sensores embarcados em *smartphones*, devido ao baixo custo e baixa curva de implementação. No ambiente, recomenda-se o uso de sensores sem contato ou sensores não invasivos. Em termos de funcionalidades, identificou-se o uso de Sistemas de Lembretes Digitais (*Digital Remainder Systems - DRS*), especialmente para suporte de lembretes de atividades.

Na perspectiva de oportunidades gerais, destacam-se sete razões para a abordagem do uso de ambientes inteligentes aplicados aos cuidados de saúde, desde as motivações econômicas até as técnicas:

1. Envelhecimento acelerado da população global;
2. Aumento e multiplicidade de doenças crônicas;

3. Crescimento da demanda por serviços de saúde;
4. Possibilidade de prestação de serviços de suporte contínuo;
5. Apoio de serviços de saúde ubíquos especializados e personalizados;
6. Interligação entre hospital, serviços de emergência, cuidadores, robôs, entre outros;
7. Redução das taxas de hospitalização e dos custos médicos.

Dez desafios foram identificados nos artigos selecionados pesquisados, por critérios gerais e técnicos:

1. Fusão de dados a partir do sensores multimodais ainda é um importante desafio a ser superado;
2. Métodos de detecção e classificação de eventos permanecem como lacunas a serem supridas;
3. A interface Humano-Computador (IHC) precisa ser melhorada em muitos aspectos, de forma mais natural e não-intrusiva, para atender diferentes perfis de usuários;
4. Muitos aspectos da segurança devem ser atendidos, reduzindo as vulnerabilidades das aplicações e os dados dos usuários;
5. Modelos preventivos e preditivos, prevendo rotinas e hábitos, são abordagens que podem melhorar efetivamente os ambientes inteligentes;
6. Detecção de atividades e de comportamentos genéricos ainda continua como um desafio de reconhecimento das atividades humanas;
7. Muitas estratégias de localização interna evoluíram, como imagem, acústica, campo magnético e sinal *wireless*. Entretanto, esse aspecto não está totalmente atendido ainda;
8. Lidar com grandes volumes de dados (*Big Data*) e capacidade de processamento em tempo real continua como outro desafio importante;
9. Aprimoramento de técnicas de inteligência artificial;
10. Questões éticas e sociais assim como fatores humanos e suas particularidades devem ser atendidos.

A principal tendência para os ambientes inteligentes identificada foi a agregação de robôs de serviço para suporte no ambiente inteligente. Os robôs de serviço podem agir para prevenir ou apoiar pessoas em circunstâncias específicas ou em caso de emergência. Além disso,

identificou-se como sendo uma oportunidade a implementação do auto-aprendizado em sistemas e dos alertas/notificações, como atualmente proposto. Finalmente, o uso de dados fisiológicos, além dos dados padrões de saúde, pode contribuir para o desenvolvimento de soluções preventivas e preditivas mais precisas para a *U-Healthcare*.

Portanto, o mapeamento sistemático realizado nesta tese enfocou a aplicação de ambientes inteligentes aos cuidados ubíquos e pode orientar futuros trabalhos sobre o uso da tecnologia para cuidar da saúde das pessoas ou para a promoção do seu bem-estar.

Por fim, o mapeamento sistemático foi publicado em inglês no *Journal of Ambient Intelligence and Smart Environments (JAISE)*, volume 1, em 2020, sob o título *Ubiquitous healthcare on smart environments: A systematic mapping study* (ROSA TAVARES; VICTÓRIA BARBOSA, 2020).

6.2 Avaliação da Acurácia de Detecção de Riscos e Predição de Acidentes Baseada em Contextos Sintéticos

A avaliação de acurácia de detecção de riscos e predição de acidentes do modelo Apollo obteve *score* médio superior a 98%. A geração de *datasets* sintéticos similares a contextos reais associado ao uso de *machine learning* demonstrou que o modelo é viável e escalável e poderia ser aplicado em contextos reais.

6.2.1 Detecção de Riscos

Embora a acurácia de detecção de riscos tenha atingido média superior a 98% para os modelos de *Random Forest* com classificação binária e multiclasse, observou-se a métrica de *recall* de 80% e aproximadamente 60%, respectivamente. Constatou-se que estes valores inferiores são justificáveis pela menor quantidade de amostras categorizadas como `risco`, representando aproximadamente 3,6% do total. Como a precisão para ambos os casos ficou maior que 90%, o *F1-score* médio obteve, no mínimo, resultado superior a 82%.

Em contrapartida, observou-se que, para ambos os experimentos de *datasets* binário e multiclasse, utilizando *Random Forest* e configurado com os melhores hiperparâmetros pré-processados, obteve-se isonomia quanto aos atributos mais importantes. Apesas da divergência na ordem dos experimentos, os atributos `att_6` (EstadoMovimentoEquilibrio), `att_21` (PeriodoDia), `att_20` (Supervisao) e `att_26` (Objeto) foram os mais relevantes para os algoritmos de classificação. Estes resultados evidenciaram que o modelo de ML mapeou corretamente os atributos que são críticos a partir da literatura e da opinião de especialistas e corroboram a validade do *dataset* gerado pelo Apollo Simulator.

As pesquisas realizadas acerca de métodos de detecção de riscos à saúde de PAR possibilitou a colaboração para a publicação para a *MDPI Electronics*, em 2021, sob o título *Ambient Intelligence Based on IoT for Assisting People with Alzheimer's Disease Through Context Histories*

(MACHADO et al., 2021). Em particular, os resultados apresentados nesta tese estão sendo preparados para a submissão ao *Journal of Ambient Intelligence and Humanized Computing (JAIHC)*.

6.2.2 Predição de Acidentes

O modelo preditivo *HMM* do Apollo se apresentou como uma alternativa viável e com alta acurácia para a predição de acidentes, após o mapeamento dos dois estados ocultos (AVD e acidente), bem como os quatro eventos observáveis, calculando-se ainda as probabilidades de cada transição modelada. O modelo *HMM* foi testado com 5 cenários de teste *ad hoc*, após ser treinado com as sequências mapeadas do *dataset* sintético.

Os resultados apresentaram 100% para a acurácia, *recall* e *F1-score*. Embora estes resultados tenham sido muito relevantes, considera-se que isto ocorreu porque o conjunto de dados usado para o treinamento e teste foi pequeno. Neste caso, considera-se uma prova de conceito importante do modelo preditivo. Porém, dado o fato de que a quantidade de cenários é restrita, a performance do modelo *HMM* poderá ser menos performática para um volume de dados maior e mais representativo, dada a maior variabilidade dos atributos dos contextos presentes em cenários reais.

Observou-se ainda que a estratégia de adoção do modelo oculto de *Markov* para a implementação do módulo Predição de Acidentes foi adequada, pois a sua codificação, treinamento e teste foram realizados com uma relação custo-benefício conveniente, adequando-se, inclusive, à limitação da quantidade de dados disponíveis no *dataset* sintético utilizado. Além disso, o modelo *HMM* do Apollo poderia ser re-treinado e atualizado em produção com baixo investimento de tempo.

Por fim, por se tratar de um modelo estocástico probabilístico explicável, poderia ser mais facilmente compreendido por usuários não-técnicos da área da computação, tais como médicos, cuidadores e familiares. Portanto, em detrimento dos modelos ou métodos mais complexos e que demandariam maior capacidade de processamento, como, por exemplo, *Deep Learning*, o modelo *HMM* mostrou ser uma escolha adequada.

Os resultados acerca da predição de acidentes apresentados nesta tese estão sendo preparados para a submissão ao *Journal of Ambient Intelligence and Humanized Computing (JAIHC)*. Além disso, as pesquisas acerca da aplicação de robôs de serviço aos cuidados ubíquos preditivos colaboraram para a publicação na *Robotics and Autonomous Systems*, em 2021, sob o título *A systematic mapping study of robotics in human care* (SANTOS et al., 2021).

6.3 Limitação da Pesquisa

Embora esta pesquisa tenha avançado cientificamente no campo da predição de acidentes em ambientes inteligentes promovendo o suporte aos cuidados ubíquos através da aplicação de

inteligência artificial, algumas limitações foram registradas.

Esta pesquisa não se dedicou a abordar aspectos de segurança envolvendo PAR e ambientes inteligentes. Sabe-se que a área da saúde possui diversos padrões envolvendo proteção de dados e boas práticas de segurança. Portanto, até este ponto da pesquisa, foram desconsiderados requisitos de segurança mais aprofundados. Os artefatos de *software* ficaram restritos ao uso de princípios e métodos elementares do uso de protocolos criptografados na comunicação entre as camadas do modelo, autenticação de serviços e acesso ao banco de dados.

Embora o modelo atue com o perfil das PAR, nesta pesquisa foram avaliados apenas os riscos e acidentes relacionados a idosos, crianças e PCDs surdos. A extensão deste estudo para outros perfis de PAR, tais como, gestantes e pessoas com *Alzheimer* ou *Parkinson*, pode contribuir para o aprimoramento do modelo.

As avaliações consideraram conjuntos de dados e de participantes reduzidos, orientados a amostras não-estatísticas e definidas por conveniência para a tese. A ampliação da quantidade de participantes e dos *datasets* poderiam contribuir para avaliações mais próximas da realidade e possibilitando melhores subsídios para análises futuras.

Finalmente, o modelo considera ambientes inteligentes de modo genérico. Porém, somente contextos residenciais foram considerados até esta etapa da pesquisa. Portanto, outros ambientes poderiam ser mapeados, modelados e avaliados.

7 CONSIDERAÇÕES FINAIS

Este capítulo conclui a tese consolidando as principais conclusões, aprendizados e contribuições realizadas durante esta pesquisa. A Seção 7.1 apresenta as conclusões e síntese dos principais resultados obtidos nas avaliações. A Seção 7.2 lista as principais contribuições científicas do modelo Apollo. A Seção 7.3 enumera as publicações científicas realizadas, patentes registradas e intercâmbio internacional. Por fim, na Seção 7.4 são apresentadas ideias de temas que podem ser investigados mais profundamente dando continuidade ao propósito desta tese.

7.1 Conclusão

Esta tese apresentou o modelo Apollo, um modelo para a detecção de riscos e predição de acidentes por causas externas não intencionais em ambientes inteligentes. Este modelo se baseou em padrões internacionais da área da saúde para o diagnóstico e a gestão de acidentes e riscos à saúde. Portanto, o objetivo principal do Apollo é auxiliar na redução da quantidade de acidentes causados por causas externas não intencionais, sofridos por PAR em ambientes inteligentes.

Para isso, o Apollo possibilita a detecção de riscos a partir do processamento dos históricos de contextos, com aplicação de algoritmos de *machine learning*. Outra meta do Apollo é apoiar nos cuidados ubíquos e na promoção do bem-estar das pessoas, promovendo a saúde integral, via predição de acidentes, com a implementação de um modelo de *Hidden Markov Model (HMM)*.

Quando o modelo Apollo detecta riscos ou prediz acidentes, recomendações e notificações são apresentadas para as PAR e seus cuidadores, alertando-os sobre os riscos iminentes à sua saúde, via interface acessível. Além disso, o ambiente inteligente em que a PAR se encontra pode atuar proativamente para evitar os incidentes nocivos à saúde, com atuadores do próprio ambiente ou com o suporte de robôs de serviço. Neste sentido, propõe-se o *ApolloBot* como um módulo genérico de robô de serviço para atuação no ambiente inteligente.

Adicionalmente, foi proposta a *ApolloOnto*, uma ontologia para cuidados ubíquos por causas externas não intencionais em ambientes inteligentes. As classes mais relevantes foram mapeadas e relacionadas, com base na CID-10 e CICEL. Esta ontologia é utilizada pelo modelo Apollo para a padronização dos contextos, pessoas, objetos e regras implementadas.

Realizou-se um mapeamento sistemático, com ampla revisão da literatura, no intuito de verificar como os ambientes inteligentes podem ser aplicados aos cuidados ubíquos. Diante das lacunas e das oportunidades identificadas, detalhadas no Capítulo 3, propõe-se o modelo Apollo que agrega diferenciais científicos como a capacidade de detecção de riscos com o uso de algoritmos de aprendizado de máquina, predição de contextos relacionados a acidentes usando modelos ocultos de *Markov* e interfaces acessíveis e adaptáveis de acordo com o perfil da PAR.

Desenvolveu-se um simulador de contextos de riscos e acidentes nomeado *Apollo Simula-*

tor. A geração sintética de *datasets* de contextos via *Apollo Simulator* permitiu a realização de experimentos contemplando 15 cenários relacionados a AVDs de PAR, evitando a exposição das PAR aos riscos inerentes aos experimentos reais e de exposição desnecessária aos riscos da doença Covid-19, causada pelo coronavírus SARS-CoV-2, situação pandêmica que assola o mundo de 2019 até o presente momento.

A avaliação de acurácia do módulo de Detecção de Riscos do modelo *Apollo* atingiu *F1-score* médio de 97,9% com a aplicação do algoritmo de *machine learning Random Forest* para o *dataset* de classificação multiclasse. Enquanto isso, o módulo Predição de Acidentes atingiu acurácia média de 100% na predição de contextos acidentais, com a aplicação do modelo *Hidden Markov Model* com dois estados ocultos e quatro estados observáveis.

Espera-se que o modelo possa auxiliar as pessoas e as organizações na redução de acidentes, evitando a ocorrência de morbimortalidade por causas externas. Além disso, o *Apollo* pode ajudar na redução dos gastos médicos associados aos acidentes de saúde.

7.2 Contribuições Científicas do Modelo *Apollo*

Dentre as principais contribuições científicas do modelo *Apollo*, pode-se destacar:

- A realização de um mapeamento sistemático da literatura, identificando lacunas e oportunidades de pesquisa na área de cuidados ubíquos em ambientes inteligentes;
- O projeto, a modelagem, a implementação e a avaliação de um modelo para detecção de riscos, com o uso de *machine learning*, baseado em históricos de contextos;
- O projeto, a modelagem, a implementação e a avaliação de um modelo para predição de acidentes, com a implementação de um modelo *Hidden Markov Model*, aplicando a predição de contextos baseada em históricos de contextos;
- O projeto, a modelagem, a implementação e a implantação de uma ontologia para os cuidados ubíquos em ambientes inteligentes, nomeada *ApolloOnto*;
- A implementação de um simulador de contextos orientados aos cuidados ubíquos em ambientes inteligentes, baseado na *ApolloOnto*, nomeado *Apollo Simulator*;
- A aplicação de robôs de serviço como agentes pró-ativos de suporte aos cuidados ubíquos em ambientes inteligentes, através de um protótipo de robô de serviço chamado *ApolloBot*;
- A utilização de interfaces de usuário acessíveis orientadas aos cuidados ubíquos em ambientes inteligentes.

7.3 Contribuições Acadêmicas e Publicações

Como contribuições adicionais, 12 artigos foram publicados durante o período desta pesquisa e estão disponíveis para a comunidade acadêmica, de acordo com a seguinte lista ordenada cronologicamente.

1. **DA ROSA TAVARES, João Ellison**; VICTÓRIA BARBOSA, Jorge Luis . *Apollo Sign-Sound: an intelligent system applied to ubiquitous healthcare of deaf people*. *JOURNAL OF RELIABLE INTELLIGENT ENVIRONMENTS (JRIE)*, v. 7, p. 157-170, 2021. DOI: 10.1007/s40860-020-00119-w.
2. MACHADO, Savanna D.; **TAVARES, João E. R.**; MARTINS, Márcio G.; BARBOSA, Jorge L. V.; GONZALEZ, Gabriel V.; LEITHARDT, Valderi R. Q. *Ambient Intelligence Based on IoT for Assisting People with Alzheimer's Disease Through Context Histories*. *ELECTRONICS*, v. 10, p. 1260, 2021. DOI: 10.3390/electronics10111260.
3. SANTOS, Nicolas B.; BAVARESCO, Rodrigo; **TAVARES, João E. R.**; RAMOS, Gabriel O.; BARBOSA, Jorge L. V. *A systematic mapping study of robotics in human care*. *ROBOTICS AND AUTONOMOUS SYSTEMS*, v. 1, p. 103833, 2021. DOI: 10.1016/j.robot.2021.103833.
4. MATOS, Christian M.; MATTER, Vítor K.; MARTINS, Márcio G.; **TAVARES, João E. R.**; WOLF, Alexandre; BUTTENBENDER, Paulo C.; BARBOSA, Jorge L. V. *Towards a Collaborative Model to Assist People with Disabilities and the Elderly People in Smart Assistive Cities*. *JOURNAL OF UNIVERSAL COMPUTER SCIENCE (JUCS)*, v. 27, p. 65-86, 2021. DOI: 10.3897/jucs.64591.
5. NETO, Eduardo G. A.; **TAVARES, João E. R.** ; BARBOSA, Jorge L. V. *Cidades inteligentes assistivas apoiando nos cuidados das pessoas com deficiência: um mapeamento sistemático*. *REVISTA BRASILEIRA DE COMPUTAÇÃO APLICADA (RBCA)*, v. 13, p. 54-61, 2021. DOI: 10.5335/rbca.v13i3.12322.
6. MACHADO, Savanna Denega; BARBOSA, Jorge Luis Victória; **TAVARES, João da Rosa**; MARTINS, Márcio Garcia. *DCARE: Um Modelo Computacional para Acompanhamento de Pessoas com Doença de Alzheimer baseado na Análise de Históricos de Contextos*. In: SBSI 2021: XVII Brazilian Symposium on Information Systems, 2021, Uberlândia Brazil. XVII Brazilian Symposium on Information Systems (SBSI). New York: ACM, 2021. p. 1-8. DOI: 10.1145/3466933.3466944.
7. **DA ROSA TAVARES, João Ellison**; VICTÓRIA BARBOSA, Jorge Luis. *Ubiquitous healthcare on smart environments: A systematic mapping study*. *JOURNAL OF AMBIENT INTELLIGENCE AND SMART ENVIRONMENTS (JAISE)*, v. 1, p. 1-17, 2020. DOI: 10.3233/AIS-200581.

8. ARANDA, Jorge Arthur Scheider ; DIAS, Lucas Pfeiffer Salomão ; BARBOSA, Jorge Luis Victória ; DE CARVALHO, Juliano Varella ; **TAVARES, João Elison da Rosa** ; TAVARES, MAURICIO CAMPELO . Collection and analysis of physiological data in smart environments: a systematic mapping. *JOURNAL OF AMBIENT INTELLIGENCE AND HUMANIZED COMPUTING (JAIHC)*, v. 11, p. 2883-2897, 2020. DOI: 10.1007/s12652-019-01409-9.
9. **TAVARES, João E. da R.**; GUTERRES, Tefferson D. DA R.; BARBOSA, Jorge L. V. Apollo APA. In: *the 25th Brazillian Symposium, 2019, Rio de Janeiro. Proceedings of the 25th Brazillian Symposium on Multimedia and the Web - WebMedia '19 (WEBMEDIA)*. New York: ACM Press, p. 281-288, 2019. DOI: 10.1145/3323503.3360295.
10. **TAVARES, João E. R.** ; MOTA, Bruno ; BARBOSA, Jorge L. V. ; YAMIN, Adenauer C ; REAL, Rodrigo A. . Apollo EFP: Um Modelo para Cuidado Ubíquo Aplicado à Prevenção de Quedas de Idosos. In: *XI Simpósio Brasileiro de Computação Ubíqua e Pervasiva (SBCUP), 2019, Belém. Anais do SBCUP 2019*. Porto Alegre: SBC, p. 1-10, 2019. DOI: 10.5753/sbcup.2019.6584.
11. MATOS, Christian M.; MATTER, Vítor K.; VIEGAS, Fábio; MARTINS, Márcio G.; **TAVARES, João E. R.**; BARBOSA, Jorge L. V. *SafeFollowing: A collaborative model for public security agents to assist people with disabilities and the elderly*. *REVISTA DE INFORMÁTICA TEÓRICA E APLICADA (RITA)*, v. 26, p. 75-89, 2019. DOI: 10.22456/2175-2745.92117.
12. BARBOSA, Jorge L. V.; **TAVARES, João E. R.**; CARDOSO, Ismael G.; MOTA, Bruno; MARTINI, Bruno G. *TrailCare: an Indoor and Outdoor Context-aware System to Assist Wheelchair Users*. *INTERNATIONAL JOURNAL OF HUMAN-COMPUTER STUDIES (IJHCS)*, v. 116, p. 1-14, 2018. DOI: 10.1016/j.ijhcs.2018.04.001.

Além disso, três artigos foram submetidos recentemente e se encontram em revisão inicial ou em estágio avançado de *major review*, cujas publicações deverão ocorrer ao longo do ano de 2022.

1. **DA ROSA TAVARES, João Elison**; ULLRICH, Martin; ROTH, Nils; KLUGE, Felix; ESKOFIER, Bjoern M.; GASSNER, Heiko; KLUCKEN, Jochen; GLADOW, Till; MARXREITER, Franz; DA COSTA, Cristiano André; RIGHI, Rodrigo da Rosa; BARBOSA, Jorge Luis Victória. *uTUG: An Unsupervised Timed Up and Go Test for Parkinson's Disease*. *Computer Methods and Programs in Biomedicine (CMPB)*, 2022. Submetido - Em revisão.
2. MACHADO, Savanna Denega; BARBOSA, Jorge Luis Victória; **TAVARES, João da Rosa**; MARTINS, Márcio Garcia. *A Model for Monitoring People with Alzheimer's Dis-*

ease using Context Histories Analysis. Brazilian Journal of Information Systems (iSys), 2022. Submetido - Major Review.

3. **DA ROSA TAVARES, João Elison**; VICTÓRIA BARBOSA, Jorge Luis. *Towards a Prediction of Accidents in Smart Environments*. *Expert Systems with Applications (ESWA)*, 2022. Em preparação.

Esta tese também contribuiu para a inovação tecnológica aplicada através da publicação de três Registros de *Software* junto ao Instituto Nacional da Propriedade Industrial (INPI). Os *softwares* desenvolvidos abarcaram etapas importantes da pesquisa relacionada à aplicação dos ambientes inteligentes para a prevenção de quedas de idosos.

1. **TAVARES, João E. R.**; MOTA, Bruno; BARBOSA, Jorge L. V.. *Apollo EFP Motion*. 2020. Patente: Programa de Computador. Número do registro: BR512020001764-9, data de registro: 01/09/2020, título: "Apollo *EFP Motion*" , Instituição de registro: INPI - Instituto Nacional da Propriedade Industrial.
2. **TAVARES, João E. R.**; MOTA, Bruno; BARBOSA, Jorge L. V.. *Apollo EFP Simulator*. 2020. Patente: Programa de Computador. Número do registro: BR512020001765-7, data de registro: 01/09/2020, título: "Apollo *EFP Simulator*" , Instituição de registro: INPI - Instituto Nacional da Propriedade Industrial.
3. **TAVARES, João E. R.**; MOTA, Bruno; BARBOSA, Jorge L. V.. *Apollo EFP Env*. 2020. Patente: Programa de Computador. Número do registro: BR512020001763-0, data de registro: 01/09/2020, título: "Apollo *EFP Env*", Instituição de registro: INPI - Instituto Nacional da Propriedade Industrial.

Por fim, o autor da tese esteve em missão no exterior realizando parte desta pesquisa em regime de Doutorado Sanduíche, visitando a *Friedrich-Alexander-Universität Erlangen-Nürnberg (FAU)*, na Alemanha, entre o período de março/2021 e agosto/2021. Esta colaboração acadêmica internacional contribui significativamente para o desenvolvimento acadêmico, técnico, pessoal e cultural do doutorando. Além disso, a experiência no *Machine Learning and Data Analytics Lab (MaDLab)*, no Departamento de Inteligência Artificial em Engenharia Biomédica, contribuiu decisivamente para a qualificação das técnicas aplicadas na detecção de quedas, um dos acidentes mais frequentes pesquisados nesta tese. Esta experiência agregou, portanto, não somente para esta pesquisa, mas também para a expansão da internacionalização da Unisinos e aprofundamento dos laços entre os grupos de pesquisa Brasil-Alemanha. O artigo intitulado `uTUG: An Unsupervised Timed Up and Go Test for Parkinson's Disease`, fruto desta etapa de pesquisa, encontra-se em fase de avaliação pelo *Journal of Biomedical Informatics*.

7.4 Trabalhos Futuros

Pesquisas complementares podem ser realizadas com vistas à continuidade desta tese. Primordialmente, observa-se a oportunidade da realização de experimentos com PAR reais englobando uma maior quantidade de participantes e contextos reais.

Constata-se, também, a oportunidade de investigação do uso de *Reinforcement Learning* em conjunto com o *Apollo Simulator* para a realização de treinamentos assistidos do modelo, avaliando a aquisição de mais contextos sem a exposição das pessoas aos riscos pesquisados. Ou seja, vislumbra-se a possibilidade de aprimoramento do *Apollo Simulator*, agregando outros métodos de aprendizado de máquina.

Para o módulo *Detecção de Riscos e Predição de Acidentes*, observa-se a possibilidade de pesquisa de outras técnicas de *machine learning* e *deep learning*, podendo contribuir para o aprimoramento da acurácia do modelo. Além disso, outros modelos preditivos, tal como *Baysean Networks*, tais como *RNN* ou *LTSM*, podem ser comparados com o *HMM* aplicado nesta tese.

Como trabalhos futuros, pretende-se avaliar o uso de *U-Learning* (ANDRADE; RIGO; BARBOSA, 2021; DA SILVA; ROSEMARY; BARBOSA, 2019) de modo integrado com os robôs de serviço interagindo com as PAR e mensurando seu progresso de aprendizado. Isso permitiria ainda a entrega de conteúdo personalizado, orientado ao paradigma dos jogos sérios, com a possibilidade de maior engajamento das PAR e dimensionamento dos impactos para a prevenção de riscos e acidentes.

Vislumbra-se o aprimoramento do *Apollo Simulator* com novas rotinas de geração de *datasets* automatizados e interface gráfica com plantas virtuais dos ambientes inteligentes no modelo de realidade virtual. Considerando-se ainda, a tendência de pesquisas recentes nas linhas da realidade virtual, realidade aumentada e metaverso, visualiza-se a oportunidade de criação do *Apollo Virtual*, que poderia ser desenvolvido agregando um simulador de idade em que um usuário não-idoso pudesse realizar a simulação de atividades da vida diária sem a exposição física aos riscos reais. O uso de realidade virtual ou realidade aumentada, associada ao *Apollo Simulator*, teria potencial para uma pesquisa aprofundada e poderia favorecer a geração de uma maior quantidade de contextos simulados e orientados a situações reais, sem a exposição das pessoas.

O aprofundamento das pesquisas do uso de robôs de serviço integrados aos ambientes inteligentes, segundo indicam a experiência desta pesquisa e do estado da arte, podem contribuir para ambientes mais assistivos e relevantes aos cuidados ubíquos. Seria relevante a avaliação de qual tipo de robô de serviço seria o mais indicado para cada perfil de PAR, tal como humanoíde, do tipo *PetBot* ou baseado em rodas e tela. Além disso, estudos complementares acerca da melhor interface de comunicação a ser adotada, de acordo com o contexto, poderiam ser realizados.

Finalmente, observa-se uma oportunidade de investigação complementar orientada à mas-

siva quantidade de dados gerado pelas PAR e AI. Por isso, além da detecção de riscos e predição de acidentes baseada em históricos de contextos, o desenvolvimento de um *dashboard* ou ferramenta de suporte analítico poderia contribuir para a visualização e a análise de contextos de risco. Uma interface com mapa de calor do ambiente inteligente que auxiliasse na observação de padrões poderia contribuir para o mapeamento de novos cenários. Além disso, outros padrões históricos relacionados a horários e preferências das PAR poderiam ser mais investigados.

REFERÊNCIAS

- A., V. et al. Assistive robots for the elderly: innovative tools to gather health relevant data. **Data Science for Healthcare**, [S.l.], p. 195–215, 2019.
- ABASCAL, J. et al. Towards an intelligent and supportive environment for people with physical or cognitive restrictions. In: . <https://doi.org/10.1145/1579114.1579124>: In Proceedings of 2nd International Conference on Pervasive Technologies Related to Assistive Environments, 2009. p. Article 10.
- ABBROBOTICS. **Abb robotics**. Disponível em: <https://new.abb.com/products/robotics>.
- ABNT. **Gestão de riscos - princípios e diretrizes iso 31000 - 1 ed.** [S.l.: s.n.], 2009.
- ACAMPORA, G. et al. A survey on ambient intelligence in healthcare. **Proceedings of the IEEE**, [S.l.], v. 101, n. 12, p. 2470–2494, 2013.
- AHMADI, H. et al. The application of internet of things in healthcare: a systematic literature review and classification. **Universal Access in the Information Society**, <https://doi.org/10.1007/s10209-018-0618-4>, p. 1–33, 2018.
- AL-AAMA, T. Falls in the elderly: spectrum and prevention. **Canadian family physician Medecin de Famille Canadien**, <http://www.ncbi.nlm.nih.gov/pmc/articles/pmc3135440/>, v. 57, n. 7, p. 771–776, 2011.
- AL-SHAQI, R.; MOURSHED, M.; REZGUI, Y. Progress in ambient assisted systems for independent living by the elderly. **SpringerPlus**, <https://doi.org/10.1186/s40064-016-2272-8>, v. 5, p. 624, 2016.
- ALAM, M.; REAZ, M.; ALI, M. A review of smart homes - past, present and future. **IEEE Transactions on Systems, Man, and Cybernetics - Part C: Applications and Reviews**, <https://doi.org/10.1109/TSMCC.2012.2189204>, v. 6, n. 42, p. 1190–1203, 2012.
- ALAM, M.; REAZ, M.; ALI, M. A review of smart homes - past, present and future. **IEEE Transactions on Systems, Man, and Cybernetics - Part C: Applications and Reviews**, <https://doi.org/10.1109/TSMCC.2012.2189204>, v. 6, n. 42, p. 1190–1203, 2012.
- ALBERTI, A. et al. Advancing novagenesis architecture towards future internet of things. **IEEE Internet of Things Journal**, <https://doi.org/10.1109/JIOT.2017.2723953>, v. 11, n. 3, p. 255–278, 2017.
- ALHUSSEIN, M.; MUHAMMAD, G.; HOSSAIN, M. Mobile networks and applications. **Applied Ontology**, <https://doi.org/10.1007/s11036-018-1113-0>, v. 23, n. 6, p. 1624–1635, 2018.
- ALKHOMSAN, M. et al. Situation awareness in ambient assisted living for smart healthcare. **IEEE Access**, <https://doi.org/10.1109/ACCESS.2017.2731363>, v. 5, n. 3, p. 20716–20725, 2017.

AMIRIBESHELI, M.; BOUCHACHIA, H. Journal of ambient intelligence and humanized computing. **Applied Ontology**, <https://doi.org/10.1007/s12652-017-0645-7>, v. 9, n. 6, p. 1755–1782, 2018.

ANDRADE, T. L. de; RIGO, S. J.; BARBOSA, J. L. V. Active methodology, educational data mining and learning analytics: a systematic mapping study. **Informatics in Education**, [S.l.], v. 20, n. 2, p. 171–204, 2021.

ARANDA, J. A. S. et al. A computational model for adaptive recording of vital signs through context histories. **Journal of Ambient Intelligence and Humanized Computing**, [S.l.], v. 1, p. 1–15, 2021.

ARANDA, J. A. S. et al. A computational model for adaptive recording of vital signs through context histories. **Journal of Ambient Intelligence and Humanized Computing**, [S.l.], v. 1, p. 1–15, 2021.

AZIZA, R. et al. Simnacd. **Eng. Appl. Artif. Intell.**, USA, v. 52, n. C, p. 235–247, jun 2016.

BALDAUF, M.; DUSTDAR, S.; ROSENBERG, F. A survey on context-aware systems. **International Journal of Ad Hoc and Ubiquitous Computing**, [S.l.], v. 2, n. 4, p. 263–277, 2007.

BANNERMAN, P. L. Risk and risk management in software projects: a reassessment. **Journal of Systems and Software**, [S.l.], v. 81, n. 12, p. 2118–2133, 2008. Best papers from the 2007 Australian Software Engineering Conference (ASWEC 2007), Melbourne, Australia, April 10-13, 2007.

BASTAKI, B.; BOSAKOWSKI, T.; BENKHELIFA, E. Intelligent assisted living framework for monitoring elders. In: . <https://doi.org/10.1109/AICCSA.2017.213>: In IEEE/ACS 14th International Conference on Computer Systems and Applications (AICCSA), 2017. p. 255–278.

BECKER, E. et al. Smartdrawer: rfid-based smart medicine drawer for assistive environments. In: . <https://doi.org/10.1145/1579114.1579163>: In Proceedings of 2nd International Conference on Pervasive Technologies Related to Assistive Environments, 2009. p. Article 49.

BECKER, E. et al. Event-based experiments in an assistive environment using wireless sensor networks and voice recognition. In: . <https://doi.org/10.1145/1579114.1579131>: In Proceedings of 2nd International Conference on Pervasive Technologies Related to Assistive Environments, 2009. p. Article 17.

BECKER, E. et al. Smartdrawer: rfid-based smart medicine drawer for assistive environments. In: . <https://doi.org/10.1145/1579114.1579163>: In Proceedings of 2nd International Conference on Pervasive Technologies Related to Assistive Environments, 2009. p. Article 49.

BONACCORSI, M. et al. A cloud robotics solution to improve social assistive robots for active and healthy aging. **International Journal of Social Robotics**, [S.l.], v. 8, n. 3, p. 393–408, Jun 2016.

BONACCORSI, M. et al. A cloud robotics solution to improve social assistive robots for active and healthy aging. **International Journal of Social Robotics**, <https://doi.org/10.1007/s12369-016-0351-1>, v. 8, n. 3, p. 393–408, 2016.

BOOCH GRADY; JACOBSON, I. R. J. **The unified modeling language for object-oriented development v. 0.9**. [S.l.]: Rational Software Corp., 1996.

BORELLI, E. et al. Habitat: an iot solution for independent elderly. **Sensors**, <https://doi.org/10.3390/s19051258>, v. 19, n. 5, p. 1258, 2019.

BOSTONDYNAMICS. **Boston dynamics**. Disponível em: <https://www.bostondynamics.com/>.

BOTIA, J.; VILLA, A.; PALMA, J. Ambient assisted living system for in-home monitoring of healthy independent elders. **Expert Systems with Applications**, <https://doi.org/10.1016/j.eswa.2012.01.153>, v. 39, n. 9, p. 8136–8148, 2012.

BOUCHARD, K.; BOUCHARD, B.; BOUZOUANE, A. Guidelines to efficient smart home design for rapid ai prototyping: a case study. In: . <https://doi.org/10.1145/2413097.2413134>: In Proceedings of 5th International Conference on Pervasive Technologies Related to Assistive Environments, 2012. p. Article 29.

BRL. **Bristol robotics laboratory**. Disponível em: <https://www.bristolroboticslab.com/>.

BRODZKA, W.; THORNHILL, H. L.; HOWARD, S. Burns: causes and risk factors. **Archives of physical medicine and rehabilitation**, [S.l.], v. 66, n. 11, p. 746–752, 1985.

BROUWER, M. D. et al. Towards a cascading reasoning framework to support responsive ambient-intelligent healthcare interventions. **Sensors**, <https://doi.org/10.3390/s18103514>, v. 18, n. 10, p. 3514, 2018.

BURBEY, I.; MARTIN, T. L. A survey on predicting personal mobility. **International Journal of Pervasive Computing and Communications**, [S.l.], v. 8, n. 1, p. 5–22, Jan 2012.

BVSMS. **Queimaduras - biblioteca virtual em saúde do ministério da saúde**. Disponível em: <https://bvsms.saude.gov.br/queimaduras/>, note = Acessado em: 2021-11-30.

CAMARADEPUTADOS. **Lei nº 13.146, de 6 de julho de 2015 - portal da câmara dos deputados**. Disponível em: <https://www2.camara.leg.br/legin/fed/lei/2015/lei-13146-6-julho-2015-781174-publicacaooriginal-147468-pl.html>.

CBMPB. **Afogamento**. Disponível em: <https://bombeiros.pb.gov.br/bombeiros-alertam-a-populacao-para-os-riscos-de-afogamento-em-acudes-2>, note = Acessado em: 2021-12-01.

CELINO, S. et al. Morbimortalidade por causas externas no brasil entre 2015 e 2019: um estudo ecológico. **Revista Ciência Plural**, [S.l.], v. 7, n. 3, p. 180–201, Agosto 2021.

CHAN, M. et al. Mobility behavior assessment using a smart-monitoring system to care for the elderly in a hospital environment. In: . <https://doi.org/10.1145/2674396.2674397>: In Proceedings of 7th International Conference on Pervasive Technologies Related to Assistive Environments, 2014. p. Article 51.

CHEN, Y. et al. An intelligent knowledge-based and customizable home care system framework with ubiquitous patient monitoring and alerting techniques. **Sensors**, <https://dx.doi.org/10.3390>

CHEN, Y. et al. Monitoring elder's living activity using ambient and body sensor network in smart home. In: . <https://doi.org/10.1109/SMC.2015.515>: In IEEE International Conference on Systems, Man, and Cybernetics, 2015.

CHIBANI, A. et al. Ubiquitous robotics: recent challenges and future trends. **Robotics and Autonomous Systems**, [S.l.], v. 61, n. 11, p. 1162–1172, 2013. Ubiquitous Robotics.

CHIÊM, J.-C.; MACQ, J.; SPEYBROECK, N. Rule-based modeling of chronic disease epidemiology: elderly depression as an illustration. **PLOS ONE**, [S.l.], v. 7, n. 8, p. 1–14, 08 2012.

CONNELLY, K. et al. The future of pervasive health. **IEEE Pervasive Computing**, [S.l.], v. 16, n. 1, p. 16–20, 2017.

COSTA, C. A. da et al. Internet of health things: toward intelligent vital signs monitoring in hospital wards. In: . [S.l.: s.n.], 2018. v. 89, p. 61.

CRUZ, B.; CORDOVIL, P.; BATISTA, K. Perfil epidemiológico de pacientes que sofreram queimaduras no brasil: revisão de literatura. **Revista Brasileira de Queimaduras**, [S.l.], v. 11, n. 4, p. 246–250, 2012.

CUNHA, A.; LOURENÇO, R. Quedas em idoso: prevalências e fatores associados. **Revista Hospital Universitário Pedro Ernesto**, [S.l.], v. 13 (2), p. 21–29, 2014.

D., A.; M., M.; C., T. A survey of prediction approach in pervasive computing. **International Journal of Scientific Engineering Research**, [S.l.], v. 6, n. 5, p. 1–11, 2015.

D. PUPO; A., M. S. F. **Acessibilidade**: discurso e prática no cotidiano das bibliotecas. [S.l.]: UNICAMP: Biblioteca Cesar Lattes Central, 2006.

da Rosa, J. H.; BARBOSA, J. L.; RIBEIRO, G. D. Oracon: an adaptive model for context prediction. **Expert Systems with Applications**, [S.l.], v. 45, p. 56–70, 2016.

DA SILVA, L.; ROSEMARY, F.; BARBOSA, J. Locallearn: um modelo u-learning para auxílio no aprendizado do vocabulário de inglês. **RENOTE - Revista Novas Tecnologias na Educação**, [S.l.], v. 17, n. 3, 2019.

DALTON, V. **Moderno gerenciamento de projetos. 2 ed.** [S.l.]: Prentice Hall, 2016.

DATASUS. **Tabnet win32 3.0 - Óbitos por causas externas - brasil**. Disponível em: <http://tabnet.datasus.gov.br/cgi/tabcgi.exe?sim/cnv/ext10uf.def>, note = Acessado em: 2021-11-05.

DATASUS. **Informações de saúde - tabnet datasus**. Disponível em: <https://datasus.saude.gov.br/informacoes-de-saude-tabnet/>, note = Acessado em: 2021-12-19.

DATASUS. **Estatísticas de saúde no brasil**. Disponível em: <http://tabnet.datasus.gov.br/cgi/tabcgi.exe?sim/cnv/obt10uf.def>.

DE ALMEIDA, S. T. et al. Análise de fatores extrínsecos e intrínsecos que predisõem a quedas em idosos. **Revista da Associação Médica Brasileira**, [S.l.], v. 58, n. 4, p. 427–433, 2012.

DEEN, J. Information and communications technologies for elderly ubiquitous healthcare in a smart home. **Personal and Ubiquitous Computing**, <https://doi.org/10.1007/s00779-015-0856-x>, v. 19, n. 3-4, p. 573–599, 2015.

DEL DOTTORE, E. et al. Toward growing robots: a historical evolution from cellular to plant-inspired robotics. **Frontiers in Robotics and AI**, [S.l.], v. 5, 2018.

DEY, A. K. Understanding and using context. **Personal and Ubiquitous Computing**, [S.l.], v. 5, n. 1, p. 4–7, Feb 2001.

DO, H. et al. Rish: a robot-integrated smart home for elderly care. robotics and autonomous systems. **Robotics and Autonomous Systems**, <https://doi.org/10.1016/j.robot.2017.12.008>, v. 101, n. 3, p. 74–92, 2018.

D'ONOFRIO, G. et al. Assistive robots for socialization in elderly people: results pertaining to the needs of the users. **Aging clinical and experimental research**, [S.l.], v. 31, n. 9, p. 1313–1329, 2019.

DOUKAS, C. et al. Emergency incidents detection in assisted living environments utilizing sound and visual perceptual componentes. In: . <https://doi.org/10.1145/1579114.1579128>: In Proceedings of 2nd International Conference on PErvasive Technologies Related to Assistive Environments, 2009. p. Article 14.

DOUKAS, C. et al. Digital cities of the future: extending @home assistive technologies for the elderly and the disabled. **Telematics and Informatics**, <https://doi.org/10.1016/j.tele.2010.08.001>, v. 28, n. 3, p. 176–190, 2011.

ECLIPSE. **Eclipse foundation**. Disponível em: <https://www.eclipse.org/downloads/>.

EDERALDO LUIZ BELINE, P. T. e. In: XII ENCONTRO DE ENGENHARIA DE PRODUÇÃO AGROINDUSTRIAL (XII EEPA), 2018. **Anais...** [S.l.: s.n.], 2018. p. 1–9.

ENGEHALL. **Choque elétrico**. Disponível em: <https://www.cursonr10.com/choque-eletrico-curso-nr10/>, note = Acessado em: 2021-11-05.

FILIPPETTO, A. S.; LIMA, R.; BARBOSA, J. L. V. A risk prediction model for software project management based on similarity analysis of context histories. **Information and Software Technology**, [S.l.], v. 131, p. 106497, 2021.

FILIPPETTO, A. S.; LIMA, R.; BARBOSA, J. L. V. A risk prediction model for software project management based on similarity analysis of context histories. **Information and Software Technology**, [S.l.], v. 131, p. 106497, 2021.

FIORINI, L. et al. Enabling personalised medical support for chronic disease management through a hybrid robot-cloud approach. **Autonomous Robots**, <https://doi.org/10.1007/s10514-016-9586-9>, v. 41, n. 5, p. 1263–1276, 2017.

FOURNIER, D. et al. Towards ad hoc contextual services for pervasive computing. In: WORKSHOP ON MIDDLEWARE FOR SERVICE ORIENTED COMPUTING (MW4SOC 2006), 1., 2006, New York, NY, USA. **Proceedings...** Association for Computing Machinery, 2006. p. 36–41. (MW4SOC '06).

GARCIA-CONSTANTINO, M. et al. Ambient and wearable sensor fusion for abnormal behaviour detection in activities of daily living. In: IEEE INTERNATIONAL CONFERENCE ON PERVASIVE COMPUTING AND COMMUNICATIONS WORKSHOPS (PERCOM WORKSHOPS), 2020., 2020. **Anais...** [S.l.: s.n.], 2020. p. 1–6.

GARCIA, E. et al. The evolution of robotics research. **IEEE Robotics Automation Magazine**, [S.l.], v. 14, n. 1, p. 90–103, 2007.

GEORGIATECH. **Institute for robotics and intelligent machines**. Disponível em: <https://research.gatech.edu/robotics>.

GHASEMI, F.; REZAEI, A.; RAHMANI, A. Structural and behavioral reference model for iot-based elderly health-care systems in smart home. **International Journal of Communication Systems**, <https://doi.org/10.1002/dac.4002>, v. 32, n. 12, p. 255–278, 2019.

GIRDHAR, M. et al. Hidden markov models based anomaly correlations for the cyber-physical security of ev charging stations. **IEEE Transactions on Smart Grid**, [S.l.], p. 1–1, 2021.

GOOGLE. **Google colab**. Disponível em: <https://colab.research.google.com>, note = Acessado em: 2022-01-10.

HELAL, A.; COOK, D.; SCHMALZ, M. Smart home-based health platform for behavioral monitoring and alteration of diabetes patients. **Journal of Diabetes Science and Technology**, <https://dx.doi.org/10.1177v.3>, n. 1, p. 141–148, 2009.

HUANG, J.; YU, S.; SYU, H. Development of the smart toilet equipment with measurements of physiological parameters. In: . <https://doi.org/10.1109/UIC-ATC.2012.143>: In 9th International Conference on Ubiquitous Intelligence and Computing and 9th International Conference on Autonomic and Trusted Computing, 2012.

HUANG, M. et al. Inconspicuous on-bed respiratory rate monitoring. In: . <https://doi.org/10.1145/2504335.2504353>: In Proceedings of 6th International Conference on Pervasive Technologies Related to Assistive Environments, 2013. p. Article 18.

IETF. **Common format and mime type for comma-separated values (csv) files**. Disponível em: <https://datatracker.ietf.org/doc/html/rfc4180>.

IMAMURA, J. **Epidemiologia dos traumas em países desenvolvidos e em desenvolvimento, dissertação de mestrado – usp, 2012**. Disponível em: <http://www.teses.usp.br/teses/disponiveis/5/5141/tde-18092012-161930/pt-br.php>.

IQBAL, M. et al. Living++: a platform for assisted living applications. In: . <https://doi.org/10.1145/2494091.2497327>: In Proceedings of the 2013 ACM conference on Pervasive and ubiquitous computing adjunct publication, 2013. p. 853–860.

IROBOT. **Roomba® robot vacuums**. Disponível em:

<https://www.irobot.com/roomba>.

JARVIS, R. et al. An intelligent robotic assistive living system. In: .

<https://doi.org/10.1145/1579114.1579174>: In Proceedings of 2nd International Conference on Pervasive Technologies Related to Assistive Environments, 2009. p. Article 60.

JUNG, Y.; YOON, Y. Multi-level assessment model for wellness service based on human mental stress level. **Multimedia Tools and Applications**,

<https://doi.org/10.1007/s11042-016-3444-9>, v. 76, n. 9, p. 11305–11317, 2017.

KAFFASH-CHARANDABI, N.; ALESHEIKH, A.; SHARIF, M. A ubiquitous asthma monitoring framework based on ambient air pollutants and individuals' contexts.

Environmental Science and Pollution Research,

<https://doi.org/10.1007/s11356-019-04185-3>, v. 26, n. 8, p. 7525, 2019.

KESHAV, S. How to read a paper. **ACM SIGCOMM Comput. Commun.**,

<https://doi.org/10.1145/1273445.1273458>, v. 37, n. 3, p. 83–84, 2007.

KIM, Y. B.; KIM, M.; LEE, Y. J. Cosmos: a middleware platform for sensor networks and a u-healthcare service. In: ACM SYMPOSIUM ON APPLIED COMPUTING, 2008., 2008,

New York, NY, USA. **Proceedings...** Association for Computing Machinery, 2008.

p. 512–513. (SAC '08).

KITCHENHAM, B.; BUDGEN, D.; BRERETON, O. Using mapping studies as the basis for further research—a participant-observer case study. **Information and Software Technology**,

<https://doi.org/10.1016/j.infsof.2010.12.011>, v. 53, n. 6, p. 638–651, 2011.

KITCHENHAM, B.; CHARTERS, S. Guidelines for performing systematic literature reviews in software engineering. **Keele University and Durham University Joint Report**, [S.l.],

2007.

KITCHENHAM, B. et al. Systematic literature reviews in software engineering—a tertiary

study. **Information and Software Technology**, <https://doi.org/10.1016/j.infsof.2010.03.006>,

v. 52, n. 8, p. 792–805, 2010.

KLAKEGG, S. et al. Designing a context-aware assistive infrastructure for elderly care. In: .

<https://doi.org/10.1145/3123024.3124403>: In UbiComp '17 Proceedings of the 2017 ACM International Joint Conference on Pervasive and Ubiquitous Computing and Proceedings of the 2017 ACM International Symposium on Wearable Computers, 2017. p. 563–568.

KOURTIS, L. et al. Digital biomarkers for alzheimer's disease: the mobile/wearable devices opportunity. **Digital Medicine**, <https://doi.org/10.1038/s41746-019-0084-2>, v. 2, p. Article 9, 2019.

LIN, Y. et al. Decision making in assistive environments using multimodal observations. In: .

<https://doi.org/10.1145/1579114.1579120>: In Proceedings of 2nd International Conference on Pervasive Technologies Related to Assistive Environments, 2009. p. Article 6.

LIQUANE, Z. et al. An improved extreme learning machine model for the prediction of human scenarios in smart homes. **Applied Intelligence**, USA, v. 48, n. 8, p. 2017–2030, aug 2018.

- LITTLE, L.; BRIGGS, P. Pervasive healthcare: the elderly perspective. In: INTERNATIONAL CONFERENCE ON PERVASIVE TECHNOLOGIES RELATED TO ASSISTIVE ENVIRONMENTS, 2., 2009, New York, NY, USA. **Proceedings...** Association for Computing Machinery, 2009. (PETRA '09).
- LIU, L. et al. Smart homes and home health monitoring technologies for older adults: a systematic review. **International Journal of Medical Informatics**, <https://doi.org/10.1016/j.ijmedinf.2016.04.007>, v. 91, p. 44–59, 2016.
- MACHADO, S. D. et al. Ambient intelligence based on iot for assisting people with alzheimer's disease through context histories. **Electronics**, [S.l.], v. 10, n. 11, 2021.
- MALHOTRA, N. **Pesquisa de marketing: uma orientação aplicada**. Porto Alegre: Bookman, 2001.
- MANZI, A. et al. Design of a cloud robotic system to support senior citizens: the kubo experience. **Autonomous Robots**, <https://doi.org/10.1007/s10514-016-9569-x>, v. 41, n. 3, p. 699–709, 2017.
- MARTINI, B. G. et al. Indoorplant: a model for intelligent services in indoor agriculture based on context histories. **Sensors**, [S.l.], v. 21, p. 1631, 2021.
- MARTINI, B. G. et al. Indoorplant: a model for intelligent services in indoor agriculture based on context histories. **Sensors**, [S.l.], v. 21, n. 5, 2021.
- MATTIMORE, T. J. et al. Surrogate and physician understanding of patients' preferences for living permanently in a nursing home. **Journal of the American Geriatrics Society**, [S.l.], v. 45, n. 7, p. 818–824, 1997.
- MAYTRONICS. **Residential robotic pool cleaners**. Disponível em: <https://maytronicsus>.
- MEDJAHED, H. et al. A pervasive multi-sensor data fusion for smart home healthcare monitoring. In: . <https://doi.org/10.1109/FUZZY.2011.6007636>: In IEEE International Conference on Fuzzy Systems (FUZZ-IEEE), 2011.
- MEHDI, S.; BERNS, K. Guidelines to efficient smart home design for rapid ai prototyping: a case study. In: . <https://doi.org/10.1145/2141622.2141631>: In Proceedings of 4th International Conference on Pervasive Technologies Related to Assistive Environments, 2011. p. Article 7.
- MELIONES, A.; KOKKOVOS, S. Privacy-preserving intelligent networked video surveillance for patient monitoring and alarm detection. In: . <https://doi.org/10.1145/2769493.2769509>: In Proceedings of 8th International Conference on Pervasive Technologies Related to Assistive Environments, 2015. p. Article 63.
- MITSUBISHIELECTRIC. **Industrial robots-melfa**. Disponível em: <https://www.mitsubishielectric.com/fa/products/rbt/robot/index.html>.
- MOSQUITTO. **Eclipse mosquito**. Disponível em: <https://mosquitto.org/>.
- NARENDRA, N. C. et al. Functional and architectural adaptation in pervasive computing environments. In: INTERNATIONAL WORKSHOP ON MIDDLEWARE FOR PERVASIVE AND AD-HOC COMPUTING, 3., 2005, New York, NY, USA. **Proceedings...** Association for Computing Machinery, 2005. p. 1–7. (MPAC '05).

NEVES, F. et al. Heath-prior: an intelligent ensemble architecture to identify risk cases in healthcare. **IEEE Access**, [S.l.], v. 8, p. 217150–217168, 2020.

NOCENTINI, O. et al. A survey of behavioral models for social robots. **Robotics**, [S.l.], v. 8, n. 3, 2019.

OBERC, H. et al. Human robot interaction – learning how to integrate collaborative robots into manual assembly lines. **Procedia Manufacturing**, [S.l.], v. 31, p. 26–31, 2019. Research. Experience. Education. 9th Conference on Learning Factories 2019 (CLF 2019), Braunschweig, Germany.

OGUNDUYILE, O.; OLUGBARAB, O.; LALL, M. Development of wearable systems for ubiquitous healthcare service provisioning. **APCBEE Procedia**, <https://doi.org/10.1016/j.apcbee.2013.08.028>, v. 7, p. 163–168, 2013.

OLIVER, M. et al. Ambient intelligence environment for home cognitive telerehabilitation. **Sensors**, [S.l.], v. 18, p. 3671, 2018.

OLIVIER, P. et al. Ambient kitchen: designing situated services using a high fidelity prototyping environment. In: . <https://doi.org/10.1145/1579114.1579161>: In Proceedings of 2nd International Conference on Pervasive Technologies Related to Assistive Environments, 2009. p. Article 47.

OMS. **Publicações da oms**. Disponível em:

<https://www.who.int/eportuguese/publications/pt/>, note = Acessado em: 2021-12-02.

ONROMROBOTICS. **Robotics**. Disponível em:

<https://automation.omron.com/en/us/products/category/robotics>.

ONU. **Objetivo 3: saúde e bem-estar**. Disponível em: <https://www.br.undp.org/content/brazil/pt/home/sustainable-development-goals/goal-3-good-health-and-well-being.html>.

PADGHAM, L.; WINIKOFF, M. **Developing intelligent agent systems: a practical guide**. [S.l.]: Australia: Wiley, 2004.

PAPADOPOULOS, I. et al. Enablers and barriers to the implementation of socially assistive humanoid robots in health and social care: a systematic review. **BMJ Open**, [S.l.], v. 10, n. 1, 2020.

PAPAGEORGIOU, X. et al. Intelligent assistive robotic systems for the elderly: two real-life use cases. In: . <https://doi.org/10.1145/3056540.3076184>: In Proceedings of 10th International Conference on Pervasive Technologies Related to Assistive Environments, 2017.

PDT. **Prometheus/pdt**. Disponível em: <https://sites.google.com/site/rmitagents/software/prometheusPDT>.

PEDIATRIA, S. B. de. **Acidentes domésticos estão entre principais causas de morte de crianças**. Disponível em: <https://www.sbp.com.br/imprensa/detalhe/nid/acidentes-domesticos-estao-entre-principais-causas-de-morte-de-criancas>

PEJOVIC, V.; MUSOLESI, M. Anticipatory mobile computing: a survey of the state of the art and research challenges. **ACM Comput. Surv.**, New York, NY, USA, v. 47, n. 3, apr 2015.

- PEREIRA, J. et al. A movement activity recognition pervasive system for patient monitoring in ambient assisted living. In: . <https://doi.org/10.1145/2851613.2851689>: In SAC'16 Proceedings of the 31st Annual ACM Symposium on Applied Computing, 2016. p. 155–161.
- PETERSEN, K. et al. Systematic mapping studies in software engineering. In: . [S.l.]: In 12th International Conference on Evaluation and Assessment in Software Engineering, 2008. p. 68–77.
- PETERSEN, K.; VAKKALANKA, S.; KUZNIARZ, L. Guidelines for conducting systematic mapping studies in software engineering: an update. **Information and Software Technology**, <https://doi.org/10.1016/j.infsof.2015.03.007>, v. 64, p. 1–18, 2015.
- PHAM, M. et al. Delivering home healthcare through a cloud-based smart home environment (coshe). **Future Generation Computer Systems**, <https://doi.org/10.1016/j.future.2017.10.040>, v. 81, p. 129–140, 2018.
- PODSIADLO, D.; RICHARDSON, S. Go": a test of basic functional mobility for frail elderly persons. **J Am Geriatr Soc**, [S.l.], v. 39, n. 2, p. 142–148, Feb 1991.
- PONCELA, A. et al. Smart care home system: a platform for eassistance. **Journal of Ambient Intelligence and Humanized Computing**, <https://doi.org/10.1007/s12652-018-0979-9>, v. 10, p. 1–25, 2018.
- PYCARET. **Pycaret**. Disponível em: <https://pycaret.org/>, note = Acessado em: 2022-01-10.
- RICHARDS, D. **Afogamento - manual msd - university of colorado school of medicine**. Disponível em: <https://www.msmanuals.com/pt-br/casa/les%C3%B5es-e-envenenamentos/afogamento/afogamento>, note = Acessado em: 2021-12-01.
- ROBERT L. BERG JOSEPH S. CASSELLS, e. **The second fifty years: promoting health and preventing disability - institute of medicine (us) division of health promotion and disease prevention**. Washington (DC): National Academies Press (US), 1992.
- ROBERT, M. **Clean architecture: a craftsman's guide to software structure and design**. [S.l.]: Pearson, 2017.
- ROBOTREPORT. **10 robotics companies to watch in 2019**. Disponível em: <https://www.therobotreport.com/robotics-companies-to-watch-in-2019/>.
- ROSA TAVARES, J. E. da; VICTÓRIA BARBOSA, J. L. Ubiquitous healthcare on smart environments: a systematic mapping study. **Journal of Ambient Intelligence and Smart Environments**, [S.l.], v. 12, p. 513–529, 2020. 6.
- ROSA TAVARES, J. E. da; VICTÓRIA BARBOSA, J. L. Apollo signsound: an intelligent system applied to ubiquitous healthcare of deaf people. **Journal of Reliable Intelligent Environments**, [S.l.], v. 7, n. 2, p. 157–170, Jun 2021.
- ROSANSWERS. **Pr2 drifts over time in gazebo**. Disponível em: <https://answers.ros.org/question/42011/pr2-drifts-over-time-in-gazebo/>.

ROSTIROLLA, G. et al. Elcity: an elastic multilevel energy saving model for smart cities. **IEEE Transactions on Sustainable Computing**, <https://doi.org/10.1109/TSUSC.2017.2749880>, v. 3, p. 30–43, 2018.

RUNDE, D. **Lesões por choque elétrico - manual msd - university of iowa hospitals and clinics**. Disponível em: <https://www.msmanuals.com/pt-br/profissional/les%C3%B5es-intoxica%C3%A7%C3%A3o/les%C3%B5es-por-choque-el%C3%A9trico-e-raios/les%C3%B5es-por-choque-el%C3%A9trico>, note = Acessado em: 2021-12-01.

SADRI, F. Ambient intelligence: a survey. **ACM Comput. Surv.**, New York, NY, USA, v. 43, n. 4, oct 2011.

SANTOS, N. B. et al. A systematic mapping study of robotics in human care. **Robotics and Autonomous Systems**, [S.l.], v. 144, p. 103833, 2021.

SATYANARAYANAN, M. Pervasive computing: vision and challenges. **IEEE Personal Communications**, [S.l.], v. 8, n. 4, p. 10–17, 2001.

SBP. **Queimaduras - sociedade brasileira de pediatria**. Disponível em: <https://www.sbp.com.br/imprensa/detalhe/nid/queimaduras/>, note = Acessado em: 2021-11-29.

SEMPREBOM TIAGO; CAMADA, M. Y. M. I. **Ontologias e protÉgÉ. universidade federal de santa catarina (ufsc) - florianópolis, sc, brazil**. [S.l.: s.n.], 2007.

SERRA, M. et al. Análise de pacientes internados por queimadura elétrica. **Revista Brasileira de Queimaduras**, [S.l.], v. 10, n. 4, p. 124–128, 2011.

SILVA, J. M. et al. Content distribution in trail-aware environments. **Journal of the Brazilian Computer Society**, [S.l.], v. 16, n. 3, p. 163–176, Sep 2010.

SOTO-MENDOZA, V. et al. Design of a predictive scheduling system to improve assisted living services for elders. **ACM Trans. Intell. Syst. Technol.**, New York, NY, USA, v. 6, n. 4, jul 2015.

SPANAKIS, E. et al. Diabetes management using modern information and communication technologies and new care models. **Interactive Journal of Medical Research**, <http://dx.doi.org/10.2196/ijmr.2193>, v. 1, n. 2, 2012.

SPARREMBERGER, A. et al. Groupprofile: um modelo de gerenciamento de perfis de grupos de aprendizes em ambiente virtual de aprendizagem. **Revista Brasileira de Informática na Educação**, [S.l.], v. 27, n. 03, p. 369–402, 2019.

SPOLADORE, D. et al. Domus: a domestic ontology managed ubiquitous system. **Journal of Ambient Intelligence and Humanized Computing**, [S.l.], Mar 2021.

SPSP. **Panorama da mortalidade por acidentes em crianças e adolescentes no brasil - pediatria atualize-se - sociedade de pediatria de são paulo**. Disponível em: <https://www.spsp.org.br/site/asp/boletins/AT9.pdf>, note = Acessado em: 2021-11-09.

SURYADEVARA, N.; MUKHOPADHYAY, S. Determining wellness through an ambient assisted living environment. **Intelligent Systems**, <https://doi.org/10.1109/MIS.2014.16>, v. 29, n. 3, p. 30–37, 2014.

TEMDEE, P.; UTTAMA, S. Smart care environment with food recognition for personalization support: a case study of thai seniors. **Wireless Personal Communications**, <https://doi.org/10.1007/s11277-019-06636-z>, p. 1–15, 2019.

TENTORI, M.; ESCOBEDO, L.; BALDERAS, G. A smart environment for children with autism. **IEEE Pervasive Computing**, <https://doi.org/10.1109/MPRV.2015.22>, v. 14, n. 2, p. 42–50, 2015.

TMPR. **The czech play that gave us the word ‘robot’ - the mit press reader**. Disponível em: <http://thereader.mitpress.mit.edu/origin-word-robot-rur/>.

TRABALHO, S. do. **10 acidentes domésticos mais comuns**. Disponível em: <https://www.blogsegurancadotrabalho.com.br/10-acidentes-domesticos-mais-comuns/>.

UBROBOT. **Ubttech**. Disponível em: <https://www.ubtrobot.com/?ls=pt>.

UML. **What is uml**. Disponível em: <https://www.uml.org/what-is-uml.htm>.

UN. **Afogamentos continuam sendo uma das principais causas de mortes acidentais**. Disponível em: <https://news.un.org/pt/story/2021/07/1757642>, note = Acessado em: 2021-12-08.

UN. United nations: ageing. , <https://www.un.org/en/global-issues/ageing>, 2022.

VALERO, M. et al. Integration of multisensor hybrid reasoners to support personal autonomy in the smart home. **Sensors**, <https://doi.org/10.3390/s140917313>, v. 14, n. 9, 2014.

VANSYCKEL, S.; BECKER, C. A survey of proactive pervasive computing. In: ACM INTERNATIONAL JOINT CONFERENCE ON PERVASIVE AND UBIQUITOUS COMPUTING: ADJUNCT PUBLICATION, 2014., 2014, New York, NY, USA. **Proceedings...** Association for Computing Machinery, 2014. p. 421–430. (UbiComp '14 Adjunct).

VARELLA, D. **Acidentes domésticos**. Disponível em: <https://drauziovarella.uol.com.br/pediatria/acidentes-domesticos-entrevista/>.

VIANNA, H.; BARBOSA, J. A scalable model for building context-aware applications for noncommunicable diseases prevention. **Information Processing Letters**, <http://dx.doi.org/10.1016/j.ipl.2019.03.010>, p. 1–10, 2019.

WEISER, M. The computer for the 21st century. **SIGMOBILE Mob. Comput. Commun. Rev.**, New York, NY, USA, v. 3, n. 3, p. 3–11, jul 1991.

WHO. **Who global report on falls prevention in older age**. Disponível em: https://www.who.int/ageing/publications/Falls_prevention7March.pdf, note = Acessado em: 2021-12-05.

WHO. **Burns**. Disponível em:

<https://www.who.int/news-room/fact-sheets/detail/burns>, note =
Acessado em: 2021-11-28.

WHO. **International statistical classification of diseases and related health problems 10th revision**. Disponível em: <https://icd.who.int/browse10/2019/en#/>.

WHO. World health organization: disability. In: . <https://www.who.int/disabilities/en/>: [s.n.], 2019.

WHO. World health organization: chronic diseases and health promotion. In: . <https://www.who.int/nutrition/topics/2background/en/> : [s.n.], 2019.

WHO. **Falls, burns and drowning**. Disponível em: https://www.who.int/violence_injury_prevention/media/events/David-Meddings-WHO.pdf, note = Acessado em: 2021-11-09.

WHO. **World health organization: injuries and violence**. Disponível em: <https://www.who.int/news-room/fact-sheets/detail/injuries-and-violence>.

WHO. **Icd-11 for mortality and morbidity statistics**. Disponível em: <https://icd.who.int/browse11/l-m/en>.

WHO. **Falls**. Disponível em:

<https://www.who.int/news-room/fact-sheets/detail/falls>.

WHO. **International classification of functioning, disability and health (icf)**. Disponível em: <https://apps.who.int/classifications/icfbrowser/>.

WHO. **Classificação internacional de causas externas de lesões (cicel)**. Disponível em: <https://www.whofic.nl/sites/default/files/2018-05/ICECI%20in%20Portugese.pdf>.

WHO. **Mental health: strengthening our response**. Disponível em:

<https://www.who.int/news-room/fact-sheets/detail/mental-health-strengthening-our-response>.

WHORISKEY, K. et al. Predicting aquatic animal movements and behavioural states from acoustic telemetry arrays. **Methods in Ecology and Evolution**, [S.l.], v. n/a, n. n/a, 2022.

YANG, G. et al. Convolutional neural network-based embarrassing situation detection under camera for social robot in smart homes. **Sensors**, <https://doi.org/10.3390/s18051530>, v. 18, p. 1530, 2018.

ZHANG, Z. et al. Danger-pose detection system using commodity wi-fi for bathroom monitoring. **Sensors**, <https://doi.org/10.3390/s19040884>, v. 19, n. 4, p. 884, 2019.

ZIELINSKA, T. History of service robots and new trends. **Novel Design and Applications of Robotics Technologies**, [S.l.], p. 30, 2019.

ZIMMERMANN, G. et al. Universal remote console standard: toward natural user interaction in ambient intelligence. In: CHI '04 EXTENDED ABSTRACTS ON HUMAN FACTORS IN COMPUTING SYSTEMS, 2004, New York, NY, USA. **Anais...** Association for Computing Machinery, 2004. p. 1608–1609. (CHI EA '04).

APÊNDICE A – INFORMAÇÕES COMPLEMENTARES

Tabela 18: Artigos selecionados a partir do mapeamento sistemático.

Id	Referência	Classif.	Escopo	Tecnol.	Modelo	Doença	Grupo
S1	Abascal et al., 2009 (ABASCAL et al., 2009)	Ciência do contexto	Atuação	AS	Sim	Não específico	PCD e Idosos
S2	Alhussein et al., 2018 (ALHUSSEIN; MUHAMMAD; HOSSAIN, 2018)	Ciência do contexto	Deteção	AS / W	Não	Epilepsia	Não específico
S3	Alkhomsan et al., 2017 (ALKHOMSAN et al., 2017)	Ciência do contexto	Deteção	AS / W	Sim	Não específico	Idosos
S4	Al-Shaqi et al., 2016 (AL-SHAQI; MOURSHED; REZGUI, 2016)	Sistema de suporte	Somente monitoramento	AS / W	Não	Não específico	Idosos
S5	Amirib. e Bouc., 2018 (AMIRIBESHELI; BOUCHACHIA, 2018)	Identificação de atividades	Deteção	AS	Não	Demência	Não específico
S6	Bastaki et al., 2017 (BASTAKI; BOSAKOWSKI; BENKHELIFA, 2017)	Sistema de suporte	Notificação	W	Sim	Não específico	Idosos
S7	Becker et al., 2009a (BECKER et al., 2009b)	Ciência do contexto	Deteção	AS / W / SR	Não	Não específico	Idosos
S8	Becker et al., 2009b (BECKER et al., 2009c)	Sistema de suporte	Notificação	AS	Não	Não específico	Idosos

continua na próxima página

Tabela 18 – continuação da página anterior

Id	Referência	Classif.	Escopo	Tecnol.	Modelo	Doença	Grupo
S9	Bonaccorsi et al., 2016 (BONACCORSI et al., 2016b)	Assistência robótica	Atuação	AS / SR	Sim	Não específico	Idosos
S10	Borelli et al., 2018 (BORELLI et al., 2019)	Identificação de atividades	Deteção	AS / W	Sim	Não específico	Idosos
S11	Botia et al., 2012 (BOTIA; VILLA; PALMA, 2012)	Ciência do contexto	Deteção	AS	Sim	Não específico	Idosos
S12	Bouchard et al., 2012 (BOUCHARD; BOUCHARD; BOUZOUANE, 2012)	Ciência do contexto	Somente monitoramento	AS	Não	Alzheimer	Não específico
S13	Chan et al., 2014 (CHAN et al., 2014)	Ciência do contexto	Notificação	AS	Não	Alzheimer	Idosos
S14	Chen et al., 2012 (CHEN et al., 2012)	Ciência do contexto	Notificação	AS / W	Não	Não específico	Não específico
S15	Chen et al., 2015 (CHEN et al., 2015)	Ciência do contexto	Deteção	AS / W	Não	Não específico	Idosos
S16	De Brouwer et al., 2018 (BROUWER et al., 2018)	Sistema de suporte	Notificação	AS / W	Sim	Não específico	Não específico
S17	Deen, 2015 (DEEN, 2015)	Sistema de suporte	Notificação / Atuação	AS / W	Sim	Não específico	Idosos
S18	Do et al., 2018 (DO et al., 2018)	Assistência robótica	Deteção	W / SR	Sim	Não específico	Idosos
S19	Doukas et al., 2009 (DOUKAS et al., 2009)	Ciência do contexto	Deteção	AS	Não	Não específico	Idosos
S20	Doukas et al., 2011 (DOUKAS et al., 2011)	Sistema de suporte	Notificação	AS / W	Sim	Não específico	Idosos e PCD

continua na próxima página

Tabela 18 – continuação da página anterior

Id	Referência	Classif.	Escopo	Tecnol.	Modelo	Doença	Grupo
S21	Fiorini et al., 2017 (FIORINI et al., 2017)	Assistência robótica	Atuação	W / SR	Sim	Não específico	Idosos
S22	Ghasemi et al., 2019 (GHASEMI; REZAEI; RAHMANI, 2019)	Sistema de suporte	Somente monitoramento	AS / W	Sim	Não específico	Idosos
S23	Helal et al., 2009 (HELAL; COOK; SCHMALZ, 2009)	Identificação de atividades	Notificação	W	Sim	Diabetes	Não específico
S24	Huang et al., 2012 (HUANG; YU; SYU, 2012)	Sistema de suporte	Somente monitoramento	AS	Não	Obesidade	Não específico
S25	Huang et al., 2013 (HUANG et al., 2013)	Ciência do contexto	Somente monitoramento	AS	Não	Distúrbios do sono	Não específico
S26	Iqbal et al., 2013 (IQBAL et al., 2013)	Sistema de suporte	Notificação	AS	Sim	Demência	Idosos
S27	Jarvis et al., 2009 (JARVIS et al., 2009)	Assistência robótica	Atuação	AS / SR	Não	Não específico	Idosos e PCD
S28	Jung e Yoon, 2017 (JUNG; YOON, 2017)	Ciência do contexto	Notificação	AS / W	Sim	Estresse	Não específico
S29	Kaffash-Ch. et al., 2019 (KAFFASH-CHARANDABI; ALESHEIKH; SHARIF, 2019)	Sistema de suporte	Somente monitoramento	AS	Sim	Asma	Não específico
S30	Klakegg et al., 2017 (KLAKEGG et al., 2017)	Ciência do contexto	Somente monitoramento	AS	Não	Não específico	Idosos

continua na próxima página

Tabela 18 – continuação da página anterior

Id	Referência	Classif.	Escopo	Tecnol.	Modelo	Doença	Grupo
S31	Kourtis et al., 2019 (KOURTIS et al., 2019)	Ciência do contexto	Detecção	W	Não	Alzheimer	Não específico
S32	Lin et al., 2009 (LIN et al., 2009)	Assistência robótica	Atuação	SR	Não	Não específico	Idosos e PCD
S33	Manzi et al., 2017 (MANZI et al., 2017)	Assistência robótica	Atuação	SR	Sim	Não específico	Idosos
S34	Medjahed et al., 2011 (MEDJAHED et al., 2011)	Identificação de atividades	Detecção	AS / W	Sim	Não específico	Idosos
S35	Mehdi e Berns, 2011 (MEHDI; BERNS, 2011)	Assistência robótica	Detecção	SR	Não	Não específico	Idosos
S36	Meliones e Kok., 2015 (MELIONES; KOKKOVOS, 2015)	Ciência do contexto	Notificação	AS	Não	Não específico	Não específico
S37	Olivier et al., 2009 (OLIVIER et al., 2009)	Identificação de atividades	Notificação / Atuação	AS / W	Não	Cognitivo	Não específico
S38	Oliver et al., 2018 (OLIVER et al., 2018)	Sistema de suporte	Notificação / Atuação	AS	Sim	Demência	Idosos
S39	Papageorg. et al., 2017 (PAPAGEORGIOU et al., 2017)	Assistência robótica	Atuação	SR	Não	Não específico	Idosos
S40	Pereira et al., 2016 (PEREIRA et al., 2016)	Identificação de atividades	Notificação	AS / W	Não	Doenças crônicas	Não específico
S41	Pham et al., 2018 (PHAM et al., 2018)	Assistência robótica	Atuação	AS / W / SR	Sim	Não específico	Idosos

continua na próxima página

Tabela 18 – continuação da página anterior

Id	Referência	Classif.	Escopo	Tecnol.	Modelo	Doença	Grupo
S42	Poncela et al., 2018 (PONCELA et al., 2018)	Identificação de atividades	Atuação	AS / SR	Não	Não específico	Idosos e PCD
S43	Spanakis et al., 2012 (SPANAKIS et al., 2012)	Sistema de suporte	Notificação	W	Não	Diabetes	Não específico
S44	Suryadev. e M., 2014 (SURYADEVARA; MUKHOPADHYAY, 2014)	Identificação de atividades	Detecção	AS	Não	Não específico	Idosos
S45	Temdee e Utt., 2019 (TEMDEE; UTTAMA, 2019)	Sistema de suporte	Somente monitoramento	AS	Sim	Não específico	Idosos
S46	Tentori et al., 2015 (TENTORI; ESCOBEDO; BALDERAS, 2015)	Sistema de suporte	Somente monitoramento	AS	Não	Autismo	Crianças
S47	Valero et al., 2014 (VALERO et al., 2014)	Ciência do contexto	Notificação / Atuação	AS / W	Sim	Não específico	Idosos
S48	Yang et al., 2018 (YANG et al., 2018)	Identificação de atividades	Detecção	SR	Não	Não específico	Não específico
S49	Zhang et al., 2019 (ZHANG et al., 2019)	Ciência do contexto	Detecção	AS	Sim	Não específico	Não específico

Tabela 19: Cenários desenvolvidos com base na literatura.

Id	PAR	Descrição do contexto	Mapeamento atributos de risco
CE1	Idoso	<p>Atividade trivial do cotidiano Paulo tem <u>63 anos</u> (A), é professor, casado e convive diariamente com sua esposa, Julia de 62 anos, em um <u>apartamento amplo e bem iluminado</u> (B). Ele <u>não possui doenças ou comorbidades</u> (C). Além disso, Paulo <u>não consome medicamentos</u> (D). Ele segue ainda uma <u>alimentação regrada e pratica exercícios físicos diariamente</u> (E). Paulo e a esposa gostam de viajar e conhecer novos lugares e novas pessoas. Em uma determinada <u>manhã</u> (F), enquanto sua esposa toma banho, ele <u>toma seu chá e lê sua revista favorita</u> (G) <u>sentado no sofá da sala</u> (H), enquanto a aguarda para tomarem o café da manhã juntos.</p>	(A) att_0; (B) att_13; (C) att_11 e att_12; (D) att_25; (E) att_23; (F) att_21; (G) att_1; (H) att_2.
			continua na próxima página

Tabela 19 – continuação da página anterior

Id	PAR	Descrição do contexto	Mapeamento atributos de risco
CE2	Criança	<p>Luiza tem <u>6 anos</u> (A) de idade e está aproveitando o feriadão de Páscoa para ficar junto com a sua família no apartamento em que residem. Sua mãe e seu pai estão conversando no sofá próximo ao que Luiza <u>está sentada</u> (B), assistindo aos seus desenhos animados favoritos. Luiza pede para sua mãe preparar seu lanche favorito para comer enquanto aproveita a parte preferida do seu desenho. A mãe de Luiza se dirige até a cozinha e, enquanto prepara o lanche, <u>o pai de Luiza a acompanha assistindo a menina</u> (C) em suas necessidades. Ao retornar da cozinha, a mãe entrega para Luiza seu lanche para ser desfrutado por ela sentada no sofá enquanto <u>seus pais retomam sua conversa</u> (D).</p>	(A) att_0; (B) att_0; (C) att_20; (D) att_1.
CE3	PCD cadeirante criança	<p>Camila é uma <u>cadeirante paraplégica</u> (A) e está com 29 anos. Depois de um dia de trabalho, em que desempenhou suas atividades como analista de sistemas na modalidade <i>home office</i>, ela resolve assistir a um novo documentário sobre arte no seu sistema de <i>streaming</i> favorito. Além de analista de sistemas, ela também tem como <i>hobby</i> a pintura à óleo sobre telas. No <u>final da noite</u> (B), já cansada e com sono, dirige-se até sua cama, em <u>seu quarto</u> (C) para dormir, seguindo seu ritual noturno cotidiano antes de adormecer.</p>	(A) att_0; (B) att_21; (C) att_2.

continua na próxima página

Tabela 19 – continuação da página anterior

Id	PAR	Descrição do contexto	Mapeamento atributos de risco
CE4-CE6	Idoso	<p>José está com <u>80 anos</u> (A), é diabético e consome <u>medicamentos</u> (B) para controle da pressão arterial. Reside <u>sozinho</u> (C) em sua casa e está dormindo em sua cama no seu quarto à noite. Acorda durante a <u>madrugada</u> (D) sentindo necessidade de ir ao banheiro. Senta-se na lateral da cama antes de se levantar. O quarto está <u>escuro</u> (E) e o idoso <u>procura seus calçados</u> (F) no chão ao lado da cama, sem encontrar. Levanta-se, posicionando-se de pé, e segue caminhando lentamente buscando encontrar o <u>equilíbrio corporal</u> (G) para se deslocar até o banheiro. Ao entrar no banheiro, acende a <u>iluminação</u> (H) do banheiro. Após realizar suas necessidades, desliga a <u>iluminação</u> (I) do banheiro e retorna lentamente para o quarto. Quando se aproxima da cama, <u>tropeça em um dos chinelos</u> que estavam na lateral da cama, <u>cai no chão</u> (J), de modo a <u>lesionar as partes inferiores do corpo</u> (K), necessitando de atendimento médico urgente, porém se encontra distante do seu telefone e impossibilitado de se deslocar por conta das lesões.</p>	(A) att_0; (B) att_25; (C) att_20; (D) att_21; (E) att_13; (F) att_1; (G) att_6; (H) att_13; (I) att_13; (J) att_2; (K) LesoesJoelhosPer-nas _S80-S89.
			continua na próxima página

Tabela 19 – continuação da página anterior

Id	PAR	Descrição do contexto	Mapeamento atributos de risco
CE7-CE9	Criança	<p>Bruno tem <u>2 anos</u> (A) de idade e há poucos meses <u>começou a caminhar</u> (B) com mais independência. Ele está na fase de exploração do ambiente e tudo que o cerca. Em um determinado dia, durante a tarde, ele está brincando na sala de sua casa, sendo <u>supervisionado</u>, (C) à distância, por sua mãe que se encontra na cozinha preparando uma refeição. Enquanto sua mãe <u>se distrai</u> (D) atendendo uma videochamada de sua tia, Bruno se movimenta da sala até o pátio da casa <u>correndo</u> (E) atrás de seu cão que vai em direção ao pátio, aonde há uma <u>piscina</u> (F) com 1,7 metros de profundidade. A piscina se encontra cheia de água e sem proteção. Quando Bruno se aproxima da piscina, a bolinha que ele e o cão perseguiam <u>cai na piscina</u> (G). O cão realiza uma manobra rápida e retorna para dentro de casa, mas Bruno <u>segue em direção à água</u> para recuperar a bolinha. Bruno <u>cai dentro da piscina</u> (H) e tenta durante alguns minutos, <u>batendo suas mãos e pés</u> (I), sair da água, sem sucesso.</p>	<p>(A) att_0; (B) att_1; (C) att_20; (D) att_20; (E) att_1; (F) att_2; (G) att_2; (H) att_2; (I) att_1; (J) OutrosNaoDefinidos EfeitosCausasExternas_T66-T78.</p>
			continua na próxima página

Tabela 19 – continuação da página anterior

Id	PAR	Descrição do contexto	Mapeamento atributos de risco
CE10-CE12	PCD surdo adulto	<p>Elias é um <u>PCD surdo</u> (A) congênito, com 37 anos, que reside com sua esposa Maria, que é ouvinte. Eles se comunicam por LIBRAS. Em uma determinada noite, <u>Maria vai até a academia praticar exercícios</u> (B), como realiza semanalmente. Elias decide proporcionar uma surpresa para a esposa preparando seu prato favorito. Ele coloca as panelas com os alimentos a serem cozidos sobre o <u>fogão à gás e acende as chamas</u> (C). Enquanto os alimentos cozinham, ele se dirige ao banheiro para tomar seu banho. Antes de entrar no banho, distrai-se com uma mensagem que recebeu em seu smartphone. Depois de alguns minutos, prossegue até o banheiro e se banha <u>demoradamente</u> (D). Enquanto isso, as panelas que estavam sobre o fogão superaquecem e os alimentos entram em <u>combustão</u> (E). Quando Elias sai do banheiro, observa a fumaça saindo da cozinha. Com o princípio de <u>incêndio</u> (F), assustado, Elias toma a iniciativa de remover as panelas de cima do fogão, na tentativa de cessar o fogo, porém, acaba <u>se queimando seriamente com o líquido quente e as chamas que lesionam partes do seu corpo</u> (G).</p>	<p>(A) att_0; (B) att_20; (C) att_26; (D) att_1; (E) att_15; (F) att_16; (G) OutrosNaoDefinidos EfeitosCausasExternas_T66-T78.</p>
continua na próxima página			

Tabela 19 – continuação da página anterior

Id	PAR	Descrição do contexto	Mapeamento atributos de risco
CE13-CE15	Criança	<p>Artur está com <u>4 anos</u> (A) de idade e recebe em sua casa seu primo Lucas de <u>5 anos</u> (B) de idade para brincarem durante as férias. A mãe de Artur os deixa <u>sozinhos</u> (B) na sala enquanto sai para realizar a limpeza e a alimentação dos pets nos fundos da casa. Lucas gosta de brincar com brinquedos de encaixar e sugere a Artur brincar com os <u>grampos de cabelo metálicos</u> (C) de sua mãe que estão sobre a mesa ao lado. A seguir, enquanto brincam sozinhos e de posse dos grampos metálicos, dirigem-se <u>em direção às tomadas elétricas próximas</u> (D) que estão <u>sem proteção</u> (E) alguma para conectarem. Ao plugar um dos grampos na tomada elétrica, Artur recebe uma <u>forte carga elétrica e leva um choque</u> (F). Lucas assustado, tenta ajudar puxando o primo Artur, de modo que também é <u>eletrocutado</u> (F).</p>	(A) att_0; (B) att_20; (C) att_26; (D) att_26; (E) att_20; (F) OutrosNaoDefinidos EfeitosCausasExternas_T66-T78.

Tabela 20 – Perfil dos cuidadores entrevistados.

Id Cuidador	Perfil profissional e acadêmico	Tempo de experiência (anos)
C1	Técnica em Enfermagem, com experiência em cuidados de idosos, com formação extensionista complementar orientada a dependentes químicos, alcoólatras e pacientes psiquiátricos.	12
C2	Terapeuta Ocupacional (TO) com experiência em cuidados de idosos, crianças e PCDs. Pós-graduada em Ergonomia, Educação especial inclusiva, Psicologia educacional, Gestão em clínicas e consultórios e cursando especialização em terapia ocupacional na reorganização sensorial no autismo, além de formação complementar extensionista em diversas áreas.	19
C3	Coordenadora pedagógica de escola de educação especial para surdos. Pedagoga Pós-graduada em Educação Especial e Inclusiva com ampla experiência em educação e assistência a PCDs.	8
C4	Familiar de idoso com autonomia reduzida.	8
C5	Familiar de criança com autonomia reduzida.	3

Tabela 21 – Relação de cenários validados por cuidador.

Id Cuidador	Ids Cenários	Comentários
C1	CE1, CE2, CE4-CE9, C13-C15	Validação dos cenários envolvendo idosos e crianças.
C2	CE1-CE15	Validação de todos os cenários.
C3	CE3, CE10-CE12	Validação dos cenários envolvendo PCDs.
C4	CE1, CE4-CE6	Validação dos cenários envolvendo idosos.
C5	CE2, CE7-CE9, CE13-CE15	Validação dos cenários envolvendo crianças.

Tabela 22: Descrição dos atributos da estrutura do dicionário do Apollo *Simulator* baseado na ontologia ApolloOnto.

Id	Superclasse	Classe	Descrição
att_0	<i>Thing</i>	PAR	Pessoa com Autonomia Reduzida.
att_1	Contexto	Atividade	Atividades da Vida Diária da PAR.
att_2	Contexto	LocalizacaoSemantica	Local físico no ambiente inteligente.
att_3	Contexto_Saude	EstadoECG	Classificação do indicador de ECG.
att_4	Contexto_Saude	EstadoEEG	Classificação do indicador de EEG.
att_5	Contexto_Saude	EstadoFrequenciaCardiaca	Classificação do indicador de frequência cardíaca.
att_6	Contexto_Saude	EstadoMovimentoEquilibrio	Classificação do indicador de movimento e equilíbrio.
att_7	Contexto_Saude	EstadoPressaoArterial	Classificação do indicador de pressão arterial.
att_8	Contexto_Saude	EstadoPsicologico	Classificação do indicador de avaliação de estado psicológico.
att_9	Contexto_Saude	EstadoSaturacao	Classificação do indicador de saturação de oxigênio.
att_10	Contexto_Saude	EstadoTemperaturaCorporal	Classificação do indicador de febre.
att_11	Contexto_Saude	Comorbidade	Existência de comorbidades.
att_12	Contexto_Saude	DoencaCronica	Existência de doença crônica.
att_13	Contexto_AmbienteFisico	Luminosidade	Grau de luminosidade do local semântico.
att_14	Contexto_AmbienteFisico	PressaoAr	Nível de pressão atmosférica.
att_15	Contexto_AmbienteFisico	Ruido	Nível de ruído do local semântico.

continua na próxima página

Tabela 22 – continuação da página anterior

Id	Superclasse	Classe	Descrição
att_16	Contexto_ AmbienteFisico	Temperatura	Temperatura do local semântico.
att_17	Contexto_ AmbienteFisico	TipoPiso	Tipo de piso do local semântico.
att_18	Contexto_ AmbienteFisico	UmidadeAr	Umidade relativa do ar do local semântico.
att_19	Contexto_ AmbienteFisico	VelocidadeVento	Velocidade do vento no local semântico.
att_20	Contexto	Supervisão	Existência de supervisão a PAR.
att_21	Contexto	PeriodoDia	Classificação do turno do dia.
att_22	<i>Thing</i>	EducacaoSuporte	Existência de recurso para apoio à educação da PAR.
att_23	<i>Thing</i>	ExercicioAtividadeFisica	PAR pratica exercícios ou atividades físicas regularmente.
att_24	<i>Thing</i>	TecnologiaAssistiva	PAR utiliza algum recurso ortopédico ou tecnologia assistiva.
att_25	<i>Thing</i>	Medicacao	PAR consome medicamento de uso contínuo.
att_26	<i>Thing</i>	Objeto	Objeto do ambiente inteligente próximo ou sendo usado por PAR.
att_27	<i>Thing</i>	AcaoNotificacao	Tipo de notificação ou ação a ser executada.
att_28	<i>Thing</i>	Risco	Classificação de risco.
att_29	<i>Thing</i>	Acidente	Classificação de acidente.

Tabela 23: Dados da estrutura de dicionário do Apollo *Simulator* baseado na ontologia ApolloOnto.

Id	Superclasse	Classe	Instâncias: Valor
att_0	<i>Thing</i>	PAR	Nenhum: 0 Idoso: 1 Criança: 2 PCD: 3 Gestante: 4
att_1	Contexto	Atividade	Nenhum: 0 ParadoEmPe: 1 SentadoCama: 2 SentadoSofa: 3 Caminhada: 4 Corrida: 5 DeitadoCama: 6 DeitadoChao: 7 DeitadoSofa: 8 DeitadoChao: 9 Agachado: 10 Bebendo: 11 Comendo: 12 EmVeiculo: 13 EmBicicleta: 14
			continua na próxima página

Tabela 23 – continuação da página anterior

Id	Superclasse	Classe	Instâncias: Valor
			MovimentandoMaos: 15 MovimentandoPes: 16
att_2	Contexto	Localização semântica	Nenhum: 0 BanheiroPrincipal: 1 BanheiroSocial: 2 Biblioteca: 3 Cozinha: 4 Elevador: 5 Escadaria: 6 Estacionamento: 7 ExternoResidencia: 8 HallEntrada: 9 Patio: 10 QuartoPrincipal: 11 QuartoSecundario: 12 QuartoTerciario: 13 Sala: 14 Varanda: 15 Piscina: 16
att_3	Contexto_Saude	EstadoECG	Nenhum: 0 Normal: 1 Anormal: 2
			continua na próxima página

Tabela 23 – continuação da página anterior

Id	Superclasse	Classe	Instâncias: Valor
att_4	Contexto_Saude	EstadoEEG	Nenhum: 0 Normal: 1 Anormal: 2
att_5	Contexto_Saude	EstadoFrequenciaCardiaca	Nenhum: 0 Repouso: 1 Normal: 2 AgitacaoRegular: 3 AgitacaoIrregular: 4
att_6	Contexto_Saude	EstadoMovimentoEquilibrio	Nenhum: 0 Normal: 1 Anormal: 2
att_7	Contexto_Saude	EstadoPressaoArterial	Nenhum: 0 Normal: 1 Anormal: 2
att_8	Contexto_Saude	EstadoPsicologico	Nenhum: 0 Normal: 1 Anormal: 2
att_9	Contexto_Saude	EstadoSaturacao	Nenhum: 0 Normal: 1 Anormal: 2
att_10	Contexto_Saude	EstadoTemperaturaCorporal	Nenhum: 0 Normal: 1
			continua na próxima página

Tabela 23 – continuação da página anterior

Id	Superclasse	Classe	Instâncias: Valor
			Estado febril: 2 Febre alta: 3
att_11	Contexto_Saude	Comorbidade	Nenhum: 0 Não: 1 Sim: 2
att_12	Contexto_Saude	DoencaCronica	Nenhum: 0 Não: 1 Sim: 2
att_13	Contexto_ AmbienteFisico	Luminosidade	Nenhum: 0 Claro: 1 Médio: 2 Escuro: 3
att_14	Contexto_ AmbienteFisico	PressaoAr	Nenhum: 0 Normal: 1 Baixa: 2 Alta: 3
att_15	Contexto_ AmbienteFisico	Ruido	Nenhum: 0 Normal: 1 Alto: 2

continua na próxima página

Tabela 23 – continuação da página anterior

Id	Superclasse	Classe	Instâncias: Valor
att_16	Contexto_ AmbienteFisico	Temperatura	Nenhum: 0 Normal: 1 Frio: 2 Quente: 3 Muito frio: 4 Muito quente: 5
att_17	Contexto_ AmbienteFisico	TipoPiso	Nenhum: 0 Normal: 1 Antiderrapante: 2 Escorregadio: 3
att_18	Contexto_ AmbienteFisico	UmidadeAr	Nenhum: 0 Normal: 1 Baixa: 2 Alta: 3
att_19	Contexto_ AmbienteFisico	VelocidadeVento	Nenhum: 0 Normal: 1 Alta: 2
att_20	Contexto	Supervisão	Nenhum: 0
			continua na próxima página

Tabela 23 – continuação da página anterior

Id	Superclasse	Classe	Instâncias: Valor
			Sim: 1 Não: 2
att_21	Contexto	PeriodoDia	Nenhum: 0 Manhã: 1 Tarde: 2 Noite: 3 Madrugada: 4
att_22	<i>Thing</i>	EducacaoSuporte	Nenhum: 0 Não: 1 Sim: 2
att_23	<i>Thing</i>	ExercicioAtividadeFisica	Nenhum: 0 Não: 1 Sim: 2
att_24	<i>Thing</i>	TecnologiaAssistiva	Nenhum: 0 Não: 1 Sim: 2
att_25	<i>Thing</i>	Medicacao	Nenhum: 0 Não: 1 Sim: 2
att_26	<i>Thing</i>	Objeto	Nenhum: 0 TomadaEletrica: 1 Eletrodomestico: 2

continua na próxima página

Tabela 23 – continuação da página anterior

Id	Superclasse	Classe	Instâncias: Valor
			Fio: 3 Faca: 4 Fogao: 5 Panela: 6 Escada: 7 Banco: 8 Cama: 9 Banheira: 10
att_27	<i>Thing</i>	AcaoNotificacao	Nenhum: 0 PAR: 1 Cuidador: 2 ApolloBot: 3 PAR e Cuidador: 4 PAR e ApolloBot: 5 Cuidador e ApolloBot: 6 PAR, Cuidador e ApolloBot: 7
att_28	<i>Thing</i>	Risco	Nenhum: 0 Queda - risco baixo: 1 Queda - risco médio: 2 Queda - risco alto: 3 Afogamento - risco baixo: 4 Afogamento - risco médio: 5
			continua na próxima página

Tabela 23 – continuação da página anterior

Id	Superclasse	Classe	Instâncias: Valor
			Afogamento - risco alto: 6 Intoxicação - risco baixo: 7 Intoxicação - risco médio: 8 Intoxicação - risco alto: 9 Queimadura - risco baixo: 10 Queimadura - risco médio: 11 Queimadura - risco alto: 12 Choque elétrico - risco baixo: 13 Choque elétrico - risco médio: 14 Choque elétrico - risco alto: 15
att_29	<i>Thing</i>	Acidente	Nenhum: 0 LesoesCabeca_S00-S09: 1 LesoesCotoveloAntebraco_S50-S59: 2 LesoesJoelhosPernas_S80-S89: 3 LesoesMultiplasPartesCorpo_T00-T07: 4 LesoesOmbrosMembrosSuperiores_S40-S49: 5 LesoesPartesNaoIdentificadasTronco MembrosRegiaoCorpo_T08-T14: 6 LesoesPescoco_S10-S19: 7 LesoesPulsoMaos_S60-S69: 8 LesoesQuadrilCoxa_S70-S79: 9 LesoesTorax_S20-S29: 10
			continua na próxima página

Tabela 23 – continuação da página anterior

Id	Superclasse	Classe	Instâncias: Valor
			LesoesTornozelosPes_S90-S99: 11 LesoesAbdomenLombarEspinhaPelvis_S30-S39: 12 QueimaduraPorFrio_T33-T35: 13 QueimadurasCorrosoes_T20-T32: 14 EfeitosCorpoEstranhoEntrandoOrificioNatural_T15-T19: 15 EfeitosSubstanciasToxicas_T51-T65: 16 EnvenenamentoDrogasMedicamentos SubstanciasBiologicas_T36-T50: 17 OutrosNaoDefinidosEfeitosCausasExternas_T66-T78: 18

Tabela 24: Cenários-base utilizados para geração de instâncias de históricos de contextos do modelo Apollo.

Id	ApolloOnto - Risco	Descrição	att_0,att_1,att_2,.....,att_29
CE1	Nenhum_000-000	Atividade da Vida Cotidiana (AVD) ordinária	0,5,16,1,1,1,1,1,0,0,1,0,0,0,2,1,1,0,1,0,0,4,1,1,1,0,0,0,0
CE2	Nenhum_000-000	Assistindo TV	2,3,14,1,1,2,1,1,1,1,1,2,2,2,0,3,3,3,1,2,1,2,2,2,2,1,0,0,0,0
CE3	Nenhum_000-000	Dormindo	3,6,12,1,1,2,1,1,1,1,1,1,1,3,1,1,1,1,1,1,4,1,1,1,1,0,0,0,0
CE4	Queda_W00-W19	Queda - risco baixo	1,1,6,1,1,2,1,1,1,1,1,2,2,1,1,1,1,1,1,1,2,1,1,1,2,0,1,1,0
CE5	Queda_W00-W19	Queda - risco médio	1,16,6,2,1,2,2,1,1,1,1,2,2,2,1,1,1,3,1,1,2,2,1,1,1,2,0,4,2,4
CE6	Queda_W00-W19	Queda - risco alto	1,7,6,2,1,2,2,1,1,1,1,2,2,2,1,1,1,3,1,1,2,2,1,1,1,2,0,4,3,4
CE7	AfogamentoSubmersao_W65-W74	Afogamento - risco baixo	2,5,10,1,1,2,1,1,1,1,1,1,1,1,1,1,1,3,1,1,1,1,2,1,1,1,1,0,1,4,0
CE8	AfogamentoSubmersao_W65-W74	Afogamento - risco médio	2,5,16,1,1,2,1,1,1,1,1,1,1,1,1,1,1,3,3,1,1,2,2,1,1,1,1,0,4,5,18
CE9	AfogamentoSubmersao_W65-W74	Afogamento - risco alto	2,15,16,1,1,4,2,1,1,1,1,1,1,1,1,1,2,0,3,1,1,2,2,1,1,1,1,0,7,6,18
CE10	ContatoCalorSubstanciasQuentes_X10-X19	Queimadura - risco baixo	3,1,4,1,1,2,1,1,0,0,1,0,0,1,1,1,1,1,1,1,2,3,1,1,2,1,5,1,10,0
CE11	ContatoCalorSubstanciasQuentes_X10-X19	Queimadura - risco médio	3,15,4,2,1,2,1,1,0,0,1,0,0,1,1,2,1,1,1,1,2,3,1,1,2,1,5,4,11,14

continua na próxima página

Tabela 24 – continuação da página anterior

Id	ApolloOnto - Risco	Descrição	att_0,att_1,att_2,.....,att_29
CE12	ContatoCalorSubstanciasQuentes_X10-X19	Queimadura - risco alto	3,12,4,2,1,2,1,1,2,0,1,0,0,1,1,2,3,1,1,1,2,3,1,1,2,1,5,7,12,14
CE13	ExposicaoCorrenteEletricaRadiacao TemperaturaPressaoArExtrema_W85-W99	Choque elétrico - risco baixo	2,3,14,1,1,2,1,1,1,1,1,1,1,1,1,1,1,1,1,1,1,1,1,2,1,1,1,1,3,2,13,0
CE14	ExposicaoCorrenteEletricaRadiacao TemperaturaPressaoArExtrema_W85-W99	Choque elétrico - risco médio	2,1,14,1,1,2,1,1,1,1,1,1,1,1,1,1,1,1,1,1,1,1,1,2,2,1,1,1,1,1,2,14,4
CE15	ExposicaoCorrenteEletricaRadiacao TemperaturaPressaoArExtrema_W85-W99	Choque elétrico - risco alto	2,1,14,2,2,4,2,1,2,2,2,1,1,1,1,2,1,1,1,1,2,2,1,1,1,1,1,7,15,4

Tabela 25: Cenários de teste utilizados para a avaliação da acurácia preditiva do modelo *HMM*, considerando instâncias de históricos de contextos de PARs modelados e gerados pelo Apollo *Simulator*.

Id	ApolloOnto - Risco	Descrição	att_0,att_1,att_2,.....,att_29	Input HMM
CT1	Nenhum_000-000	AVD	0,6,12,0,1,1,0,0,1,0,1,0,0,1,1,1,0,1,0,1,1,1,4,1,1,1,0,0,0,0 0,5,16,0,0,3,0,1,1,1,1,0,0,0,2,0,1,1,0,0,1,2,1,1,1,0,0,0,0 0,7,16,1,0,3,1,0,0,0,1,1,1,1,1,1,1,1,1,1,1,1,2,0,1,1,0,0,0,0 0,2,16,0,0,0,0,0,1,0,0,1,1,1,0,1,1,0,1,1,1,1,1,0,0,0,0,0,0 0,5,3,1,0,3,1,0,0,1,1,1,1,1,1,2,1,0,0,0,0,0,2,0,0,0,0,0,0	00000
CT2	Queda_W00-W19	Queda	1,1,1,1,1,2,1,1,1,1,1,1,1,1,1,1,0,1,1,1,1,1,1,1,1,1,0,0,0,0 1,1,1,1,1,2,1,1,1,1,1,1,1,2,1,1,1,1,1,1,1,1,1,1,1,1,0,0,0,0 1,1,1,1,1,2,1,1,1,1,1,1,1,2,1,1,1,1,1,1,1,1,1,1,1,1,0,1,1,0 1,1,1,1,1,3,2,1,2,1,1,1,1,2,1,1,1,1,1,1,1,2,1,1,1,1,0,4,2,1 1,1,1,2,2,4,2,2,2,2,1,1,1,2,1,1,1,3,1,1,2,1,1,1,1,1,0,7,3,1	00123
CT3	AfogamentoSubmersao_W65-W74	Afogamento	2,1,10,0,0,0,0,0,0,0,0,0,0,0,1,1,1,1,1,1,1,0,0,0,0,0,0,0,0,0 2,1,10,1,1,2,1,1,1,1,1,1,1,1,1,1,1,1,1,0,2,0,0,0,0,0,1,4,0 2,1,10,1,1,2,1,1,1,1,1,1,1,1,1,1,1,1,1,0,2,1,0,0,0,0,1,4,0 2,1,10,1,1,2,2,1,1,2,1,1,1,1,1,1,1,1,1,1,2,0,0,0,0,0,4,5,18 2,1,10,1,1,2,2,1,1,2,1,1,1,1,1,1,1,1,1,1,2,2,0,0,0,0,0,7,5,18	01122
CT4	ContatoCalorSubstanciasQuentes_X10-X19	Queimadura	3,1,4,0,0,0,0,0,0,0,0,0,0,0,1,1,1,1,1,1,1,0,0,0,0,0,0,0,0,0 3,1,4,0,0,0,1,0,0,0,0,2,2,1,1,1,1,1,1,1,3,0,0,2,1,2,1,10,0	

continua na próxima página

Tabela 25 – continuação da página anterior

Id	ApolloOnto - Risco	Descrição	att_0,att_1,att_2,.....,att_29	Input HMM
			3,1,4,0,0,0,1,0,0,0,0,2,2,1,1,1,1,1,1,0,0,0,0,0,2,0,0,0 3,1,4,2,2,0,1,0,0,0,0,2,2,1,1,1,1,1,1,1,3,0,0,2,1,2,4,11,14 3,1,4,2,2,4,1,0,0,0,1,2,2,1,1,1,1,1,1,1,2,3,0,0,2,1,2,7,11,14	01022
CT5	ExposicaoCorrenteEletricaRadiacao TemperaturaPressaoArExtrema _W85-W99	Choque elétrico	1,2,11,1,1,1,1,1,1,1,1,1,3,1,1,1,1,1,1,2,4,1,1,2,1,1,0,0,0 1,2,11,2,2,3,1,1,1,1,1,1,1,2,1,1,1,1,1,1,1,4,1,1,1,1,1,13,0 1,2,11,2,2,4,2,1,2,1,1,1,1,2,1,1,1,1,1,1,1,4,1,1,1,1,1,4,14,18 1,2,11,1,1,1,1,1,1,1,1,1,1,2,1,1,2,1,1,1,1,4,1,1,2,1,1,1,13,0 1,2,11,2,2,4,2,1,2,2,1,1,1,2,1,1,1,1,1,1,1,4,1,1,1,1,1,7,15,18	01213